

# Seleção de Avaliações Adaptativas em Sistemas Gerenciadores de Aprendizagem Utilizando Mineração de Dados

Edson P. Pimentel, Arthur S. Alves, Bruno Willer R. Oliveira, Danilo M. Ikebara, Patrícia A. Bottaro, Renato Lopes

Departamento de Computação – Universidade IMES, São Caetano do Sul, São Paulo, Brasil.

## Resumo

A avaliação da aprendizagem é um dos aspectos mais relevantes e controversos no ensino presencial e esta dificuldade parece ter se transferido para os Sistemas Gerenciadores de Aprendizagem. Na grande maioria desses ambientes todos os estudantes são avaliados de maneira uniforme independente do seu nível de aquisição de conhecimentos e dos conteúdos abordados. O insucesso recorrente nessas avaliações pode ser desestimulante para o aprendiz e torna o processo de avaliação ineficaz uma vez que os resultados não são utilizados para realimentar o próprio processo de avaliação. Este artigo tem por objetivo apresentar um modelo para a seleção de avaliações adaptativas num ambiente computacional de aprendizagem utilizando técnicas de mineração de dados com base no nível de aquisição de conhecimentos do estudante em cada item do domínio em questão e também nos conteúdos abordados nas unidades de Avaliação.

*Palavras chaves:* Avaliações Adaptativas, Mineração de Dados, Avaliação Formativa.

## 1. Introdução

O processo de ensino-aprendizagem envolve três atores principais: estudante, professor e conteúdo. Integrando esses atores estão os métodos utilizados e as diferentes tecnologias que propiciam que o processo se complete. O mecanismo de aferição do processo nas mais diferentes etapas é a avaliação podendo ser diagnóstica somativa ou formativa [2].

Diversas pesquisas têm indicado os efeitos positivos da avaliação formativa, descrita como avaliação “para” a aprendizagem [10]. Um dos princípios mais

importantes da avaliação formativa é o uso dos resultados na realimentação do processo de ensino e aprendizagem.

No sistema tradicional de ensino e também na grande maioria dos Sistemas Gerenciadores de Aprendizagem todos os estudantes são avaliados de maneira uniforme independente do seu nível de aquisição de conhecimentos e dos conteúdos abordados. O insucesso recorrente nessas avaliações pode ser desestimulante para o aprendiz e torna o processo de avaliação ineficaz uma vez que os resultados não são utilizados para realimentar o próprio processo de avaliação.

O ramo da inteligência artificial na área da computação dispõe de diversas técnicas que permitem o desenvolvimento de Sistemas Gerenciadores de Aprendizagem dinâmicos e adaptativos.

Sistemas Adaptativos devem ser capazes de se adequar ao aprendiz, no que diz respeito ao seu histórico e o seu desempenho [13]. Num contexto de avaliação formativa seria possível, por exemplo, exibir avaliações adaptadas ao perfil cognitivo do estudante, de tal modo que este aprendiz seria avaliado formativamente de acordo com os seus conhecimentos e suas lacunas de aprendizagem.

Este artigo tem por objetivo apresentar um modelo para a seleção de avaliações adaptativas num ambiente computacional de aprendizagem utilizando técnicas de mineração de dados com base no nível de aquisição de conhecimentos do estudante em cada item do domínio em questão e também nos conteúdos abordados nas unidades de Avaliação. A seleção de unidades de avaliação adequadas ao perfil atual do estudante criará condições para avaliações personalizadas de modo a proteger ou desafiar o aprendiz nos seus sucessos ou insucessos.

Este artigo tem por objetivo apresentar um modelo para a seleção de avaliações adaptativas num ambiente computacional de aprendizagem utilizando técnicas de mineração de dados com base no nível de aquisição de conhecimentos do estudante em cada item do domínio em questão e também nos conteúdos abordados nas unidades de Avaliação. A seleção de unidades de avaliação adequadas ao perfil atual do estudante criará condições para avaliações personalizadas de modo a proteger ou desafiar o aprendiz nos seus sucessos ou insucessos.

A seguir, a disposição das seções do artigo: a seção 2 apresenta uma revisão sobre conceitos de avaliação da aprendizagem, os problemas envolvidos na avaliação e a evolução do conhecimento medido através delas; a seção 3 descreve o ambiente NETEDU e suas ferramentas; a seção 4 apresenta a técnica de adaptatividade que será utilizada neste trabalho e suas funcionalidades através do algoritmo K-means; a seção 5 apresenta um modelo para realizar a adaptação das avaliações e a seção 6 apresenta a conclusão feita com base nos testes efetuados na seção 6.

## 2. Avaliações

Segundo CHINEN[1], é a avaliação que determina a “evolução” do aluno. No entanto, avaliação pode ter diferentes finalidades: ela pode ser utilizada para certificar o estudante, ou para fins de progressão no curso ou para acompanhamento da aprendizagem. Dessa forma, é importante que os objetivos da avaliação sejam bem definidos.

