Utilizando Algoritmos de Aprendizado Semi-supervisionados Multi-visão como Rotuladores de Textos

Edson Takashi Matsubara[1] **, Maria Carolina Monard**[1] **, Gustavo E.A.P.A Batista**[2] *

[1]Laboratório de Inteligência Computacional
Instituto de Ciências Matemáticas e de Computação da Universidade de São Paulo
Av. do Trabalhador São-Carlense, 400 - Centro - Cx. Postal 668
São Carlos - São Paulo - Brasil CEP 13560-970

[2]Faculdade de Engenharia de Computação
Pontifícia Universidade Católica de Campinas
Rodovia Dom Pedro I, km 136 - Parque das Universidades
Campinas - São Paulo - Brasil CEP 13086-900

{edsontm, mcmonard, gbatista} at icmc.usp.br

Abstract. *The supervised learning approach to learn text classifiers usually requires a large number of labelled training examples. However, labelling is often manually performed, making this process costly and time-consuming. Multi-view semi-supervised learning algorithm have the potential of reducing the need of expensive labelled data whenever only a small set of labelled examples is available. In addition, these algorithms require a partitioned description of each example into distinct views. In this work we propose a method where these views can easily be obtained using simple and composed words from text data. Experimental results confirm the suitability of our proposal.*

Resumo. *O Aprendizado de Máquina supervisionado normalmente necessita de um número significativo de exemplos de treinamento para a indução de classificadores precisos. Entretanto, a rotulação de dados é freqüentemente realizada manualmente, o que torna esse processo demorado e caro. O aprendizado semi-supervisionado multi-visão tem o potencial de reduzir a necessidade de dados rotulados quando somente um pequeno conjunto de exemplos rotulados está disponível. No entanto, esses algoritmos necessitam de duas ou mais descrições de cada exemplo. Este trabalho propõem um método bastante simples de obter as visões necessárias para os algoritmos de aprendizado multi-visão utilizando palavras simples e compostas. Os resultados experimentais confirmam a adequabilidade desta proposta.*

1. INTRODUÇÃO

Boa parte do conhecimento existente está em formato texto. Desse modo é bastante evidente a necessidade da aquisição automática de conhecimento em textos. Entretanto, os textos são naturalmente não estruturados e a maioria dos algoritmos de aprendizado de máquina necessitam de exemplos em um formato estruturado. Transformar textos (formato não estruturado) em tabelas (formato estruturado) tem sido uma abordagem amplamente utilizada para possibilitar o uso da maioria dos algoritmos de que utilizam dados estruturados.

*Trabalho realizado com o auxílio financeiro da FAPESP e CAPES.

Entretanto, algoritmos de aprendizado supervisionado necessitam de uma quantia expressiva de dados rotulados para indução de um bom classificador. Na maioria das vezes, no mundo real, o número de exemplos rotulados é muito pequeno, quando inexistente. Desse modo, rotular dados tem sido um dos principais objetivos de uma área de pesquisa denominada Aprendizado de Máquina (AM) semi-supervisionado.

Boa parte dos algoritmos de aprendizado semi-supervisionado são multi-visão, ou seja, necessitam de duas ou mais descrições do conjunto de exemplos. Um exemplo pode ser descrito de diversas maneiras; por exemplo, um ser humano pode utilizar tanto a visão quanto o tato para identificar um objeto. No caso de Mineração de Textos (MT), um texto pode ser representado utilizando a freqüência de palavras simples ou de palavras compostas que ocorrerem no texto. Tanto a visão e o tato no caso de um ser humano, quanto as palavras simples e compostas no caso de um texto podem ser consideradas como duas descrições diferentes, as quais podem cooperar entre si para representar um exemplo (objeto e texto respectivamente). Desse modo, os algoritmos multi-visão são restritos a conjunto de dados que possuam essa característica.

A utilização de aprendizado semi-supervisionado pode ser de grande utilidade para a comunidade de mineração de textos, sobretudo para incrementar o número de exemplos rotulados em bases nas quais esses exemplos são escassos. Desse modo, os objetivos desse trabalho são apresentar o algoritmo semi-supervisionado CO-TRAINING como um processo rotulador de exemplos para auxiliar a tarefa de classificação de textos, mostrar um modo bastante simples de se obter conjuntos de dados multi-visão para coleções de textos e avaliar experimentalmente o algoritmo CO-TRAINING em um córpus em português utilizando duas e três classes.

Este trabalho está organizado da seguinte maneira: na Seção 2 são apresentados alguns dos principais trabalhos relacionados a esta pesquisa; na Seção 3 é proposta uma abordagem para obtenção de duas ou mais descrições dos dados de qualquer base de texto por meio de n-*gram*; na Seção 4 é descrito o algoritmo CO-TRAINING; na Seção 5 são descritos alguns detalhes do pré-processamento dos córpus utilizados nos experimentos; na Seção 6 são apresentados os resultados das análises experimentais realizadas para avaliar a eficiência da abordagem proposta; por fim, as conclusões são apresentadas na Seção 7.

