

# Uma Abordagem Baseada em Algoritmo Genético para Recomendação de Objetos de Aprendizagem Sensível ao Contexto do Estudante

Luiz Jácome Júnior<sup>1</sup>, Francisco Milton Mendes Neto<sup>1</sup>,  
Luiz Cláudio Nogueira da Silva<sup>2</sup>

<sup>1</sup>Programa de Pós-Graduação em Ciência da Computação - PPGCC  
Departamento de Ciências Exatas e Naturais - DCEN  
Universidade Federal Rural do Semi-Árido - UFERSA  
BR 110 - Km 47 Bairro Pres. Costa e Silva – CEP 59.625-900 – Mossoró - RN

<sup>2</sup>Superintendência de Tecnologia da Informação e Comunicação - SUTIC  
Universidade Federal Rural do Semi-Árido - UFERSA  
BR 110 - Km 47 Bairro Pres. Costa e Silva – CEP 59.625-900 – Mossoró - RN

{luizjunior05}@gmail.com,

{miltonmendes, luizclaudio}@ufersa.edu.br

***Abstract.** Technological developments led to important consequences for the processes of teaching and learning. This evolution has promoted the emergence of new approaches to distance learning, such as mobile learning. By facilitating access to diverse educational content, this learning modality provides content often inappropriate to the context of the student. One way to minimize this problem is by using computational techniques to support context-aware mobile learning. Therefore, this paper presents an environment able to perform context-sensitive recommendation of learning objects, defined in a standard format, through the use of ontologies, a multi-agent system and the application of a Genetic Algorithm.*

***Resumo.** A evolução tecnológica ocasionou consequências relevantes para os processos de ensino e aprendizagem. Essa evolução promoveu o surgimento de novas abordagens para o ensino não presencial, sendo uma delas a aprendizagem móvel. Por facilitar o acesso a diversos conteúdos educacionais, essa modalidade de ensino frequentemente fornece conteúdo inadequado ao contexto do estudante. Uma forma de minimizar esse problema é a utilização de técnicas computacionais para suporte à aprendizagem móvel sensível ao contexto do estudante. Portanto, este artigo apresenta um ambiente capaz de realizar a recomendação sensível ao contexto de objetos de aprendizagem, definidos em um formato padrão, através do uso de ontologias, de um sistema multiagente e da aplicação de um Algoritmo Genético.*

## 1. Introdução

Os avanços das tecnologias móveis e de comunicação sem fio contribuíram para demarcar um novo horizonte aos processos de ensino e aprendizagem já estabelecidos. Os dispositivos móveis possibilitam o acesso a ambientes virtuais de ensino e

aprendizagem, caracterizando, assim, a aprendizagem móvel, do inglês *Mobile Learning* ou *m-learning* [Saccollet et al. 2010].

Este meio de oferecer ensino permite que estudantes e professores possam tirar vantagens dos recursos oferecidos pelas tecnologias móveis, dentre os quais destaca-se a possibilidade de acessar, visualizar e prover conteúdo independentemente do horário e a partir de qualquer localidade [Yau & Joy 2010]. Entretanto, as tecnologias móveis promovem o acesso a uma ampla quantidade e diversidade de conteúdos educacionais, o que pode acarretar em perda de desempenho dos estudantes, por provocar a dispersão destes. Para lidar com essa situação, ao fornecer conteúdo educacional, deve-se levar em consideração as características particulares de cada estudante, como também as restrições dos seus dispositivos móveis, uma vez que os mesmos possuem recursos distintos e limitados. Surge então o conceito de ambientes sensíveis ao contexto (*context-aware environments*). Esse tipo de ambiente se adéqua ao perfil do usuário, levando em consideração informações fornecidas pelo próprio usuário, além daquelas captadas dinamicamente a partir de sua interação com os dispositivos computacionais [Moore et al. 2009].