### 2.1 Classificações de Avaliação

A avaliação pode ser classificada, brevemente, em:

- Diagnóstica: ocorre durante o processo de aprendizado e consegue identificar os pontos fortes e fracos do aluno em referência ao conteúdo passado.
- Formativa: segundo PERRENOUD[2], ajuda o aluno a aprender a se desenvolver. A cada objetivo finalizado, indica ao professor e ao aluno o que foi realmente aprendido, evitando acúmulos de problemas, segundo PIMENTEL[3].
- Somativa: através de provas subjetivas, objetivas e classificatórias, são atribuídas notas e um feedback aos alunos quanto ao que foi aprendido ou não.

### 2.2. Propósitos de Avaliação

A avaliação, em sua totalidade, é um meio de mensurar ganhos. Mas o que fazer com essa informação, tem alguma funcionalidade?

Segundo SOMONSON [4], a resposta é sim. De fato, a adição de muitos usos que podem direta ou indiretamente influenciar o ambiente de aprendizado ou ajudar a formular políticas, existe muitas maneiras na qual a avaliação pode também melhorar o aprendizado. No ambiente de educação à distância, resultados de avaliações podem, algumas vezes, ser usados para comparar o desempenho acadêmica dos estudantes remotos com a performance daqueles que estão no local de origem da aula. Mas, para o estudante, a idéia de Avaliação é obter uma nota pelo seu desempenho, ao final do curso, ou mesmo ao final do conteúdo exibido pelo professor. No entanto, as notas provêm uma informação limitada, mesmo que elas sejam úteis para determinar o quanto pode ser melhorado a instrução de futuros estudantes, ou mesmo, do aluno avaliado.

O melhor propósito mais influenciável para avaliação do ganho de aprendizado por parte dos aprendizes é prover o feedback. Com isso os aprendizes ganham senso de controle e responsabilidade sobre o seu aprendizado.

### 2.3. Problemas da Avaliação

As avaliações que conhecemos hoje e que desde tempos remotos são aplicadas aos aprendizes da forma para todos. Não há particularidades. Os aprendizes são tratados do mesmo modo, ignorando as suas reais necessidades e seus conhecimentos.

Esse problema da Avaliação seria resolvido se o professor desse um acompanhamento individualizado aos aprendizes, tanto em questões instrucionais, quanto nas avaliações. Mas, e como realizar isso quando a turma de aprendizes é consideravelmente grande?

Um outro ponto muito importante na aprendizagem dos aprendizes é saber o que ele já sabia antes da instrução/aula dada pelo professor, e o que ele “acha” que sabe. Dois pontos extremamente importantes para o bom andamento do processo de aprendizagem, e que nas Avaliações de hoje, pouco ou nada têm sido utilizadas.

### 2.4 Métricas da Avaliação

As métricas de acompanhamento da aprendizagem são normalmente baseadas em notas obtidas a partir de um somatório de várias questões. Além disso, utiliza-se médias aritméticas ou ponderadas para se definir a situação final do estudante. Este trabalho utilizará como métrica cognitiva o Nível de Aquisição de Conhecimentos (NAC) proposto por Pimentel [3].

NAC é uma medida instantânea que indica o grau de conhecimentos do aprendiz num determinado

conteúdo de um domínio de conhecimento e pode ser obtido a partir de diversas atividades de avaliação. O NAC é composto de duas partes: índice de conhecimento e índice de avaliação. Índice de conhecimento igual a zero e índice de avaliação igual a zero, indica que o conhecimento ainda não foi avaliado.

Em cada avaliação deve-se atualizar o NAC nos conceitos envolvidos naquela avaliação. Têm-se, portanto a medida de desempenho naquela avaliação e também a medida histórica.

## 2.5. Avaliações Adaptativas

A solução proposta por este artigo para a resolução dos problemas na avaliação dos dias atuais são as Avaliações Adaptativas. Segundo BRUSILOVSKI [15]- [16]-[17], a adaptatividade tem por objetivo adaptar o conteúdo de um nó de informação do domínio da aplicação ao nível decorrente de conhecimento e outras características do usuário.

As avaliações adaptativas que serão implementadas por meio das técnicas de adaptatividade, terão como objetivo dirigir determinadas questões da Avaliação para um determinado aprendiz, baseando-se pelo seu perfil.

Para resolver o problema da quantidade de alunos que se aplicaria a avaliação, FRANÇA [5] propõe que sejam formados grupos homogêneos compostos por alunos que possuam, mais ou menos, as mesmas lacunas de aprendizagem. No entanto, as questões adaptadas serão direcionadas ao Grupo de aprendizes e não mais ao aprendiz.

Para CURA [18], a base para a elaboração da avaliação adaptativa é o histórico de desempenho do aluno, que ficará armazenado e atualizado a cada avaliação aplicada. E a partir desse histórico, será possível, após as avaliações, gerar gráficos e estatísticas de desempenho dos conteúdos da avaliação e ter uma idéia melhor do acompanhamento da Disciplina por parte dos aprendizes.