2. TRABALHOS RELACIONADOS

Os algoritmos de aprendizado semi-supervisionado podem ser divididos em: visão única e visão múltipla (Muslea, 2002). Os algoritmos de visão única normalmente utilizam apenas um classificador e podem ser subdivididos em: transdutivos (Vapnik, 1998), variações de *Expectation Maximization* (EM) (Nigam and Ghani, 2000), algoritmos que utilizam conhecimento de fundo (Wagstaff et al., 2001) e algoritmos de *clustering* com o uso de "sementes" (Sanches, 2003). Os algoritmos de visão múltipla utilizam dois ou mais classificadores e normalmente são variações do algoritmo CO-TRAINING (Blum and Mitchell, 1998). CO-TRAINING fornece a primeira formalização de aprendizado multi-visão; ele requer que as duas visões sejam compatíveis, *i.e.*, todos os exemplos devem possuir o mesmo rótulo em cada visão, e as visão devem ser independentes, ou seja, deve ser possível realizar a indução de um classificador preciso sem depender da outra visão.

Diversos algoritmos multi-visão baseados na idéia de CO-TRAINING surgiram desde então. Goldman and Zhou (2000) propõem uma variação de CO-TRAINING que utiliza dois algoritmos indutores com *bias* diferentes para a construção das duas visões. Nigam et al. (2000), utilizando as idéias do EM e CO-TRAINING, propõem o CO-EM. Em Muslea (2002) é proposto o CO-TESTING, um algoritmo multi-visão interativo que permite ao usuário rotular os exemplos que possuem classificações distintas fornecidas por

cada visão. Ainda em Muslea et al. (2002) é proposto uma extensão do CO-TESTING, chamado CO-EMT, que surgiu da união de CO-EM e CO-TESTING. O algoritmo original de CO-TRAINING (Blum and Mitchell, 1998) utiliza *Naive Bayes* como algoritmo base. Em (Kiritchenko and Matwin, 2002; Kockelkorn et al., 2003) é apresentado uma versão de CO-TRAINING que utiliza *Support Vector Machines* (SVM) como algoritmo base. Nos resultados experimentais descritos nesses trabalhos, o CO-TRAINING com SVM supera o CO-TRAINING original (*Naive Bayes*). Brefeld and Scheffer (2004) propõem uma versão de CO-EM e *SVM* que, segundo os resultados experimentais apresentados, supera os resultados obtidos pelos outros algoritmos.

No entanto, no trabalho de Cozman et al. (2003) mostra por meio de uma análise matemática como o incremento de exemplos não rotulados, em alguns casos, pode aumentar o erro de classificação. Outros trabalhos mostram alguns poucos experimentos indicando que o uso de muitas classes pode prejudicar o desempenho de algoritmos semi-supervisionado. Em Ghani (2002) é feito uma análise comparando duas classes com multi-classe além de propor o uso de *Error-Correcting Output Coding* para melhoria do desempenho em problemas multi-classe.

O aprendizado multi-visão é amplamente utilizado em aplicações reais de Mineração de Texto. Classificação de páginas de internet (Blum and Mitchell, 1998), reconhecimento de entidades nominais (Collins and Singer, 1999), indução de *wrappers* (Muslea et al., 2002) e classificação de emails (Kiritchenko and Matwin, 2002) são alguns exemplos. Entretanto, ao observar essas aplicações de MT nota-se que a construção das duas visões é altamente dependente do domínio da aplicação. Em (Blum and Mitchell, 1998) é utilizado como primeira visão os textos contidos em páginas da internet, e como segunda visão os links de internet que apontam para essas páginas. Ao trocar de domínio de aplicação, como classificação de emails, não é possível utilizar a mesma visão utilizada em páginas da internet já que os emails não possuem links. Em (Kiritchenko and Matwin, 2001) que trata do problema de classificação de emails, é utilizado o cabeçalho do email como primeira visão e o corpo do email como segunda visão. Assim, a obtenção das visões diferentes do conjunto de exemplos pode ser realizada de diversas maneiras. Neste trabalho é proposto uma abordagem simples e genérica para a obtenção dessas duas visões, a qual pode ser utilizada sempre que os exemplos consistirem de documentos texto.

