

Uma Ferramenta de Monitoramento Automático de Mensagens de Fóruns em Ambientes Virtuais de Aprendizagem

Roberto L. de Oliveira Júnior¹, Ahmed A. A. Esmim¹,
Tiago A. Coelho¹, Deivison L. Araújo¹, Leandro Alonso Silva¹, Rafaela Giroto¹

¹Departamento de Ciência da Computação
Universidade Federal de Lavras (UFLA)
Lavras, MG - Brasil

{robertojr, deivison, alonso}@comp.ufla.br

{ahmed, tiagocoelho, }@dcc.ufla.br

ragiroto@gmail.com

Abstract. *E-learning mediated through Learning Management System, forums are an important instrument and widely used in the articulation of discussions and debates. The extensive use of forums many messages are shared and the sometimes exceeds the capacity of monitoring by teachers and tutors. This paper presents the design of a forum's message classifier that classifies messages into positive or negative, in order to clearly display the messages that need more attention. This paper applies the concepts of text mining, with the SVM algorithm and achieved satisfactory success rates.*

Resumo. *Em Educação a Distância mediada por meio de Ambientes Virtuais de Aprendizagem, fóruns de discussão são um instrumento importante e amplamente utilizado na articulação de debates e discussões entre os atores envolvidos no processo de ensino e aprendizagem. Com a ampla utilização dos fóruns muitas mensagens são trocadas e isso, por vezes, excede a capacidade de monitoramento por parte dos professores e tutores. O presente trabalho apresenta a concepção de um classificador de mensagens de fóruns que classifica as mensagens em positivas ou negativas, a fim de identificar mensagens que necessitam de maior atenção. Este trabalho aplica conceitos de mineração de textos, com o algoritmo SVM obtendo taxas de acerto satisfatórias.*

1. Introdução

Vivemos hoje no Brasil um momento muito especial no que diz respeito a Educação a Distância (EaD), pois muitas vagas e novos cursos estão sendo abertos nessa modalidade de ensino onde muito apoio está sendo dado para a sua expansão. Para dar subsídio ao seu desenvolvimento surge a necessidade de sistemas que auxiliem no processo de ensino/aprendizagem, como os Ambientes Virtuais de Aprendizagem (AVA). Este tipo de sistema contém recursos que tentam tornar o ensino a distância efetivo, como os fóruns de discussão, as enquetes, a possibilidade de realização de avaliações, entre outros.

Mesmo com estes recursos disponíveis nos AVAs, ainda há grandes dificuldades a serem enfrentadas. O pouco contato presencial dificulta, de certa forma, a avaliação do

professor quanto a compreensão ao nível de apresentação do conhecimento que o aluno está tendo. Na visão de [Moran et al. 2000] isso pode prejudicar o desempenho de um curso a distância. Neste sentido, uma ferramenta importante para o acompanhamento do aprendizado, do desenvolvimento e da satisfação dos alunos com o curso é o fórum de discussões, o que faz com que este recurso seja amplamente utilizado.

O fórum de discussões é um recurso que permite articular debates e discussões entre os atores envolvidos no processo de ensino/aprendizagem sobre temas relacionados ao curso. Podem também ser disponibilizados materiais de apoio aos alunos, para que estes complementem seus estudos, facilitando o processo de ensino/aprendizado. Outra importante característica do fórum é o fato de ser um ambiente assíncrono, ou seja, não é necessário que todos os participantes estejam *online* ao mesmo tempo para que a discussão aconteça, o que garante uma dinamicidade ao curso e ao mesmo tempo dificulta o controle e acompanhamento por parte de tutores e professores, que podem deixar passar mensagens importantes sem serem analisadas.

Um exemplo de como pode ser complexa a análise de fóruns de discussão temos um curso de pós graduação a distância da Universidade Federal de Lavras, que no segundo semestre de 2010 contava com 268 alunos, 56 disciplinas e uma quantidade de acessos que girava em torno de 44.995 a 137.378 ao mês, tendo ao todo 8.709 mensagens trocadas no fóruns.