## 3. O Ambiente NetEdu

O ambiente onde se fez a incorporação do mecanismo de adaptação proposto neste trabalho foi o NetEdu que é um ambiente de avaliação formativa em que professor e aluno podem interagir para acompanhar o progresso do estudante. A figura 1 apresenta a arquitetura geral do NetEdu com as suas principais funcionalidades.

Segundo CHINEN[1], o objetivo do ambiente é utilizar de sua arquitetura para criar condições de avaliar com mais frequência a evolução do conhecimento do aprendiz. Além disso, o ambiente possui uma avaliação metacognitiva, onde o aprendiz irá refletir sobre os seus próprios conhecimentos.

Basicamente o professor cria unidades de avaliação (UA) associando a elas os conceitos avaliados e o peso de cada conceito naquela UA. O estudante, por sua vez, responde a estas questões e como resultado o NAC do estudante é atualizado em cada conceito avaliado naquela UA.

## 3.1. Avaliação no NetEdu

O ambiente, após a realização da primeira avaliação do aprendiz, gera as métricas metacognitivas KMA e KMB, e a métrica cognitiva NAC. Essas métricas ficarão “guardadas” no histórico do aprendiz, podendo, futuramente, criar gráficos de desempenho por conteúdo da disciplina (por aluno ou por avaliação).

Dando um destaque especial ao NAC (Nível de Aquisição de conhecimento), PIMENTEL [3] define como uma medida que indica o grau de conhecimentos do aprendiz em um determinado conteúdo, de um domínio de conhecimento, naquele instante.

Por meio do conhecimento dessas métricas, o professor é capaz de criar e direcionar as avaliações aos alunos, de acordo com o nível de conhecimento e as lacunas de aprendizado dos alunos, classificando os alunos em níveis. Porém, esse direcionamento é realizado de forma O ambiente, após a realização da primeira avaliação do aprendiz, gera as métricas metacognitivas KMA e KMB, e a métrica cognitiva NAC. Essas métricas ficarão “guardadas” no histórico do aprendiz, podendo, futuramente, criar gráficos de desempenho por conteúdo da disciplina (por aluno ou por avaliação).

Dando um destaque especial ao NAC (Nível de Aquisição de conhecimento), PIMENTEL [3] define como uma medida que indica o grau de conhecimentos do aprendiz em um determinado conteúdo, de um domínio de conhecimento, naquele instante.

Por meio do conhecimento dessas métricas, o professor é capaz de criar e direcionar as avaliações aos alunos, de acordo com o nível de conhecimento e as lacunas de aprendizado dos alunos, classificando os alunos em níveis. Porém, esse direcionamento é realizado de forma manual: o professor cria a avaliação para aquele determinado aluno (ou alunos), de acordo com o nível atual.