A fim de desenvolver ambientes de aprendizagem que sejam sensíveis ao contexto do estudante, é fundamental que os conteúdos educacionais sejam criados de maneira padronizada. Desta forma, é possível que um ambiente de suporte à aprendizagem exiba o conteúdo de forma adequada e reutilize conteúdos em diferentes contextos e a partir de diversos repositórios. Além disso, é possível combinar conteúdos distintos, o que, por sua vez, melhora o processo de produção de conteúdo e, como consequência, reduz os seus custos [Rodolpho 2009]. Um modo eficaz de padronizar conteúdos educacionais é através do uso de Objetos de Aprendizagem (OAs), os quais consistem em pequenas unidades de conteúdo que podem ser usadas, reutilizadas e referenciadas durante um processo de aprendizagem [LTSC 2002].

Este artigo apresenta um ambiente de aprendizagem móvel que, através do uso de OAs, ontologias, agentes de software e aplicação de um Algoritmo Genético (AG) [Linden 2008] se adéqua às necessidades dos estudantes, fornecendo conteúdos educacionais (OAs) adequados às características do contexto no qual os mesmos se encontram.

Este artigo está dividido em oito seções. A Seção 2 mostra uma visão geral dos agentes de software. A Seção 3 apresenta a técnica dos Algoritmos Genéticos (AG). A Seção 4 traz conceitos relacionados a ambientes sensíveis ao contexto. A Seção 5 discute os trabalhos relacionados. A Seção 6 descreve a abordagem baseada em AG para recomendação sensível ao contexto proposta neste artigo. A última seção apresenta nossas considerações finais e uma discussão sobre trabalhos futuros.

## 2. Agentes de Software

De acordo com Russell & Norvig (2003), agentes são entidades de software autônomas que percebem seu ambiente por meio de sensores e que atuam sobre esse ambiente através de atuadores, processando informação e conhecimento. Um Sistema Multiagente (SMA), por sua vez, consiste de um conjunto de agentes autônomos que colaboram para resolver um problema o qual seria impossível solucionar com apenas um agente.

Agentes de software podem realizar diversas tarefas em ambientes de aprendizagem, tais como monitorar as atividades do estudante, capturar dinamicamente

informações do estudante, recomendar conteúdos de interesse deste, dentre outras atividades. Diante do aumento no número de estudantes que interagem com os sistemas de suporte à aprendizagem, o uso de agentes para realizar estas tarefas torna-se extremamente importante, principalmente devido ao fato de serem tarefas complexas para os facilitadores gerenciarem a distância.

### 3. Algoritmos Genéticos

Os AGs constituem um ramo dos algoritmos evolucionários e, portanto, também podem ser definidos como uma metáfora do processo biológico de evolução natural [Linden 2008]. De uma forma sucinta, os AGs tentam resolver problemas para os quais não existe um algoritmo conhecido, gerando-se uma população inicial e, de acordo com critérios de avaliação, selecionando os melhores indivíduos dessa população, que servirão como solução para o problema ou, caso contrário, serão combinados para obter uma nova geração. Esse processo é repetido até que se encontre uma solução ou até que se perceba que não serão alcançadas melhores soluções nas novas gerações [Artero 2009].

Os AGs, assim como os demais tipos de algoritmos evolucionários, não podem garantir que uma geração será melhor do que a sua geração antecessora, mesmo sendo pouco provável não ocorrer tal situação. Isso acontece devido ao fato desses algoritmos serem baseados na evolução natural que, por sua vez, não consiste em um processo dirigido à obtenção da solução ótima. De fato, o processo simplesmente consiste em fazer competir um conjunto de indivíduos, fazendo com que sobrevivam aqueles indivíduos que são mais aptos [Linden 2008; Petroli Neto 2011].

### 4. Ambientes Sensíveis ao Contexto

Sensibilidade ao contexto descreve um paradigma no qual o contexto de um usuário é levado em consideração para definir o seu perfil. Não existe um consenso a respeito da definição de “contexto”, sendo este específico da aplicação e da intenção desejadas, requerendo a identificação das funções e propriedades dos domínios dos indivíduos [Moore et al. 2009; Moore et al. 2008].