Estes dados encorajam a aplicação de técnicas computacionais que permitam a extração de conhecimento implícito de forma mais rápida e menos penosa para um ser humano. Com isso a aplicação de técnicas de mineração de dados e classificação em ambiente AVA está despertando recente interesse acadêmico. No trabalho [Romero et al. 2008] é apresentada uma proposta geral de como as técnicas de mineração de dados podem ser aplicadas nos ambientes AVA Moodle [Moodle 2011], onde são expostas as possibilidades de aplicação de classificação, regras de associação entre outros. O trabalho [Lin et al. 2009] descreve uma proposta de sumarização de tópicos de fóruns de discussão utilizando mineração de textos. No trabalho [Azevedo et al. 2009] é mostrado um estudo de mineração de textos aplicado aos fóruns de discussão, com o objetivo de efetuar uma análise qualitativa da contribuição de cada mensagem enviada ao fórum.

Neste cenário, o presente trabalho apresenta uma aplicação real e descreve um classificador de fóruns, que faz uso de mineração de textos para classificar as mensagens de fóruns entre duas categorias: positivas e negativas. As mensagens negativas são aquelas cujos tutores e professores devem ter maior atenção, pois expressam dúvidas, conteúdo indevido, insatisfação entre outros assuntos.

O restante deste trabalho está organizado da seguinte forma: na seção 2 são apresentadas as características e etapas da Mineração de Textos; na seção 3 relatamos o processo de desenvolvimento, mostrando a metodologia e as ferramentas utilizadas; na seção 4 descrevemos a aplicação desenvolvida e suas características. As discussões e os resultados estão na seção 5 e na seção 6 a conclusão e propostas de trabalhos futuros serão apresentados.

2. Mineração de Textos

Mineração de textos pode ser considerada similar à mineração de dados, com a aplicação de algoritmos, métodos de aprendizagem de máquina e estatística sobre textos com o

objetivo de achar padrões úteis [Hotho et al. 2005]. Além disso, possui uma interseção com a área de busca de informação na Internet, assim como influências de áreas correlatas, como Processamento da Linguagem Natural (PLN), de Recuperação da Informação (RI), Inteligência Artificial (IA) e Ciência Cognitiva [Aranha and Vellasco 2007], podendo ser considerada uma área interdisciplinar.

Sendo a mineração de textos similar à mineração de dados, pode-se empregar o processo KDD (*Knowledge Discovery in Databases*) que é a extração não trivial de informação implícita, previamente desconhecida e potencialmente útil de dados, porém neste caso, como estamos lidando com textos o KDD passa a ser KDT (*Knowledge Discovery in Textual Databases*), que propõe algumas modificações em relação ao KDD. As etapas do KDT podem ser vistas na figura 1.

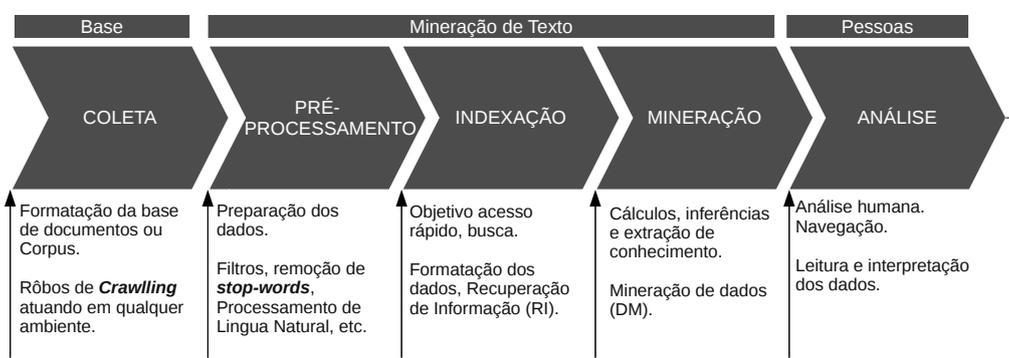


Figura 1. Etapas do KDT. Adaptado de [Aranha and Vellasco 2007]

A primeira etapa de coleta diz respeito a obtenção dos documentos de texto, o que pode ser a partir de diversas fontes como web sites, bancos de dados, arquivos textos, etc. A segunda fase, de pré-processamento, é considerada crucial para o sucesso do trabalho, pois é nela que serão retirados os ruídos e os dados serão transformados para que na fase de indexação possam ser devidamente representados de forma que o computador consiga utilizá-los. Após estas etapas, chega-se à mineração de textos propriamente dita e nela serão aplicadas as técnicas e algoritmos para extrair as informações contidas nos textos, seguindo a esta fase tem-se a análise, que cuida da validação dos resultados.