3. CONSTRUINDO DUAS DESCRIÇÕES

No Laboratório de Inteligência Computacional (LABIC[1]) foi desenvolvida a ferramenta computacional PRETEXT (Matsubara et al., 2003) que tem como objetivo realizar o pré-processamento de textos utilizando a abordagem *bag-of-words*. Nessa abordagem, cada documento é representado como um vetor das palavras que ocorrem no documento. PRETEXT permite a construção de n*-grams*, $n = 1, 2, ...$, no qual n refere-se a um termo composto por n palavras que ocorrem seqüencialmente no documento.

Neste trabalho é proposto utilizar, para cada descrição dos dados de um algoritmo multi-visão, os termos compostos por um determinado número de palavras, ou seja, cada descrição dos dados é composta por todos os n*-gram* (com n fixo) formados a partir do texto. Neste trabalho, é avaliado utilizar 1-*gram* para a primeira visão e 2-*gram* para a segunda visão. Entretanto, pode-se utilizar qualquer valor de n para cada uma das visões, desde que o valor de n seja distinto entre elas.

Um pouco mais formalmente, o conjunto de atributos $\mathbf{X}$ que descreve os exemplos

[1] `http://labic.icmc.usp.br.`

em dois subconjuntos $\mathbf{X}_{D_1}$ e $\mathbf{X}_{D_2}$, representam neste trabalho 1-*gram* e 2-*gram*, os quais constituem as duas descrições dos textos (exemplos) tal que $\mathbf{X} = \mathbf{X}_{D_1} \cup \mathbf{X}_{D_2}$ e $\mathbf{X}_{D_1} \cap \mathbf{X}_{D_2} = \emptyset$ como ilustra a Figura 1(a). Nessa figura, por simplicidade, é considerado que $\mathbf{X}_{D_1} = \{X_1, X_2, ..., X_j\}$ e $\mathbf{X}_{D_2} = \{X_{j+1}, X_{j+2}, ..., X_M\}$. Exemplos com valor de Y igual a "?" representam exemplos não rotulados.

Além da separação em duas descrições, o conjunto de exemplos $E = \{E_1, ..., E_N\}$ deve ser separado em dois subconjuntos L e U, também conhecidos como conjunto de exemplos rotulados (*Labeled*) e não-rotulados (*Unlabeled*), respectivamente. O subconjunto $L \subset E$ que contém exemplos que possuem o atributo classe conhecido é, por sua vez, dividido em duas descrições L_{D_1} e L_{D_2}, tal que $L = L_{D_1} \cup L_{D_2}$ e $L_{D_1} \cap L_{D_2} = \emptyset$. Analogamente, o subconjunto $U \subset E$ que contém os exemplos nos quais o atributo classe é desconhecido é também dividido em duas descrições U_{D_1} e U_{D_2}, tal que $U = U_{D_1} \cup U_{D_2}$ e $U_{D_1} \cap U_{D_2} = \emptyset$. Os dados de entrada do algoritmo de CO-TRAINING consistem desses quatro conjuntos de exemplos L_{D_1}, L_{D_2}, U_{D_1} e U_{D_2}. Na Figura 1(b) encontram-se ilustrados esses quatro conjuntos de exemplos, os quais são submetidos ao algoritmo CO-TRAINING descrito a seguir.

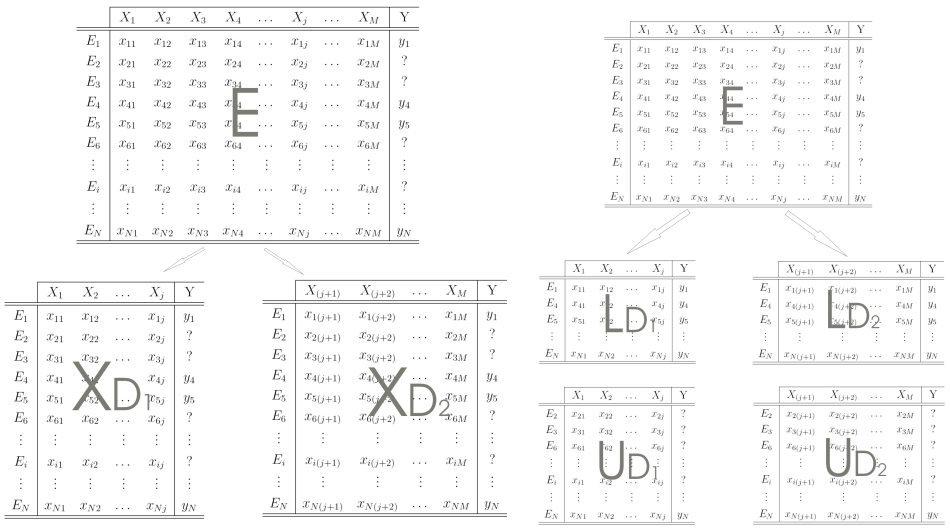

(a) Conjunto de exemplos E dividido em duas descrições $\mathbf{X}_{D_1}$ e $\mathbf{X}_{D_2}$.