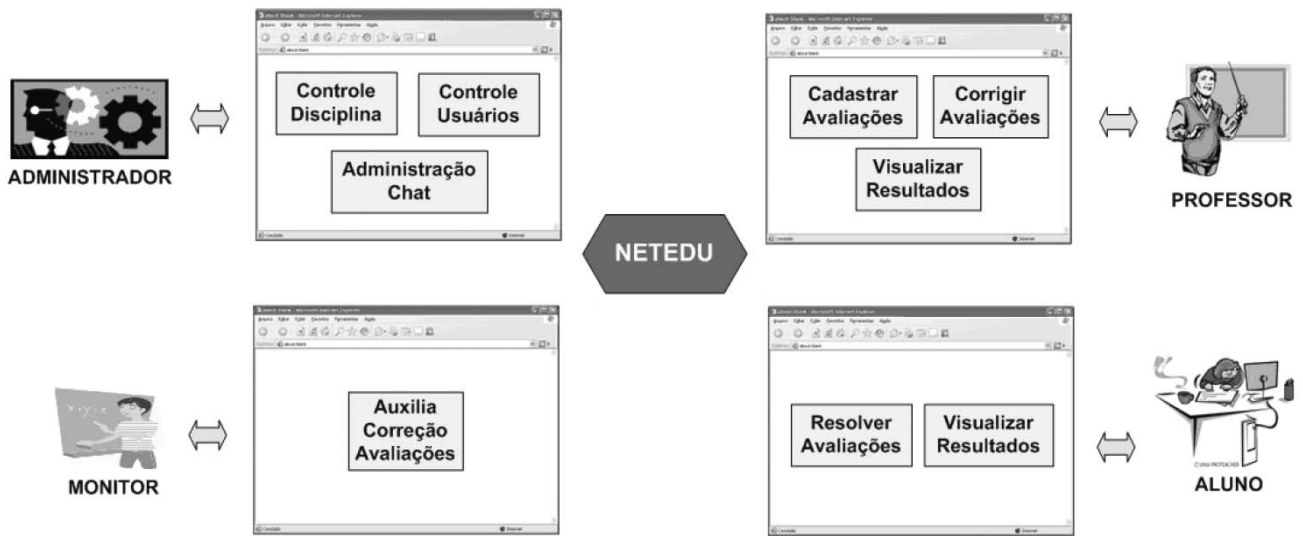


Figura 1. Principais funcionalidades do NETEDU

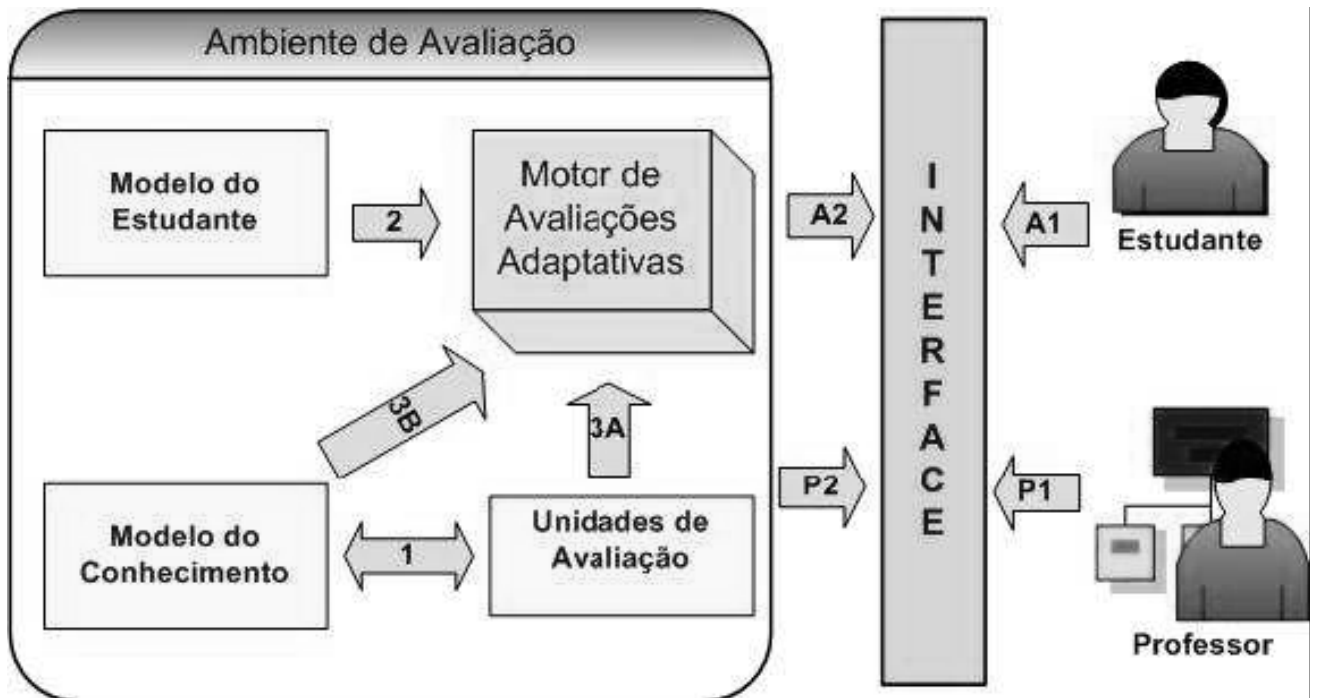


Figura 2. Modelo Geral de Avaliações Adaptativas no NetEdu.

### 3.2. Classificação de aprendizes no NetEdu

Os aprendizes e as UA's (Unidades de Avaliação) no NETEDU possuem cinco níveis: Iniciante, Básico, Intermediário, Avançado e Experiente.

Segundo CHINEN [1]:

*“Para conseguir a promoção de nível, é necessário obter sucesso em dois critérios pré-definidos pelo professor. O primeiro critério é a obtenção de uma “medida mínima” nos conteúdos da disciplina, configurada pelo professor. O segundo é a quantidade mínima de UA's respondidas relacionadas ao conteúdo da disciplina. Ao obter sucesso nos dois critérios, o ambiente vai automaticamente promover o aluno de nível, adaptando-o a um novo conjunto de avaliações, de acordo com o seu NAC, KMA e KMB.”*

O primeiro critério faz referência ao que PIMENTEL [3] descreve como índice de conhecimento do NAC e o segundo critério refere-se ao índice de avaliação do NAC. Portanto, sendo o NAC sua principal métrica de avaliação, ela será usada como entrada de dados para as seguintes técnicas de inteligência artificial (agrupamento de dados): o K-Means e a A-Priori.

Estas técnicas retornarão como resultado grupos de aprendizes que tenham conhecimentos semelhantes ou lacunas de aprendizado em comum.

## 4. Modelo para Adaptação das Avaliações

Um dos problemas em Avaliações Adaptativas é se encontrar a melhor técnica para se adaptar as questões

em um grupo de aprendizes com níveis de conhecimentos diferentes. Essas técnicas se baseiam em algoritmos que geram alguma saída que em muitos casos é de difícil compreensão.