O contexto pode ser definido de acordo com informações relativas a propriedades que se combinam para descrever e caracterizar uma entidade e seu papel de uma forma legível pelo computador [Moore et al. 2009; Moore et al. 2008]. A localização do estudante, por exemplo, é uma característica importante para a definição do seu contexto em um ambiente para aprendizagem móvel. Entretanto, o contexto inclui mais do que apenas a localização. De fato, quase todas as informações disponíveis no momento da interação podem ser vistas como informações contextuais, dentre as quais destacam-se [Moore et al. 2009; Schilit et al. 1994]: i) as diversas tarefas exigidas dos usuários; ii) a variada gama de dispositivos que se combinam para criar sistemas móveis, com a infraestrutura de serviços associada; iii) disponibilidade de recursos (ex. condição da bateria, tamanho de tela, etc.); iv) situação física (ex. nível de ruído, temperatura, nível de luminosidade etc.); v) informação espacial (ex. localização, velocidade, orientação etc.); e vii) informação temporal (ex. hora do dia, data etc.).

Esta lista, embora não contenha exatamente todas as informações que podem ser consideradas, serve para demonstrar a complexidade inerente ao contexto, sua natureza de domínio específico e a dificuldade em defini-lo e medi-lo [Moore et al. 2009]. Na

tentativa de facilitar a compreensão sobre o contexto, Moore et al. (2008) definem dois tipos gerais de contexto: estático (denominado *customização*) e dinâmico (denominado *personalização*). O primeiro diz respeito à situação na qual um perfil de usuário é criado manualmente, estando o usuário ativamente envolvido no processo e tendo um elemento de controle. Já o contexto dinâmico refere-se à situação na qual o usuário é visto como sendo passivo, ou pelo menos com um pouco menos de controle no processo de criação de seu perfil. Nesse caso, o sistema monitora, analisa e reage dinamicamente ao comportamento do usuário e ao perfil identificado.

Algumas aplicações de aprendizagem móvel sensíveis ao contexto utilizam contextos de aprendizagem a fim de adaptar ou sugerir apropriadamente atividades e conteúdos [Yau & Joy 2010]. Entretanto, os trabalhos encontrados na literatura não levam em consideração os recursos físicos dos dispositivos móveis, o que compromete uma definição mais precisa do contexto dos estudantes e, conseqüentemente, o acesso e navegação adequados nos conteúdos recomendados, uma vez que isto é diretamente influenciado pelas características dos dispositivos móveis utilizados pelos estudantes.

## 5. Trabalhos relacionados

A utilização de sistemas de recomendação em ambientes educacionais não é nenhuma novidade. Em Primo et al. (2010) é apresentado um modelo para a recomendação de conteúdos educacionais descritos através de metadados. Esse modelo considera perfis de usuários e interoperabilidade entre aplicações educacionais, além de aspectos cognitivos de aprendizado. Esse trabalho também apresenta como conteúdos educacionais podem ser descritos através de ontologias, o que facilita também a inferência dos conteúdos apropriados aos perfis dos usuários.

Em Gluz & Vicari (2010) é apresentada a MILOS (*Multiagent Infrastructure for Learning Object Support*), uma infraestrutura, combinando ontologias e agentes, que implementa as funcionalidades necessárias aos processos de autoria, gerência, busca e disponibilização de OAs compatíveis com a proposta de padrão de metadados de OAs OBAA (Objetos de Aprendizagem Baseados em Agentes).