É importante frisar que em cada passo deste processo é possível voltar aos passos anteriores, de forma que sempre pode-se refinar os resultados de cada passo. Mais detalhes sobre as fases do KDT podem ser encontradas em [Aranha and Vellasco 2007].

3. Métodos e Ferramentas

3.1. Coleta e Pré processamento

Os dados utilizados na construção da aplicação foram obtidos de ambientes experimentais montados para a realização deste trabalho. Nestes ambientes foi feito um tratamento nos dados para que informações pessoais dos usuários não ficassem disponíveis. Para isto foi feita uma codificação de Nomes de pessoas para a marcação <NOME>, e-mail para <EMAIL> e assim por diante. Um ponto importante a se destacar é que estes ambientes utilizam como AVA o sistema Moodle, que armazena os dados em Bancos de Dados, o que torna a coleta dos dados mais simplificada.

Além da codificação de identificação de usuários foi realizado um pré processamento em todas as mensagens para a remoção de marcações HTML; esta etapa foi realizada utilizando um *script* em PHP.

Dando continuidade no processo de pré processamento, cada mensagem (documento) foi transformado para o Modelo de Espaço Vetorial, onde "documentos são representados como pontos em um espaço Euclidiano t-dimensional em que cada dimensão corresponde a um *token* do léxico"[Carrilho Junior and Passos 2009]. Nesta representação, cada palavra é representada pelo índice dessa palavra no dicionário computado para o conjunto de documentos em questão e o peso dela é calculado de acordo com o tf-idf (*term frequency - inverse documento frequency*). Para mais detalhes ver [Manning et al. 2008].

3.2. Modelo da base de dados

Para que a aplicação fique independente da base de dados do AVA foi criada uma estrutura de tabelas de banco de dados. O esquema destas tabelas pode ser observado na figura 2.



Figura 2. Modelo do banco de dados do classificador

Os fins de cada tabela são:

1. **se_forum_aclassificar**: armazenar as novas mensagens enviadas ao fórum;
2. **se_forum_classificadas**: armazenar as mensagens classificadas;
3. **se_forum_modelo**: armazenar o conjunto de mensagens que forma a base de treinamento do classificador;
4. **mdl_forum_posts**: tabela do Moodle que armazena todas as mensagens do fórum.

3.3. Algoritmo de aprendizagem

Dentre os vários algoritmos utilizados para classificação textual, os dois mais mencionados na literatura são *Support Vector Machine* (SVM) e *Naïve Bayes*. Outros algoritmos também mencionados são Redes Neurais Artificiais e Árvores de Decisão. Para o desenvolvimento deste trabalho foram escolhidos os algoritmos SVM e *Naïve Bayes* e testes foram realizados para que um deles fosse escolhido.

Os testes foram realizados utilizando a ferramenta Weka [Hall et al. 2009], em um conjunto de 140 mensagens separadas igualmente em duas classes (Positiva e Negativa) e previamente classificadas. Os algoritmos tiveram o seu desempenho avaliado pelas seguintes métricas: Precisão, *Recall*, *F-measure*, Porcentagem de Mensagens Classificadas Corretamente e Incorretamente, Estatística Kappa, Erro Absoluto Médio e Raiz do Erro Quadrático Médio.

Para a validação dos resultados dos experimentos foi utilizado *10-folds cross-validation*, executado 10 vezes. Foi utilizada a implementação padrão do Weka do *Naive Bayes* e a LibSVM, como implementação do SVM. A figura 3 apresenta os resultados obtidos dos testes feitos.