Propõe-se neste trabalho o uso do algoritmo K-means que consegue num primeiro momento classificar os alunos em grupos homogêneos. A partir desses grupos utiliza-se outros procedimentos para selecionar as avaliações adaptadas ao perfil do grupo.

A figura 2 apresenta um modelo geral de avaliações adaptativas no NetEdu. As Unidades de Avaliação conectadas ao Modelo do Conhecimento (1) e as informações do modelo do estudante (2) alimentam o Motor de Avaliações Adaptativas (3A e 3B) para gerar avaliações adaptadas ao perfil do estudante.

### 4.1. Algoritmo K-Means

O algoritmo K-means é considerado como um algoritmo de mineração de dados não supervisionado,

serve para classificar ou agrupar seus objetos baseados em atributos/características no número de K agrupamentos. Segundo ZUCHINI [8] o k-means recebe como entrada um número K de agrupamentos e atribui aleatoriamente um objeto como sendo o centróide inicial de cada agrupamento. Sucessivamente, cada objeto é associado ao agrupamento mais próximo e o centróide de cada agrupamento é então recalculado levando-se em conta o novo conjunto de objetos a ele pertencentes.

O agrupamento é feito minimizando a soma dos quadrados das distâncias entre dados e o centróide correspondente do conjunto. Assim a finalidade do KMeans é classificar os dados. Abaixo apresentamos o funcionamento do algoritmo:

1. Escolha K distintos valores para centros dos grupos (A escolha pode ser aleatória)
2. Associar cada ponto ao centro mais próximo
3. Recalcular o centro de cada grupo
4. Repetir os passos 2 – 3 até não haver alterações.

Alguns problemas apontados por BARANAUSKAS [7], em relação ao algoritmo do k-means são:

- Os clusters finais não representam uma otimização global mas apenas local e clusters diferentes podem surgir a partir da diferença na escolha inicial aleatória dos centroides
- O parâmetro K deve ser escolhido antecipadamente ou vários valores devem ser tentados até encontrar o “melhor”
- Os dados devem ser numéricos e devem ser comparados através da distância Euclideana (há uma variante chamada algoritmo K-medians que aborda esse problema)
- O algoritmo trabalha melhor com dados que contêm clusters esféricos; clusters com outra geometria podem não ser encontrados.
- O algoritmo é sensível a outliers (pontos que não pertencem a nenhum cluster). Esses pontos podem distorcer a posição do centróide e deteriorar o cluster.

A figura 3 apresenta o fluxo geral para a adaptação das Unidades de Avaliação ao perfil do estudante. A seguir o detalhamento do modelo de adaptação proposto e implementado.

O primeiro passo no processo de seleção de UAs adaptadas é o agrupamento dos estudantes, a partir do NAC em cada conceito, utilizando o K-means.

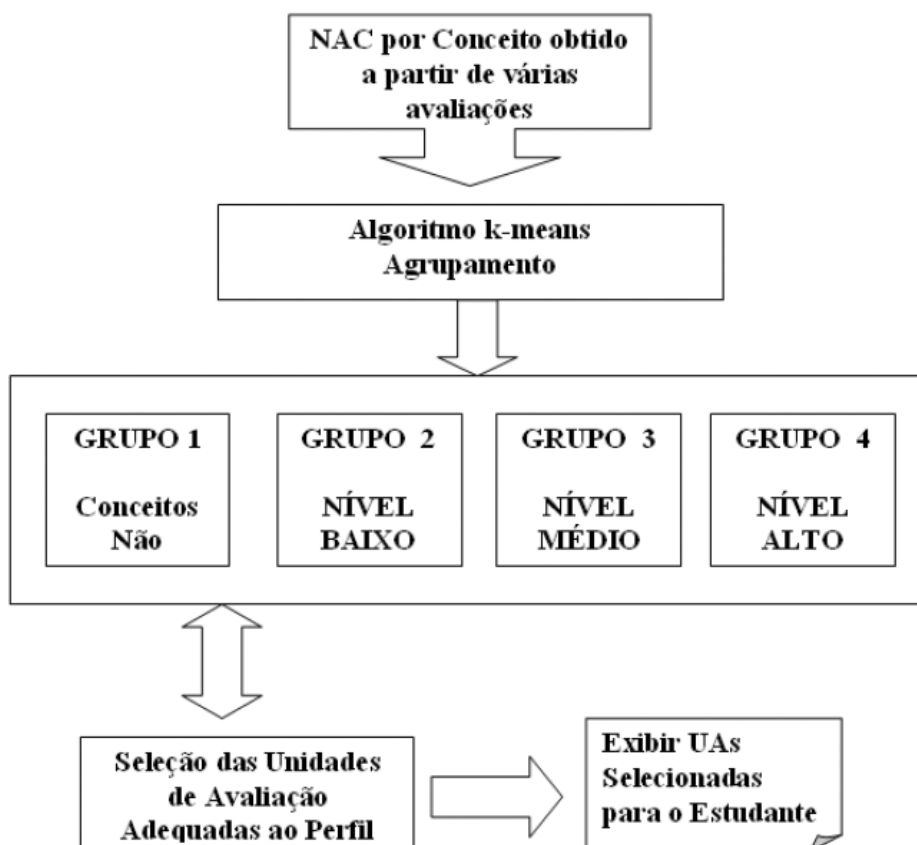


Figura 3 – Fluxo Geral para Adaptação das Unidades de Avaliação.