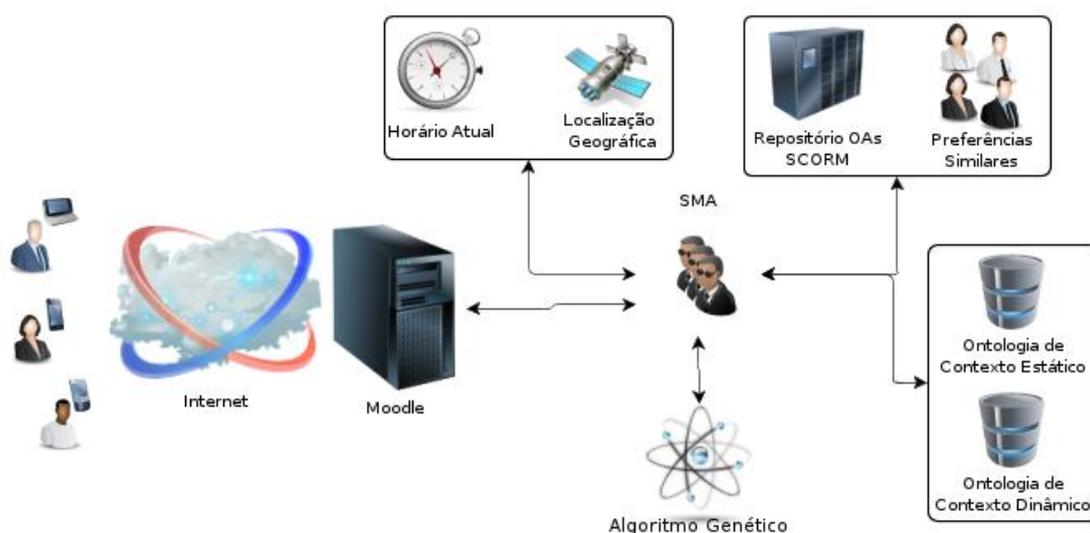
Yau & Joy (2010) propõem uma arquitetura de aprendizagem móvel sensível ao contexto composta por três componentes principais: o perfil do estudante, um mecanismo de personalização e um repositório de OAs. O perfil do estudante serve para armazenar suas preferências de aprendizagem móvel, capturadas através de um questionário respondido pelo estudante. O mecanismo de personalização recebe esse perfil e combina as informações dele com aquelas obtidas dinamicamente através de sua interação com o ambiente. Em seguida, o mecanismo de personalização compara todas as informações obtidas com os metadados dos OAs disponíveis no repositório. O sistema então recomenda OAs adequados aos estudantes de acordo com as características do seu contexto.

O presente trabalho reúne as principais características dos trabalhos citados anteriormente. Porém, o fator que difere o presente trabalho dos demais é o fato dele utilizar AG para recomendar OAs adequados às diversas características do contexto do estudante, inclusive os recursos dos dispositivos móveis, os quais podem constituir um fator limitante na aprendizagem do estudante no momento da recomendação dos OAs. Pelo fato de ser projetado para dispositivos móveis, o ambiente provê ao estudante flexibilidade quanto às opções de estudo. Utilizando agentes de software em

combinação com as ontologias de descrição dos perfis (estático e dinâmico) dos estudantes e o AG, o ambiente recomenda, de maneira autônoma, conteúdos educacionais adequados às características pessoais e cognitivas dos estudantes.

## 6. Abordagem Baseada em Algoritmo Genético para Recomendação de Objetos de Aprendizagem Sensível ao Contexto do Estudante

A arquitetura do ambiente proposto é apresentada na Figura 1. Como pode ser visto na figura, os estudantes devem, inicialmente, se autenticar no LMS e acessar algum dos cursos nos quais esteja matriculado. Para isto, eles precisam realizar um cadastro no qual irão informar algumas características de seu perfil, como, por exemplo, local e hora do dia preferidos para o estudo, sua área de interesse, entre outras. Essas informações servirão para a instanciação de um componente essencial da arquitetura, que é a ontologia de contexto estático dos estudantes.



**Figura 1. Arquitetura da solução proposta.**

Os agentes descritos nesta abordagem foram desenvolvidos utilizando o JADE (*Java Agent Development Framework*), que consiste em uma plataforma completa para desenvolvimento e execução de SMA [JADE 2012]. Também foi utilizado o framework de desenvolvimento de aplicações MLE (*Mobile Learning Engine*) [MLE 2012] para a construção do ambiente.

Outro componente de extrema relevância é o repositório de OAs. Para que o mecanismo de recomendação funcione, é necessário que estes OAs estejam em conformidade com o padrão SCORM. Através dos metadados descritos nesse padrão, o agente será capaz de comparar as informações dos OAs com os perfis dos estudantes e realizar a recomendação de OAs de maneira adequada.