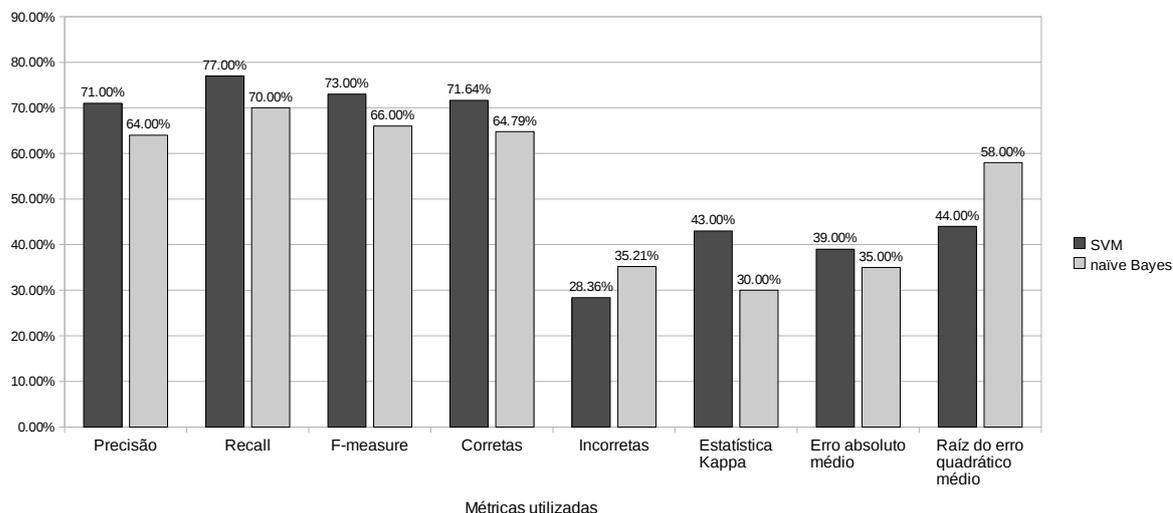


Figura 3. Comparação entre os algoritmos SVM x Naive Bayes

Ao analisar a figura 3 observa-se que o algoritmo SVM alcançou melhores resultados quando comparado com o algoritmo *Naive Bayes* nas métricas *Precisão*, *Recall* e *F-measure*, porém estes resultados foram muito próximos entre os dois algoritmos. Ao analisar a *Estatística Kappa* pode-se ver que o SVM obteve um grau de concordância superior ao do *Naive Bayes*. Nas outras métricas "Erro absoluto médio" e "Raiz do erro quadrático médio" o SVM também obteve melhores resultados em relação ao *Naive Bayes*. Estes resultados ofereceram subsídios para a escolha do algoritmo SVM.

3.4. Construção do modelo de classificação

Neste trabalho o "Classificador de Fóruns" possui um modelo padrão, que são termos, palavras e frases que foram coletados dos AVAs dos cursos de educação a distância da UFLA e classificados por um especialista. Decidiu-se pela criação deste modelo para que a aplicação pudesse ser instalada sob vários contextos e a medida que for utilizada possa se especializar através da inserção de novos termos em sua base de treinamento.

Este modelo padrão possui 91 itens, sendo 69 itens da classe negativa e 22 itens da classe positiva. Apesar do desbalanceamento entre as classes houveram taxas satisfatórias de acerto durante os testes. Outro ponto importante para este desbalanceamento é que o classificador é tendencioso à classificação de mensagens negativas, pois estas são aquelas que necessitam de maior atenção.

Os testes foram realizados com o Weka utilizando o método de pré processamento mostrado na seção 3.1 e os resultados podem ser vistos na tabela 1.

Observa-se que, de acordo com a Média de cada métrica, o classificador obteve resultados satisfatórios e, ao analisar as métricas por classe, observa-se que a capaci-

dade do algoritmo classificar uma instância da classe Positiva corretamente, definida pela métrica *Recall*, fica comprometida devido ao desbalanceamento entre as classes. Esta característica faz com que o classificador torne-se tendencioso à classificação para a classe Negativa, e isto é interessante pois mensagens desta classe necessitam de maior atenção.

Classe	Precisão	Recall	F-Measure
Positiva	60.0%	13.6%	22.2%
Negativa	77.9%	97.1%	86.5%
Média	73.6%	76.9%	70.9%

Tabela 1. Detalhes da acurácia do algoritmo SVM por classe e a média ponderada

Para fazer com que o "Classificador de Fóruns" se especialize em um determinado contexto, criou-se um módulo para re-induzir a máquina de aprendizado, em que o usuário do classificador poderá corrigir a classe de uma mensagem e inclui-la à sua base de treinamento. Após uma determinada quantidade de mensagens inseridas a aplicação realiza o treinamento do algoritmo que é avaliado pelo usuário.