## 4.2 Agrupamento por Nível de Aquisição de Conhecimentos

A Tabela 1 apresenta um exemplo de entrada para o KMeans. A primeira coluna identifica o estudante, a segunda coluna o conceito e a terceira coluna o NAC do estudante no respectivo conceito.

ALUNO	CONCEITO	NAC
101	A	5
101	B	3
101	C	6
201	A	3
201	B	8
201	C	7

A Tabela 2 apresenta um exemplo de saída do K-means (primeira coluna) com base na entrada especificada na Tabela 1. O algoritmo categorizou as linhas da Tabela 1 nas classes 1, 2 e 3.

Tabela 2. Exemplo de saída de dados do K-Means

CLASSE	ALUNO	CONTEÚDO	NAC
1	101	C	2
1	101	B	4
2	201	A	5
2	101	A	6
3	201	B	7
3	201	C	8

Para especificar qual das 3 classes é a classe baixa, média ou alta, calcula-se a média dos valores (NAC) na classe. Por exemplo, a classe 1 tem média 3 obtida pela somatória do NAC dividida pela quantidade de linhas da classe:  $(2+4)/2$ . A classe 2 tem média 5.5 e a classe 3 tem média 6.5. Basta então estabelecer um critério (regra de intervalo) para definir a categoria das classes.

O ambiente tomará por base as classes geradas para exibir as unidades de avaliação adequadas ao perfil do estudante conforme descrito a seguir.

### 4.3. Seleção das Unidades de Avaliação Adequadas ao Perfil

Com base na hierarquia de conceitos e espaços de conhecimento apresentados na seção 2 e nos grupos obtidos com o K-means as unidades de avaliação adequadas ao perfil do estudante serão selecionadas obedecendo aos seguintes passos:

a) O estudante deverá indicar em qual dos grupos pretende ser avaliado. Por exemplo, se desejar melhorar o seu NAC poderá escolher conceitos que estejam no grupo “baixo” ou “médio”. Se desejar reforçar conceitos em que já possui nível bom desempenho selecionará o grupo “alto”;

b) Se o objetivo do estudante for melhorar o seu NAC, o sistema selecionará dentro do grupo escolhido conceitos folhas ou conceitos que tenham o menor número de conceitos dependentes. Por exemplo, no grafo da figura 3, o conceito “1” é um conceito folha e o conceito “17” possui três conceitos dependentes, etc.

c) Selecionado o conceito, o ambiente deverá localizar UAs cadastradas que abordem o conceito, ou de forma

isolada ou que o conceito possua um “peso forte”. Os conceitos possuem “peso forte” em avaliações em que ele tem alto grau de participação no resultado final (nota final) da avaliação. A figura 4 apresenta o fluxo geral para a seleção das UAs adaptadas ao perfil do estudante. A partir dos grupos formados pelo K-means, o objetivo da avaliação é definido:

- Reforçar – Seleciona-se UAs que contenham os tópicos atuais e anteriores na estrutura hierárquica de Conteúdos;
- Preservar – Seleciona-se UAs que contenham os tópicos atuais na estrutura de conteúdos;
- Desafiar - Seleciona-se UAs que contenham os tópicos posteriores na estrutura de conteúdos.;

Na escolha dos tópicos leva-se em conta também o NAC atual do aprendiz em cada conteúdo.