A organização do SMA é do tipo comunidade de especialistas, pois cada um dos quatro tipos de agentes criados para este trabalho encontra-se no mesmo nível, sendo cada um deles especialista em determinada tarefa. Os agentes interagem entre si através de um protocolo de comunicação previamente estabelecido. Para o desenvolvimento dos agentes, foram utilizadas as bibliotecas do JADE e os mesmos executam sob esta plataforma.

## 6.1 Agentes de Software

Como é possível perceber na Figura 1, o SMA é composto de quatro tipos de agentes: Agente Estudante (*Student Agent - SAg*), Agente Recomendador (*Recommender Agent - RAg*), Agente de Interface (*Interface Agent - IAg*) e Agente DF (*Directory Facilitator*).

O agente DF possui o comportamento voltado para a mediação da comunicação entre os outros agentes. Sua função principal é fornecer uma arquitetura do tipo “quadro-negro”, onde agentes escrevem informações, procuram por informações escritas por outros agentes e conseguem, através do serviço provido pelo DF, se comunicar com o agente que escreveu aquela informação.

Os SAGs são responsáveis por monitorar as atividades dos estudantes, atualizar e recuperar, das ontologias de contexto estático e dinâmico, as preferências de aprendizagem que compõem os perfis dos estudantes e seus respectivos históricos de escolhas de OAs. Os SAGs também capturam as informações de localização geográfica e do horário corrente. Ou seja, o comportamento do SAg é voltado para monitoramento das informações relativas ao estudante. Em seguida, todas essas informações são cadastradas no agente DF.

O RAg tem o intuito de detectar OAs adequados ao contexto do estudante, levando em consideração (i) as informações consultadas no agente DF, (ii) as informações dos OAs disponíveis no repositório de OAs SCORM e (iii) as preferências similares de outros estudantes. Após aplicar o AG para identificar os OAs adequados, o RAg cadastra, no agente DF, as novas informações, as quais servirão ao IAg.

O IAg é responsável, principalmente, por verificar a adequação visual do OA recomendado pelo RAg às características do dispositivo móvel do estudante. Caso o OA não seja adequado ao dispositivo, o IAg rejeitará a recomendação. Além disso, o IAg tem a responsabilidade de informar ao professor o conteúdo que foi sugerido.

### 6.1.1 Recomendação Sensível ao Contexto

A identificação dos OAs que serão recomendados é realizada pelo RAg, através da aplicação de um AG. A utilização do AG é justificada pela alta complexidade do problema de recomendação, o que pode denegrir o desempenho do SMA quando o número de OAs for suficientemente grande. Neste caso, um algoritmo aproximativo (AG) viabiliza a busca por uma solução próxima da ótima.

Para realizar uma recomendação de OAs adequada ao contexto do estudante, é essencial levar em consideração características que podem limitar a aprendizagem do mesmo.

Na modelagem do problema no AG, inicialmente, temos uma população composta de certa quantidade de OAs. Cada OA possui uma série de características que o relaciona com o contexto do estudante. No presente trabalho, foram consideradas as características detalhadas a seguir:

i) Afinidade com o curso: representa o grau de relacionamento do conteúdo de um OA a determinado curso. Esse grau de afinidade é representado no AG em uma escala que varia de 0 (nenhuma afinidade) a 5 (alta afinidade). Determinado OA pode estar relacionado a um ou vários cursos, sendo o administrador de cada curso

responsável por determinar, manualmente, quais OAs são afins ao curso e qual o seu grau de afinidade.

ii) Afinidade com o dispositivo móvel: determina o grau de adequação do conteúdo de um OA ao dispositivo móvel do estudante. O grau de afinidade com o dispositivo é definido no AG de acordo com uma faixa que varia de 0 (nenhum recurso suportado) a 5 (todos os recursos suportados). As informações do dispositivo são capturadas a partir da requisição HTTP enviada do dispositivo móvel para o servidor no qual se encontra o LMS. Em seguida, em posse dessas informações, é possível verificar em uma base de dados, chamada WURFL [WURFL 2012], quais recursos aquele dispositivo móvel suporta.