3.5. Ferramentas

As ferramentas utilizadas no desenvolvimento deste trabalho foram o AVA Moodle que se destaca por ser um sistema de código aberto, de fácil instalação, manutenção e uso, sendo que estas características o fazem ser amplamente utilizado. Outra característica em que o Moodle se destaca são os fóruns que promovem um espaço virtual para as pessoas se encontrarem e debaterem as questões que são relacionadas aos cursos ou sobre outros assuntos [Lin et al. 2009].

Como fonte de implementação de algoritmos, métodos de pré processamento e de avaliação foi utilizado o Weka que, de acordo com [Hall et al. 2009], é uma coleção de algoritmos de aprendizagem de máquina para tarefas de mineração de dados, que pode ser aplicado diretamente sobre um conjunto de dados ou chamado via código Java sendo possível realizar classificação, regras de associação, regressão, pré-processamento e visualização.

Para analisar o impacto do uso do classificador de mensagens foi feita a integração com o software de gerenciamento de Giava que é um ambiente de gestão e acompanhamento de qualidade em AVA, que faz uso de conceitos de *Business Intelligence* (BI) e Mineração de Dados, construído como software livre [Esmin et al. 2010].

4. Aplicação desenvolvida

4.1. Arquitetura

A arquitetura interna do classificador pode ser vista na figura 4. O classificador possui duas operações básicas: classificar e re-induzir. A primeira irá classificar todas as mensagens que chegaram após a última classificação e a segunda irá recuperar as mensagens classificadas que foram marcadas para serem adicionadas ao conjunto de mensagens que gerará a base de treinamento.

O procedimento "classificar" consiste dos seguintes passos:

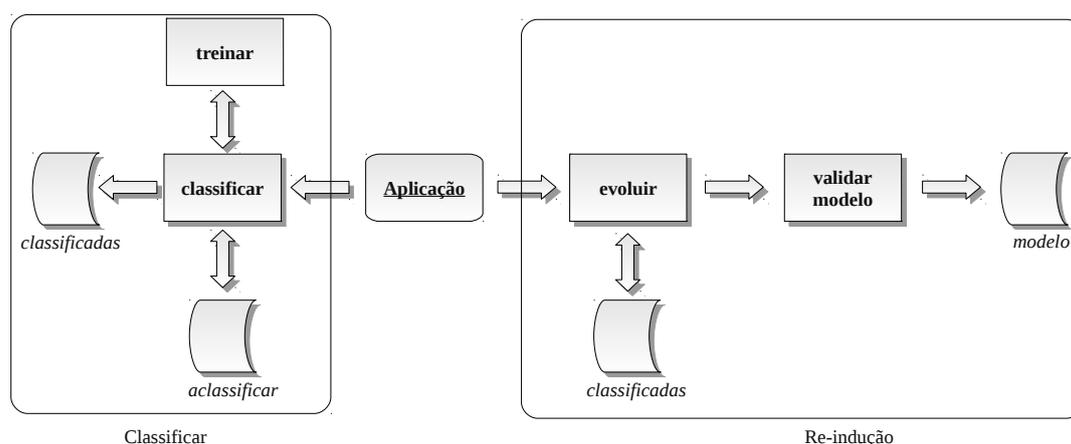


Figura 4. Arquitetura interna do classificador

1. q's mensagens a serem classificadas serão recuperadas da tabela **se_forum_aclassificar**;
2. o método de treinamento será invocado utilizando o conteúdo da tabela **se_forum_modelo** para gerar o modelo de classificação;
3. as novas mensagens serão classificadas e salvas na tabela **se_forum_classificadas**.

A operação "re-indução" possui o seguinte processamento:

1. as mensagens que estão na tabela **se_forum_classificadas** e foram marcadas para compor o modelo de classificação serão recuperadas;
2. o método validar-modelo será invocado, e neste o algoritmo será treinado com a junção das mensagens recém recuperadas e aquelas que já estavam presentes na tabela **se_forum_modelo**;
3. ainda no método validar-modelo, o algoritmo treinado será validado utilizando o método *10-fold cross-validation*;
4. com o resultado da validação o usuário poderá avaliar a re-indução da máquina de aprendizagem.

As ações de adicionar uma mensagem ao modelo e de confirmar a evolução do modelo são feitas em uma interface onde o classificador deve ser acoplado.