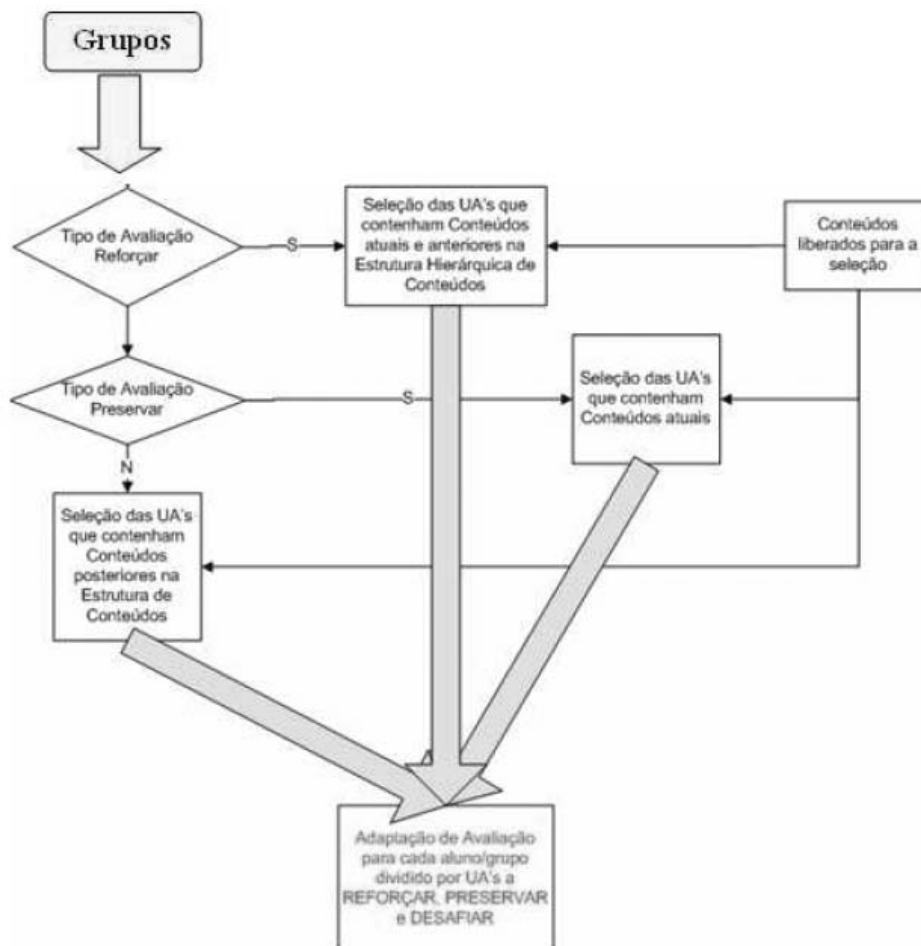


Figura 4. Fluxo Geral para Seleção das UAs Adaptadas

## 5. Conclusão

Utilizando o algoritmo K-means pode-se gerar agrupamentos de aprendizes de forma a selecionar a melhor UA para cada grupo.

Analisando o algoritmo K-means podemos concluir que para o seu objetivo de separar os aprendizes em número determinados de grupos, o algoritmo cumpre o seu objetivo.

Adaptar as avaliações ao perfil cognitivo de cada estudante é uma estratégia pedagógica que tem por finalidade preservar os estudantes de insucessos consecutivos além de ajudar a identificar os conteúdos em que o estudante possui lacunas de aprendizagem.

Este trabalho apresentou um modelo para a seleção de unidades de avaliação adaptadas ao atual nível de aquisição de conhecimentos do estudante. No modelo proposto o conhecimento foi organizado na forma de hierarquia de pré-requisitos utilizando-se a teoria dos espaços de conhecimento. Para reduzir o espaço de busca no ato da adaptação utilizou-se o algoritmo de agrupamento K-means para a geração prévia de agrupamentos.

O modelo foi incorporado ao ambiente de avaliação NetEdu. Como aprofundamentos necessários pretendese utilizar as métricas metacognitivas já existentes no NeTEdu no processo de seleção das avaliações adaptativas.

Como trabalhos futuros, pretende-se realizar estudos de casos reais para se verificar os efeitos das avaliações adaptativas como estratégia pedagógica.

## Referências

[1] CHINEN André Augusto Berti, SCHIRMER Felipe, CARRER Ricardo Nendre, SANTOS Rodrigo Henrique Costa dos Santos. Um ambiente para o Mapeamento do Conhecimento Cognitivo e Metacognitivo. Trabalho de Conclusão de Curso, Universidade IMES, 2006.

[2] PERRENOUD Philippe. Avaliação da excelência à regulação das aprendizagens – entre duas lógicas. Porto Alegre: Artmed, 1999.

[3] PIMENTEL Edson Pinheiro. Um modelo para Avaliação e Acompanhamento Contínuo do Nível de Aquisição de Conhecimento do Aprendiz. Trabalho de Tese. Instituto Tecnológico de Aeronáutica, 2006

[4] SOMONSON Michael, SMALDINO Sharon, ALBRIGH Michael, ZVACEK Susan. Teaching and Learning at a Distance. Foundations of Distance Education, 3ª Edição.

[5] FRANÇA Vilma F. de , PIMENTEL Edson Pinheiro, OMAR Nizam. A identificação de grupos de aprendizes no ensino presencial utilizando técnicas de clusterização. Artigo apresentado no XIV Simpósio Brasileiro de Informática na Educação, 2003.

[6] ZADROZNY, Bianca. Tópicos Avançados em Otimização e IA II Aprendizado Automático. Rio de Janeiro. Disponível em: [http://www.ic.uff.br/~bianca/topicos/index\\_arquivos/Aula9-AA.pdf](http://www.ic.uff.br/~bianca/topicos/index_arquivos/Aula9-AA.pdf). Acesso em: 08 jun. 2007.

[7] BARANAUSKAS José Augusto. Departamento de Física e Matemática – USP. Clustering. Disponível em: <http://yanomami.fmrp.usp.br/cbab/apres/05-05/Cluster.ppt>. Acesso em: 09 jun. 2007.