(b) Descrições $\mathbf{X}_{D_1}$ e $\mathbf{X}_{D_2}$ divididas em sub-conjuntos L_{D_1}, U_{D_1} e L_{D_2}, U_{D_2}.

Figura 1: Criação de duas descrições de um conjunto de dados

4. O ALGORITMO CO-TRAINING

No primeiro passo do CO-TRAINING — Algoritmo 1 —, antes do laço, são criados dois subconjuntos U'_{D_1} e U'_{D_2}, tal que $U' = U'_{D_1} \cup U'_{D_2}$ e $U'_{D_1} \cap U'_{D_2} = \emptyset$, sendo U' um subconjunto de, geralmente, poucos exemplos de U, ou seja, esses dois subconjuntos de exemplos não rotulados U'_{D_1} e U'_{D_2} são subconjuntos de U_{D_1} e U_{D_2}, respectivamente. Os exemplos que compõem U'_{D_1} e U'_{D_2} são removidos de U_{D_1} e U_{D_2} a fim de verificar as condições $U'_{D_1} \cap U_{D_1} = \emptyset$ e $U'_{D_2} \cap U_{D_2} = \emptyset$ criando assim conjuntos disjuntos. Após cada iteração, com os conjuntos de exemplos rotulados L_{D_1} e L_{D_2} são induzidos dois classificadores h_{D_1} e h_{D_2}, respectivamente, os quais são utilizados para rotular exemplos não rotulados de U'_{D1} e U'_{D2}. No fim desse processo, R'_{D_1} e R'_{D_2} contém os conjuntos de exemplos rotulados nesse passo da iteração, os quais são argumentos da função $melhores/2$ que é responsável pela seleção de exemplos que foram "melhor" rotulados, e com o mesmo rótulo, pelos respectivos classificadores h_{D_1} e h_{D_2}.

Algoritmo 1 Cotraining

Input: $L_{D_1}, L_{D_2}, U_{D_1}, U_{D_2}, k$
Output: L_{D_1}, L_{D_2}
Construir U'_{D_1} e U'_{D_2} como descrito;
$U_{D_1} = U_{D_1} - U'_{D_1}$;
$U_{D_2} = U_{D_2} - U'_{D_2}$;
for $i = 0$ *to* k **do**
    induzir o classificador h_{D_1} a partir dos exemplos de treinamento L_{D_1};
    induzir o classificador h_{D_2} a partir dos exemplos de treinamento L_{D_2};
    R'_{D_1} = todos os exemplos de U'_{D_1} rotulados com o classificador h_{D_1};
    R'_{D_2} = todos os exemplos de U'_{D_2} rotulados com o classificador h_{D_2};
    $(R_{D_1}, R_{D_2}) = melhores(R'_{D_1}, R'_{D_2})$;
    if $R_{D_1} = \emptyset$ **then Return** L_{D_1}, L_{D_2} ;
    $L_{D_1} = L_{D_1} \cup R_{D_1}$;
    $L_{D_2} = L_{D_2} \cup R_{D_2}$;
    if $U_{D_1} = \emptyset$ **then Return** L_{D_1}, L_{D_2} **else**
        retirar aleatoriamente alguns exemplos de U_{D_1} e os exemplos respectivos de U_{D_2} e adicioná-los a U'_{D_1} e U'_{D_2} respectivamente;
    end
end
Return L_{D_1}, L_{D_2};

Em outras palavras, a função $melhores/2$ ignora exemplos que foram rotulados diferentemente pelos classificadores h_{D_1} e h_{D_2}. Posteriormente, é calculado o *ranking* dos exemplos rotulados como o produto das probabilidades das classes fornecidas pelos classificadores h_{D_1} e h_{D_2}. Os exemplos são ordenados pelo *ranking* em forma decrescente e a função $melhores/2$ seleciona os melhores exemplos (os primeiros do *ranking*) de cada classe. Após a execução da função $melhores/2$, os exemplos que foram "melhor" rotulados são adicionados aos conjuntos de exemplos de treinamento L_{D_1} e L_{D_2}. Caso ainda existam exemplos não rotulados, são utilizados mais exemplos ainda não rotulados em U_{D1} e U_{D2} os quais são adicionados aos conjuntos U'_{D1} e U'_{D2}, respectivamente, e o processo é repetido.

Note que a função $melhores/2$ exige do classificador um valor de confiança para cada exemplo rotulado. Como mencionado, no artigo do método original é utilizado o algoritmo *Naive Bayes*. O *Naive Bayes*, ao classificar um exemplo, fornece a probabilidade do exemplo pertencer a cada uma das classes possíveis. Entre essas classes possíveis, a classe de maior probabilidade é a classe do exemplo. Essa probabilidade da classe do exemplo é aqui denominada de valor de confiança. O usuário pode definir um valor mínimo aceitável para esse valor de confiança. Dessa maneira, todos os exemplos rotulados que possuírem o valor de confiança menor que o definido pelo usuário são descartados.