iii) Horário de estudo: os horários de estudo são definidos em faixas de horários. O estudante define, inicialmente, qual o horário de estudo preferido dele. Assim, quando o estudante acessa o ambiente de aprendizagem, o sistema se encarrega de verificar se o horário corrente está incluso na faixa de estudo preferida do estudante. Caso esteja nessa faixa, o sistema atribui o maior valor possível a essa variável no AG (valor 5). Do contrário, será atribuído um valor cada vez menor, sendo o mínimo 1, à medida que o horário corrente se distancie daquele definido como preferido pelo estudante.

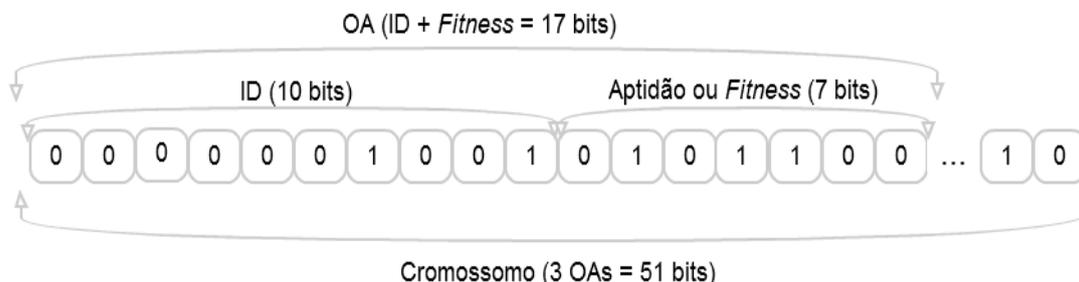
iv) Localização corrente: outra informação que pode ser levada em consideração para a definição do contexto do estudante é a localidade na qual ele se encontra. Em posse dessa informação, é possível verificar, nos metadados do padrão de OAs LOM (*Learning Object Metadata*) [LTSC 2002], a incidência de palavras relacionadas à localização do estudante. Com base nisso, são capturadas e consideradas informações do país, estado e cidade na qual o estudante se encontra. Quanto mais palavras relacionadas à localização do estudante forem encontradas, maior será o valor atribuído a essa variável no AG (máximo 5). Por outro lado, caso não seja encontrada nenhuma informação relacionada, será atribuída a pontuação mínima (valor 0).

v) Escolhas de outros estudantes: define um valor proporcional que representa a quantidade de acessos de um OA. A informação de quais OAs são mais acessados é levada em consideração em conjunto com a informação de afinidade do OA com o curso, pois de nada adiantaria para a recomendação um OA ser o mais acessado e não possuir nenhuma afinidade com o curso em questão. Desta forma, esse valor pode variar de 0 a 5 dependendo da quantidade de acessos e da sua relação com o curso.

vi) Incidência de palavras-chave: os OAs disponibilizados no padrão SCORM possuem metadados que informam as palavras-chave relacionadas ao assunto daquele OA (*tag keywords*), além do título deste. Essas informações estão localizadas, mais especificamente, no padrão LOM, o qual é parte integrante do padrão SCORM. Em posse dessas informações, é feita uma verificação da incidência dessas palavras na descrição do curso do qual o estudante está participando. Quanto maior a quantidade de palavras-chave relacionadas, a probabilidade de que o OA possua assuntos relacionados ao curso será maior, sendo pontuado, portanto, com um peso maior (no máximo 5). Por outro lado, quanto menor a quantidade de palavras-chave relacionadas, o peso atribuído ao OA nessa variável no AG torna-se proporcionalmente menor.