[8] ZUCHINI, Márcio Henrique. Aplicações de Mapas Auto-Organizáveis em Mineração de dados e Recuperação de Informação. Trabalho de Mestrado apresentado a Faculdade de Engenharia Elétrica e de Computação (FEEC - UNICAMP), Universidade de Campinas, 2003.

[9] LOCATELLI Mariana B., PIMENTEL Edson P., SILVEIRA Ismar Frango, OMAR Nizam. Modelagem de um Ambiente de Apoio ao Nível de Aquisição de Conhecimento Construído sob Ontologia.

[10] Broadfoot P. et al. (1999) Assessment for Learning: Beyond the Black Box. Assessment Reform Group University of Cambridge, School of Education, Cambridge.

[11] SOUZA FILHO, Hélcio Gomes de. Extração de Regras de Associação de um Banco de Dados Relacional. Tese – Universidade Federal do Rio de Janeiro, COPPE. Engenharia Civil – 2004

[12] CUNICO, Luiz H. B. Técnicas Em Data Mining Aplicadas Na Predição de Satisfação de Funcionários de Uma Rede de Lojas Do Comercio

Varejista. Tese de Mestrado do Curso de Pós-Graduação em Métodos Numéricos em Engenharia – Área de Concentração em Programação Matemática, Setores de Tecnologia e de Ciências Exatas. Universidade Federal do Paraná, 2005.

[13] PIMENTEL, Edson Pinheiro, FRANÇA, Vilma Fernandes de, OMAR, Nizam. A caminho de um ambiente de avaliação e acompanhamento contínuo da aprendizagem em Programação de Computadores. Instituto Tecnológico da Aeronáutica, Universidade Municipal de São Caetano, Universidade Presbiteriana Mackenzie.

[14] CHINEN, André, SCHIRMER, Felipe, CARRER, Ricardo, SANTOS, Rodrigo, LOPES, Vinicius, PIMENTEL, Edson. NetEdu – Um Ambiente Computacional para o Mapeamento do Conhecimento do Estudante, Universidade Municipal de São Caetano, 2006.

[15] BRUSILOVSKY, P. Methods and Techniques of Adaptive Hypermedia User Modeling and User Adapted Interaction, 1996.



[16] BRUSILOVSKY, P. Adaptative Educational Systems on the World-Wide-Web. A Review of Available Technologies. In: Fifth International Conference on Intelligent Tutoring System. ITS-98: San Antonio – Texas. 1998.

[17] BRUSILOVSKY, P. Adaptative Hypermedia. User Modeling and User Adapted Interaction. 2001.

[18] CURA Claudio, NUNES, Danilo, PINHEIRO, Edson, BONANO, Enio, MANDAJI, Ricardo, OMAR, Nizam. Uma Ferramenta Adaptativa de Avaliação da Aprendizagem Baseada no Perfil Cognitivo e Metacognitivo do Estudante – Universidade Municipal de São Caetano do Sul, Universidade Presbiteriana Mackenzie.

*Dirección de Contacto del Autores:*

Edson P. Pimentel  
Santo André, SP, Brasil  
edson.pimentel@imes.edu.br

Bruno Willer R. Oliveira  
Santo André, SP, Brasil  
bruno.willer@gmail.com

Arthur Sapata Alves  
São Caetano do Sul, SP, Brasil  
arthur.sapata@uol.com.br

Danilo M. Ikebara  
Santo André, SP, Brasil  
midanilo@gmail.com

Patricia A. Bottaro  
Santo André, SP, Brasil  
abpatricia2002@yahoo.com.br

Renato Lopes  
São Caetano do Sul, SP, Brasil  
renatolps@hotmail.com

---

**Edson Pinheiro Pimentel** é doutor em Engenharia da Computação pelo Instituto Tecnológico de Aeronáutica (ITA), Brasil. É professor e pesquisador da Universidade IMES e seus principais interesses são Informática na Educação e Inteligência Artificial

---



---

**Bruno Willer R. de Oliveira** é bacharel em Ciência da Computação pela Universidade Municipal de São Caetano, Brasil. É Gerente de Projetos na área de robótica e seus principais interesses são Inteligência Artificial e Informática na Educação.

---



---

**Arthur Sapata Alves** é bacharel em Ciência da Computação pela Universidade Municipal de São Caetano, Brasil. É Consultor de Tecnologia e seus principais interesses são Inteligência Artificial e Banco de Dados.

---



---

**Danilo M. Ikebara** é bacharel em Ciência da Computação pela Universidade Municipal de São Caetano, Brasil. É Analista Programador e seus principais interesses são Inteligência Artificial e Banco de Dados.

---



---

**Renato Lopes** é bacharel em Ciência da Computação pela Universidade Municipal de São Caetano, Brasil. É Analista Programador e seus principais interesses são Banco de Dados e Engenharia de Software.

---



---

**Patrícia Alavarce Bottaro** é bacharel em Ciência da Computação pela Universidade Municipal de São Caetano, Brasil. É Analista Programador e seus principais interesses são Banco de Dados e Engenharia de Software.

---