5. Pré-processamento dos textos

O subcórpus para a construção da base de dados para execução dos experimentos foi obtida utilizando o Lácio-web [2] do Núcleo Interinstitucional de Lingüística Computacional (NILC USP-São Carlos). No Lácio-web estão disponibilizados diversos córpus que podem ser acessados e copiados livremente. Entre os córpus existentes no Lácio-web, o Lácio-ref possibilita a construção de subcórpus de acordo com a necessidade do

[2] `http://www.nilc.icmc.usp.br/lacioweb/`

usuário. A versão atual do Lácio-ref possui 4.156.816 ocorrências composta por textos organizados em cinco gêneros (informativo, científico, prosa, poesia e drama), vários tipos de textos (por exemplo, reportagens, artigos, crônicas, cartas), vários domínios (como educação, engenharia, política) e alguns meios de distribuição (revista, internet, livro, por exemplo). O Lácio-ref é disponibilizado para pesquisa com geração de subcórpus para download em dois formatos: um com cabeçalho em XML contendo dados bibliográficos e de catalogação, e outro com o título, subtítulo, autoria e texto cru.

Para avaliar o método de construção de multi-visões, foi construído um subcórpus utilizando os cadernos `dinheiro`, `esport` e `informática` do jornal Folha de São Paulo. Cada caderno representa uma classe para o algoritmo de aprendizado de máquina — Tabela 1. O subcórpus construído é do gênero informativo, contendo textos de diferentes domínios do meio jornalístico. Os tipos de textos mais comuns encontrados nesse subcórpus são notícias, reportagens ou artigos, todos coletados em 1994.

caderno	abreviação	# textos
`dinheiro`	din	279
`esport`	ept	302
`informática`	inf	253

Tabela 1: Cadernos do Jornal Folha de SP utilizados como *classe*

Combinando os três cadernos foram construídos 4 conjuntos de textos: três com duas classes, `din-ept`, `din-inf`, `ept-inf` e uma com três classes `din-ept-inf` — Tabela 2. Os conjuntos de textos foram devidamente separados nesses 4 conjuntos de textos e pré-processados, *i.e.*, transformados em tabela atributo-valor separadamente. Essa etapa foi realizada com a ferramenta de pré-processamento PRETEXT[3] (Matsubara et al., 2003). Inicialmente, o PRETEXT transformou as palavras dos textos em *stems* (remoção de sufixos de um termo, ou mesmo na transformação de um verbo para sua forma no infinitivo). Os *stems* foram agrupados dois a dois para formarem os 2-*gram* necessários para a construção da segunda visão do CO-TRAINING. As tabelas atributo-valor foram construídas utilizando a abordagem *bag-of-words* (*bow*). Nessa abordagem, cada texto é representado por um vetor de palavras ou termos, sendo que cada palavra ou termo está associado a um valor numérico. O valor numérico é fornecido por uma medida geralmente associada à frequência de ocorrência da palavra ou termos nos textos. Nos experimentos realizados foi utilizada a contagem dos termos nos textos, também conhecida como medida *term frequency* (tf).

Com as duas visões, 1-*gram* e 2-*gram*, devidamente transformadas foram realizados os cortes de Luhn, o qual considera que os termos muito frequentes e pouco frequentes não são muito relevantes para descrever o texto. A Tabela 2 apresenta os cortes máximo e mínimo de cada conjunto. Para 1-*gram* foram retirados os termos que aparecem uma ou duas vezes ou os termos que apareceram mais de 600 vezes. Para 2-*gram* os conjuntos com duas classes foram pré-processados retirando os termos que aparecem menos de quatro vezes. O conjunto com três classes para 1-*gram* foram retirados os termos que apareceram menos que três vezes e mais que 900 vezes. Para 2-*gram* foram retirados os termos menos de quatro vezes.

CO-TRAINING utiliza duas descrições do conjunto de exemplos, as quais devem se corresponder uma a uma (devem ser compatíveis). Assim, o método de reamostragem 10-*fold cross-validation* foi adaptado para essa particularidade do algoritmo, como ilustrado na Figura 2. Após o pré-processamento das bases de documentos, cada

[3]Disponível para *download* em `www.icmc.usp.br/~edsontm/`

conjunto		visão	corte min	corte max	#atr. depois corte
`din-ept`	581	1-*gram*	3	600	4129
		2-*gram*	4	-	1577
`din-inf`	532	1-*gram*	3	600	3831
		2-*gram*	4	-	1450
`ept-inf`	555	1-*gram*	3	600	3815
		2-*gram*	4	-	1302
`din-ept-inf`	834	1-*gram*	3	900	5180
		2-*gram*	4	-	2301

Tabela 2: Cortes de Lunh

uma das descrições do conjunto de exemplos é particionada em 10 subconjuntos, sendo que cada subconjunto contém exemplos correspondentes a cada uma das descrições. Essas partições são sempre pareadas uma a uma, tal que as mesmas partições de ambas as descrições, em cada iteração, são utilizadas para treinamento (90%) e teste (10%). Todos os experimentos com CO-TRAINING, descritos a seguir, foram avaliados utilizando 10-*fold cross-validation*, no qual os 10 *folds* foram construídos como ilustrado na Figura 2.