### 6.1.2 Codificação do Algoritmo Genético

No AG cada cromossomo é formado por um conjunto de três OAs. A representação do OA (gene) é formada pelo ID e sua respectiva aptidão. O cálculo da aptidão do OA é o somatório dos valores atribuídos a cada característica citada anteriormente. Desta forma, cada cromossomo (ou indivíduo da população) é composto conforme o exemplo de cromossomo mostrado na Figura 2.



**Figura 2. Representação cromossomial utilizada.**

A população é composta de cromossomos que possuem, cada um, cinquenta e um bits em representação binária (0 ou 1). Cada OA é representado por dezessete bits, sendo dez utilizados para a sua identificação (ID) e sete para a representação do resultado de sua aptidão, considerando os aspectos descritos anteriormente. Assim, com cada OA utilizando dezessete bits, e com uma representação de cromossomo de cinquenta e um bits, é possível representar até três OAs por cromossomo ( $17 \times 3 = 51$  bits).

Com o ID do OA sendo representado por dez bits, é possível endereçar todo um repositório contendo até mil e vinte e quatro OAs ( $2^{10} = 1024$ ). Isso permite que o repositório de OAs possa crescer sem causar problemas no AG. A aptidão de cada OA, por sua vez, é representada por sete bits, podendo resultar em um valor de até cento e vinte e oito na representação decimal ( $2^7 = 128$ ). Quando da execução do AG, é considerada como aptidão do cromossomo a soma das aptidões dos três OAs do cromossomo. Ou seja, para efeito da escolha do indivíduo com maior possibilidade de reprodução (maior aptidão), é considerada a aptidão do cromossomo como um todo.

Essa abordagem de um cromossomo contendo três OAs foi utilizada porque, no final da execução do AG, será indicado um cromossomo como o indivíduo mais apto, ou seja, como a melhor solução levando-se em consideração o contexto em questão. Portanto, não seria interessante, recomendar apenas um OA, mas sim um conjunto dentre o qual o estudante pudesse escolher aquele que lhe fosse mais conveniente.

## 7. Considerações Finais e Trabalhos Futuros

Um dos desafios do ensino não presencial é a adequação do conteúdo ao estudante de acordo com as características cognitivas deste. No ensino presencial, esta já é uma tarefa difícil de ser realizada, visto que é necessário que o professor possua certo conhecimento das necessidades de cada um dos alunos. Tal tarefa torna-se ainda mais complexa quando o ensino é realizado a distância, visto que muitos ambientes virtuais de aprendizagem enfocam, geralmente, aspectos relacionados à sua funcionalidade, esquecendo assim a função pedagógica do ambiente.

Outro fator que deve ser levado em consideração é que, nem sempre, os recursos tecnológicos utilizados para o ensino permitem realizar o ensino de forma simples e completa, sendo necessárias algumas adaptações, como é o caso da aprendizagem móvel, a qual pode apresentar limitações de acordo com as características do dispositivo móvel do estudante.

Pensando nisso, o presente trabalho apresentou uma abordagem que, através da aplicação de um AG, realiza a recomendação de conteúdos educacionais (OAs) que sejam adequados às características do contexto do estudante. Para tanto, a abordagem leva em consideração uma série de características, conforme mostrado ao longo deste trabalho. O intuito desta abordagem é aperfeiçoar o processo de ensino-aprendizagem de forma transparente aos estudantes, provocando assim um maior interesse no estudo por parte destes.

Apesar do trabalho realizado até o momento, há algumas melhorias que podem ser realizadas. Assim, como trabalho futuro, pretende-se:

i) Testar o ambiente desenvolvido em um contexto real, utilizando os principais repositórios de conteúdos educacionais (OAs). Isso possibilitará mensurar, estatisticamente, o quanto este mecanismo de recomendação contribui para o processo de ensino-aprendizagem;

ii) Disponibilizar a infraestrutura do ambiente, denominado MobiLE, como um componente do Moodle sob uma licença GPL, de forma a facilitar a instalação e utilização do ambiente por instituições que utilizem esse LMS e desejem disponibilizá-lo através de dispositivos móveis;

iii) Testar o ambiente desenvolvido em áreas específicas (ex. área médica, petrolífera, etc.) para verificar a adequabilidade da recomendação de OAs em contextos específicos;

iv) Aperfeiçoar a visualização da recomendação, visto que no momento a recomendação é feita de forma textual, informando o nome do OA;

v) Levar em consideração outras características do dispositivo móvel do estudante antes de decidir se um OA é adequado ao contexto do estudante, aperfeiçoando, conseqüentemente, o mecanismo de recomendação;