4.2. Integração do Classificador ao Giava

A integração do Classificador de Fóruns ao Giava foi feita como uma forma de expandir as formas de gerência e monitoramento de AVAs. A seguir será mostrado como se deu esta integração.

Quando uma nova mensagem chega ao fórum de discussões é disparada uma *trigger* que irá inserir esta nova mensagem na tabela **se_forum_aclassificar**. Utilizando o agendador de tarefas do sistema operacional o classificador será chamado com as suas duas operações uma vez por dia, para buscar as novas mensagens e para verificar se já é possível a re-indução da máquina de aprendizagem.

No Giava, há uma área de visualização das mensagens onde o usuário pode visualizar as mensagens classificadas, analisar o seu contexto, modificar a classificação da

mensagem e inclui-la no modelo. Também é possível acompanhar quando foi realizada a última classificação e evolução do modelo.

Em relação a re-indução, o usuário tem a opção de avaliar o novo modelo e efetivar ou não sua evolução. Ainda no Giava, as mensagens que estão presentes no modelo podem ser vistas e as que serão incluídas na próxima evolução podem ser vistas ou removidas deste conjunto.

Observe na figura 5 como é a visualização de mensagens provida pelo Giava.

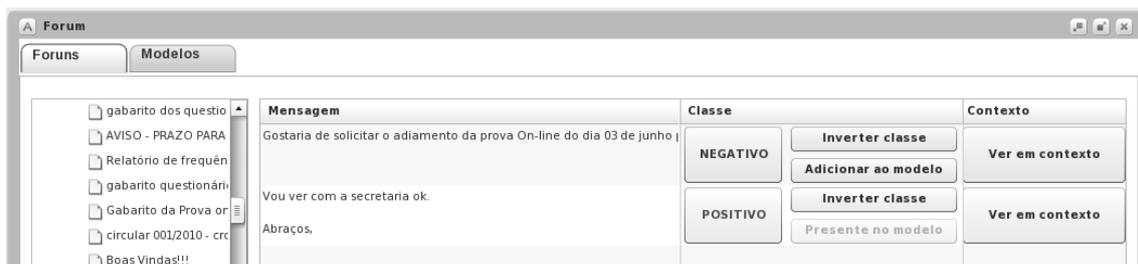


Figura 5. Visualizador de mensagens no Giava

4.3. Re-indução do modelo de classificação

Uma das ações que demandam mais trabalho durante um processo de classificação supervisionada, que é o caso deste classificador por usar o algoritmo SVM, é a construção de um bom modelo de classificação, uma vez que é necessária uma pessoa e/ou especialista para ajudar na construção deste.

Quando o classificador é instalado, o modelo padrão é utilizado nas primeiras classificações e o usuário poderá incluir novas mensagens a este modelo, corrigindo ou não a classificação delas.

Este processo irá especializar o modelo no assunto tratado em cada fórum como, por exemplo, se o fórum é de um curso de Administração de Redes, termos como *hacker*, *invadir* poderão ser colocados pertencendo à classe positiva, ao passo que se fosse um fórum de Engenharia de Software estes termos poderiam ser considerados como negativos.

A especialização do modelo de classificação poderá melhorar consideravelmente a qualidade do classificador, porém esta melhora será dependente da pessoa que irá incluir, utilizar e gerenciar o classificador.

5. Discussões e resultados

O classificador está em fase de testes monitorando cinco AVAs de cursos de educação a distância da UFLA e vem obtendo taxas de acerto média de 65% a 75%. Consideram-se estes resultados satisfatórios, pois conseguir separar bons conjuntos de mensagens para formar o modelo é um trabalho demorado e difícil. A solução achada para contornar este problema foi a criação do modelo de classificação padrão.

Alguns termos que compõem o modelo padrão estão na tabela 2 e, como pode-se observar, há termos que são dependentes do contexto e da interpretação de quem o está lendo, como "Apesar de um pouco cansativo, gostei", que ser for analisado tomando

por base o esforço no curso seria negativa, por outro lado, se analisada a satisfação seria positiva.

Para que esta questão fosse amenizada, a evolução do modelo foi implementada e com ela deseja-se especializar o modelo, melhorando as taxas de acerto. No entanto este procedimento é dependente do usuário do classificador, que deve estar atento para que boas mensagens e com a classificação correta sejam incluídas ao modelo.