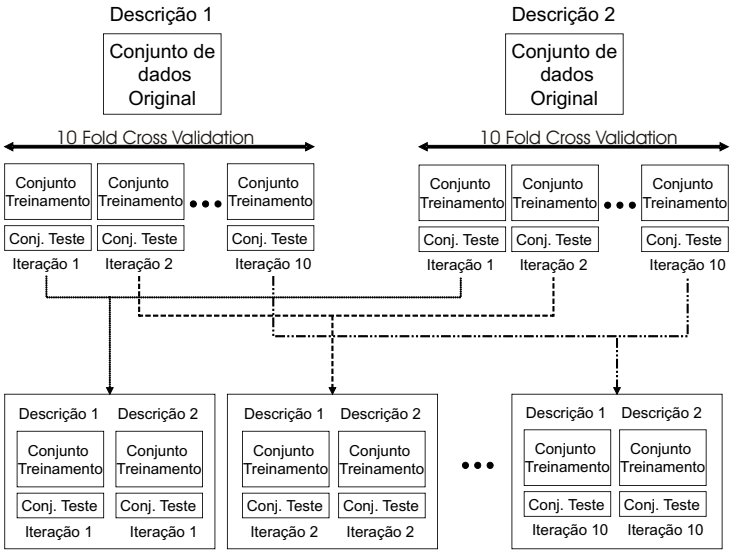

Figura 2: Representação gráfica da construção dos 10-*folds* para CO-TRAINING

6. Análise experimental

Na implementação realizada (Matsubara and Monard, 2004), CO-TRAINING pode ser executado em dois modos diferentes: modo simulação e modo real. A principal diferença entre esses modos de execução refere-se ao conjunto de exemplos não rotulados U. No modo simulação, o conjunto U é construído artificialmente a partir de um conjunto de exemplos rotulados. Dessa maneira, é possível verificar, a cada iteração do algoritmo, se os rótulos atribuídos por CO-TRAINING aos exemplos "não rotulados" coincidem com os verdadeiros rótulos desses exemplos. Todos os experimentos com CO-TRAINING realizados neste trabalho foram executados no modo simulação. Foi utilizado o algoritmo *Naive Bayes* para construir, em cada iteração do algoritmo, os classificadores h_{D_1}, h_{D_2} e o classificador combinado h o qual é construído multiplicando as probabilidades obtidas de h_{D_1} e h_{D_2}.

Para avaliar o uso de duas visões com 1-*gram* e 2-*gram*, foram realizados alguns experimentos com o algoritmo CO-TRAINING com as bases previamente descritas. A implementação realizada do algoritmo CO-TRAINING foi executada com os parâmetros padrão ilustrados na Tabela 3.

critério de parada	$U = \emptyset$
tamanho inicial do conjunto de exemplos rotulados	10 exemplos
valor mínimo de confiança	0.6

Tabela 3: Parâmetros utilizados nos experimentos com CO-TRAINING

O critério de parado do algoritmo é acionado quando o conjunto de exemplos não rotulados U estiver vazio. Vale ressaltar que o U' ainda pode ter alguns exemplos a serem rotulados. O número de exemplos rotulados inicial L_{ini} é de 10 exemplos, o que representa aproximadamente 2% dos dados para os conjuntos com duas classes. Com relação ao conjunto de teste, ele consiste, em cada uma das execuções realizadas usando a adaptação de 10-*fold cross validation* ilustrada na Figura 2 na página anterior, de um arquivo `.test` que contém os 10% dos exemplos de teste para os respectivos 90% de exemplos de treinamento.