## Referências

- ADL (2012) “Advanced distributed learning”, <http://www.adlnet.org>, Abril.
- Artero, A. O. (2009) “Inteligência Artificial - Teoria e Prática”. 1ª. ed. São Paulo: Livraria da Física.
- Dias, C. C. L., Kemczinski, A., and Lucena, S. V. d. S. (2009) “Padrões abertos: aplicabilidade em Objetos de Aprendizagem (OAs)”, In Anais do XX Simpósio Brasileiro de Informática na Educação, SBIE, Florianópolis, SC.
- Gluz, J.C., Vicari, R. M. (2010) “MILOS: Infraestrutura de Agentes para Suporte a Objetos de Aprendizagem OBAA”, In Anais do XXI Simpósio Brasileiro de Informática na Educação, SBIE, João Pessoa, PB.
- JADE (2012) “Java development framework: an open-source platform for peer-to-peer agent based applications”. Disponível em: <http://jade.tilab.com/>.

- Linden, R. (2008) “Algoritmos Genéticos - Uma importante ferramenta da Inteligência Computacional”. 2ª. ed. Rio de Janeiro, RJ: Brasport.
- LTSC (2002) “Draft Standard for Learning Object Metadata. IEEE Standard 1484.12.1”.LTSC, Learning Technology Standards Committee, New York: Institute of Electrical and Electronics Engineers.
- MLE (2012) “MLE- Mobile Learning Engine”, <http://mle.sourceforge.net/mle/index.php>, Abril.
- Moore, P., Hu, B., Jackson, M., Wan, J. (2009) “Intelligent context for personalized m-learning”, In International Conference on Complex, Intelligent and Software Intensive Systems, 2009.CISIS '09, p. 247 –254.
- Moore, P., Hu, B., Wan, J. (2008) “A Context Ontology for Pervasive Mobile Computing”, The Computer Journal, Vol. 53, p. 191-207.
- Petroli Neto, S. (2011) “Computação Evolutiva: desvendando os algoritmos genéticos. Ubiquidade”, Revista de Estudos de Tecnologia da Informação e Comunicações, v. 1, n. 1, p. 34-45.
- Primo, T. T., Vicari, R. M, Silva, J. M. C. da (2010) “Rumo ao Uso de Metadados Educacionais em Sistemas de Recomendação”, In Anais do XXI Simpósio Brasileiro de Informática na Educação, SBIE, João Pessoa, PB.
- Rodolpho, E. R. (2009) “Convergência digital de objetos de aprendizagem SCORM”, Dissertação de Mestrado, Universidade Estadual Paulista Júlio de Mesquita Filho - UNESP, São José do Rio Preto, SP.
- Russell, R. &Norvig, P. (2003) “Artificial Intelligence, A Modern Approach 2nd Edition”, Prentice Hall.
- Saccol, A., Schlemmer, E., Barbosa, J. (2010) “m-learning e u-learning - Novas perspectivas da aprendizagem móvel e ubíqua”. São Paulo, SP: Pearson.
- Schilit, B., Adams, N., Want, R. (1994) “Context-Aware Computing Applications”, In: IEEE Workshop on Mobile Computing Systems and Applications (WMCSA), p. 85-90, IEEE Computer Society, Santa Cruz.
- Yau, J.-K.& Joy, M. (2010) “A context-aware personalized m-learning application based on m-learning preferences”, In 6th IEEE International Conference on Wireless, Mobile and Ubiquitous Technologies in Education (WMUTE), p. 11 –18.
- WURFL (2012) “WURFL - Wireless Universal Resource FiLe”,<http://wurfl.sourceforge.net/>, Abril.