Classe Positiva	Classe Negativa
Estou muito satisfeito	Falta de suporte de professores
Ótimo curso	Preciso de orientação
Apesar de um pouco cansativo, gostei	Falta de organização
Achei muito legal	Aguardo contato urgente

Tabela 2. Tabela com termos, palavras e frases que compõe o modelo padrão

A integração com o Giava possibilita fazer outras análises sobre os fóruns como, por exemplo, cruzar dados extraídos do classificador com os dados extraídos do AVA, para descobrir quais usuários estão enviando mais mensagens negativas, ou mensagens que tenham classificação positiva. Isto contribui para tomadas de decisão futuras, o que fortalece a ferramenta Giava e melhora o acompanhamento não só dos fóruns de discussão, mas do AVA como um todo.

6. Conclusão e trabalhos futuros

O presente trabalho teve como objetivo a construção de uma ferramenta que auxiliasse e facilitasse o trabalho de monitoramento dos fóruns de discussão em EaD, pelo fato de o número de mensagens trocadas pelos usuários exceder a capacidade de análise de tutores e professores, sobrecarregando o trabalho destes. Com isto, mensagens com conteúdos impróprios podem ser enviadas e não analisadas, ou analisadas tardiamente, gerando problemas.

Utilizando os conceitos de mineração de textos, estudos do algoritmo SVM e das tecnologias anteriormente citadas, o classificador foi desenvolvido e implantado junto a ferramenta Giava. Consideramos que o objetivo do trabalho foi alcançado, pois com a utilização do classificador sua taxa de acerto tende a aumentar indicando que a dificuldade de análise das mensagens trocadas em fóruns também tenda a diminuir.

Com as informações adquiridas por meio do classificador torna-se possível o cruzamento destes dados com os outros dados dentro do AVA, através da aplicação de regras de associação, utilizando a classes das mensagens, usuário, sumarização do tipo de tópico (tópico de dúvidas, notícias, exercícios, etc), extrair dados estatísticos, entre outras análises sobre os dados obtidos com o classificador. Assim, novas ferramentas para auxiliar o gerenciamento de cursos de EaD serão obtidas, possibilitando a melhoria da qualidade desta modalidade de ensino.

Agradecimentos

Este trabalho contou com o apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

Referências

- Aranha, C. N. and Vellasco, M. M. B. R. (2007). *Uma Abordagem de Pré-Processamento Automático para Mineração de Textos em Português: Sob o Enfoque da Inteligência Computacional*. PhD thesis, Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.
- Azevedo, B. F. T., Reategui, E., and Behar, P. A. (2009). Estudo de análise qualitativa em fórum de discussão. *Novas Tecnologias na Educação, CINTED-UFRGS*, 7.
- Carrilho Junior, J. R. and Passos, E. P. L. (2009). Desenvolvimento de uma metodologia para mineração de textos. Master's thesis, Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro.
- Esmín, A. A. A., Alonso, L. S., Éder Bruno Fonseca, Coelho, T. A., de Oliveira Júnior, R. L., and Girôto, R. (2010). Giava: Ambiente inteligente de acompanhamento e gestão de qualidades em avá. In *Encontro de Software Livre na Educação*.
- Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., and Witten, I. H. (2009). The WEKA data mining software: An update. *SIGKDD Explorations*, 11(1).
- Hotho, A., Nürnberger, A., and Paass, G. (2005). A brief survey of text mining. *Ldv Forum*, 20:19–62.
- Lin, F.-R., Hsieh, L.-S., and Chuang, F.-T. (2009). Discovering genres of online discussion threads via text mining. *Computers & Education*, 52:481–495.
- Manning, C. D., Raghavan, P., and Schütze, H. (2008). *Introduction to Information Retrieval*. Cambridge University Press, New York, NY, USA.
- Moodle (2011). Moodle documentation - disponível em <http://www.moodle.org>. acesso em: 07 de abril de 2011.
- Moran, J. M., Masetto, M. T., and Behrens, M. A. (2000). Mediação pedagógica e o uso da tecnologia. *Novas Tecnologias e Mediação Pedagógica*.
- Romero, C., Ventura, S., and García, E. (2008). Data mining in course management systems: Moodle case study and tutorial. *Computers & Education*, 51:368–384.