Na Tabela 4 é apresentado, para cada conjunto de dados, um resumo dos resultados obtidos ao final da execução do CO-TRAINING. Os resultados apresentados são as médidas obtidas nos 10 pares de conjuntos de treinamento e teste, em conjunto com os respectivos desvios padrão. A tabela apresenta o número de iterações realizadas pelo algoritmo CO-TRAINING (# iterações), o tamanho do conjunto de exemplos rotulados ao final da execução ($|L_{fim}|$), o número total de exemplos rotulados errados (# Errados), e o percentual de exemplos rotulados errados (% Errados). Deve-se notar que o número de exemplos rotulados errados pode ser considerado baixo, sobretudo considerando que os classificadores foram gerados incrementalmente a partir de uma base inicial de somente 10 exemplos rotulados. Para o conjunto de dados com duas classes com pior desempenho, `din-inf`, o algoritmo errou em média 8.8 entre 423.6 exemplos, isto é, aproximadamente 2% dos exemplos estão rotulados errados. Para a base com três classes, `din-ept-inf`, o algoritmo errou em média 16.7 entre 656 exemplos (2.5%).

conjunto	# iterações	$\lvert L_{fim}\rvert$	# Errados	% Errados
`din-ept`	116	461.6 (2.72)	4.0 (1.05)	0.87% (0.23%)
`din-inf`	106	423.6 (0.70)	8.8 (1.62)	2.07% (0.38%)
`ept-inf`	110	433.4 (2.32)	2.7 (1.16)	0.62% (0.27%)
`din-ept-inf`	111	656.0 (4.35)	16.7 (3.43)	2.55% (0.52%)

Tabela 4: Resumo do número de exemplos rotulados e o número de exemplos rotulados errados

Na Tabela 5 é mostrado o erro médio na primeira e última iteração dos classificadores induzidos, h_{D_1} e h_{D_2}, e do classificador combinado h para cada conjunto de documentos; o número entre parênteses indica o desvio padrão. Vale ressaltar que na primeira iteração do CO-TRAINING os classificadores são construídos utilizando apenas 10 exemplos rotulados e como esperado o erro da primeira é sempre maior que o erro da última iteração.

O erro dos classificadores combinados h dos quatro conjuntos são apresentados na Figura 3. Todos os quatro conjuntos tiveram resultados semelhantes sendo bastante evidente o descréscimo do erro dos classificadores nos quatro conjuntos de dados durante as iterações.

	h_{D_1}		h_{D_2}		h	
conjunto	primeira	última	primeira	última	primeira	última
din-ept	5.51 (4.66)	1.03 (1.44)	29.24 (8.74)	3.79 (2.67)	5.17 (4.45)	1.03 (1.44)
din-inf	9.43 (4.88)	2.62 (2.35)	32.70 (4.88)	6.95(4.36)	9.43 (5.19)	2.62 (2.35)
ept-inf	2.86 (3.02)	0.36 (0.77)	24.75 (7.13)	2.53 (2.29)	3.05 (3.01)	0.54 (0.87)
din-ept-inf	13.53 (3.95)	2.28 (1.64)	45.19 (5.79)	6.12 (2.15)	14.73 (3.08)	2.40 (1.49)

Tabela 5: Erro médio (%) dos classificadores na primera e última iteração

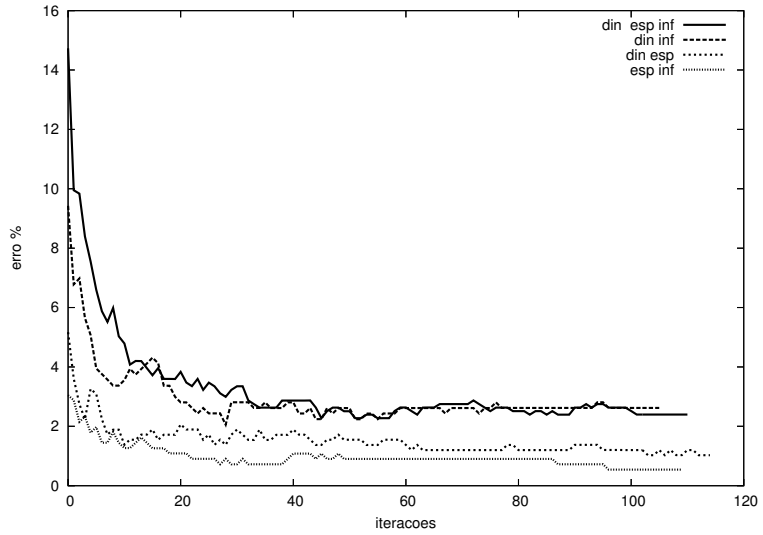

Figura 3: Classificador combinado dos 4 conjuntos

7. Conclusões

Rotular textos é uma tarefa árdua, demorada e muitas vezes realizada manualmente. Este trabalho apresentou o aprendizado semi-supervisionado como uma método de auxílio a essa tarefa, no qual ao rotular alguns poucos exemplos, os algoritmos semi-supervisionados rotulam o restante dos exemplos. No entanto, boa parte dos algoritmos de aprendizado semi-supervisionados são multi-visão e necessitam que os dados fornecidos como entrada sejam de diferentes descrições que por sua vez devem ser compatíveis e independentes. A construção das duas descrições dos dados é altamente depedente do domínio de aplicação. Neste trabalho foi apresentada uma abordagem para a construção de duas ou mais descrições de dados obtidas a partir de documentos textos que satisfazem essas condições. As descrições dos dados são obtidas na fase de pré-processamento dos textos, por meio da criação de n-*grams*.

Considerando o número de exemplos rotulados errado e o erro dos classificadores induzidos, pode-se concluir que o algoritmo semi-supervisionado CO-TRAINING atingiu bons resultados com os quatro conjuntos de dados utilizados. Com apenas 10 exemplos rotulados foi possível rotular quase totalmente os conjuntos com uma média de erro (10 folds) de aproximandamente 2%. Esse bom desempenho é refletido na precisão dos classificadores induzidos no qual é bastante evidente o decréscimo no erro dos classificadores. Desse modo, CO-TRAINING mostrou-se bastante efetivo como um rotulador de exemplos para auxiliar a construção de córpus anotados.

Referências

Blum, A. and Mitchell, T. (1998). Combining labeled and unlabeled data with co-training. In *Proc. 11th Annu. Conf. on Comput. Learning Theory*, pages 92–100. ACM Press, New York, NY.

Brefeld, U. and Scheffer, T. (2004). Co-EM Support Vector Learning. In *Proceedings of the International Conference in Machine Learning*. Morgan Kaufmann.

Collins, M. and Singer, Y. (1999). Unsupervised models for named entity classification. In *Proceedings of the Joint SIGDAT Conference on Empirical Methods in Natural Language Processing and Very Large Corpora*.

Cozman, F. G., Cohen, I., and Cirelo, M. C. (2003). Semi-supervised learning of mixture models. In Fawcett, T. and Mishra, N., editors, *Proceedings of the 20th International Conference (ICML 2003)*, pages 99–106. AAAI Press.

Ghani, R. (2002). Combining labeled and unlabeled data for multiclass text categorization. In *Proceedings of the 19th International Conference (ICML 2002)*, pages 187–194.

Goldman, S. and Zhou, Y. (2000). Enhancing supervised learning with unlabeled data. In *Proceedings of the International Conference on Machine Learning*, pages 327–334. Morgan Kaufmann.

Kiritchenko, S. and Matwin, S. (2001). Email classification with co-training. In *Conference of the Centre for Advanced Studies on Collaborative research*, page 8. IBM Press.

Kiritchenko, S. and Matwin, S. (2002). Email classification with co-training. Technical report, University of Otawa.

Kockelkorn, M., Lüneburg, A., and Scheffer, T. (2003). Using transduction and multiview learning to answer emails. In *Proceedings of the European Conference on Principle and Practice of Knowledge Discovery in Databases*, pages 266–277. Springer-Verlag.

Matsubara, E. T., Martins, C. A., and Monard, M. C. (2003). Pretext: Uma ferramenta para pré-processamento de textos utilizando a abordagem *bag-of-words*. Technical Report 209, ICMC-USP. `ftp://ftp.icmc.sc.usp.br/pub/BIBLIOTECA/rel_tec/RT_209.zip`.

Matsubara, E. T. and Monard, M. C. (2004). Projeto e implementação do algoritmo de aprendizado de máquina semi-supervisionado CO-TRAINING. Technical Report 229, ICMC-USP. `ftp://ftp.icmc.usp.br/pub/BIBLIOTECA/rel_tec/rel_tec229.zip`.

Muslea, I. (2002). Active Learning With Multiple Views. Phd Dissertation, University Southerm California.

Muslea, I., Minton, S., and Knoblock, C. (2002). Active + semi-supervised learning = robust multi-view learning. In *International Conference on Machine Learning*, pages 435–432. Morgan Kaufmann.

Nigam, K. and Ghani, R. (2000). Analyzing the effectiveness and applicability of co-training. In *Conference on Information and Knowledge Management*, pages 86–93.

Nigam, K., McCallum, A. K., Thrun, S., and Mitchell, T. M. (2000). Text classification from labeled and unlabeled documents using EM. *Machine Learning*, 39(2/3):103–134.

Sanches, M. K. (2003). Aprendizado de máquina semi-supervisionado: proposta de um algoritmo para rotular exemplos a partir de poucos exemplos rotulados. Dissertação de Mestrado, ICMC-USP, `http://www.teses.usp.br/teses/disponiveis/55/55134/tde-12102003-140536`.

Vapnik, V. (1998). *Statistical learning theory*. John Wiley & Sons.

Wagstaff, K., Cardie, C., Rogers, S., and Schroedl, S. (2001). Constrained k-means clustering with background knowledge. In *Proceedings of the Eighteenth International Conference on Machine Learning*, pages 577–584.