

Vigilância em atenção básica à saúde a partir do uso de *relevance feedback* para classificação de pacientes em diferentes níveis de cuidado em saúde

J. T. Pollettini¹, R. Tinos¹, S. Panico², J. C. Daneluzzi², A. A. Macedo¹

¹ Departamento de Física e Matemática, FFCLRP – USP

² Departamento de Pediatria e Puericultura, FMRP – USP

jupollettini@usp.br, {ale_alaniz,rtinos}@ffclrp.usp.br,
sylviaapanico.sc@gmail.com, juliiodaneluzzi@hotmail.com

Abstract. *The identification of people requiring different levels of Pediatric health care at a Primary Healthcare Unit in Ribeirão Preto exploits the Grau de Vigilância (GV) measure. This paper proposes the automatic definition of GV using relevance feedback towards helping surveillance in primary healthcare. As a result, it was developed alertness functionalities to the system responsible for automatic classification of GV.*

Resumo. *Com o objetivo de identificar pacientes requerendo diferentes níveis de atenção à saúde, uma Unidade Básica de Saúde (UBS) de Ribeirão Preto utiliza uma medida denominada Grau de Vigilância (GV). O presente artigo propõe o desenvolvimento de uma funcionalidade de vigilância para o sistema de definição automática do GV do paciente considerando relevance feedback.*

1. Introdução

Profissionais da atenção básica a saúde necessitam detectar, o mais cedo possível, pacientes em situação de risco visando promover encaminhamentos ou intervenções que minimizem ou corrijam problemas detectados. Outra ação importante para esses profissionais é identificar pacientes, principalmente crianças, que contam com fatores protetores para a promoção da saúde e do desenvolvimento [Salles 2001]. Com o objetivo de sistematizar procedimentos para o acompanhamento do processo de desenvolvimento humano e a promoção da saúde de pacientes atendidos em unidades básicas de saúde, pesquisadores de diferentes universidades brasileiras, integrantes de um núcleo de pesquisa denominado “Núcleo Interdisciplinar de Pesquisa e Ensino (NIPE)”, realizaram, durante as últimas décadas, diversas pesquisas, propondo a utilização de um índice denominado Grau de Vigilância (GV) [Panico 1998].

O GV consiste em um índice cuja utilização permite a definição de procedimentos, inicialmente pediátricos, a serem adotados no atendimento básico a saúde, por meio da associação de fatores de risco e de proteção à saúde e ao processo de desenvolvimento, aos quais estão expostos os pacientes e suas famílias. O GV deve ser definido para cada paciente em cada atendimento do qual o mesmo participa, visto que varia de acordo com o período de desenvolvimento pelo qual ele está passando e de acordo também com variáveis orgânicas ou ambientais presentes em sua vida naquele momento. Esse índice varia em valores gradativos possibilitando a definição de ações educativas, terapêuticas ou terapêuticas especializadas requeridas pelos pacientes e respectivas famílias. O GV pode ser estabelecido de acordo com os seguintes valores: GV Rotina, que indica necessidade apenas de ações de rotina usualmente prestadas nos serviços de atenção primária à saúde; GV1, que adverte

para a necessidade adicional de ações educativas; GV2, que indica que o paciente requer, além de ações educativas, ações terapêuticas; GV3, que indica necessidade também de ações terapêuticas especializadas; e GV Urgência, cuja atribuição pode vir associada a qualquer outro GV e indica necessidade de urgência no atendimento [Salles 2001][Panico 1998].

Este artigo propõe mecanismos automáticos de vigilância em atenção básica a partir do uso de *relevance feedback* para a classificação de medidas identificadoras, especificamente GV, de pacientes que requerem diferentes níveis de cuidado em saúde. Como resultado, gerou-se um sistema de alerta para os profissionais de uma equipe interdisciplinar (familiarizada com o GV) que sinaliza atendimentos classificados como GV3 ou GV Urgência. Experimentos com os mecanismos propostos foram realizados e comparados com os resultados de trabalhos prévios que usavam técnicas de reconhecimento de padrões para a classificação de GVs. Esses experimentos usam informações de pacientes do atendimento médico pediátrico multidisciplinar de uma unidade básica de saúde de Ribeirão Preto. Os resultados dos experimentos indicam bom desempenho da proposta.

O restante do artigo está organizado da seguinte forma: a Seção 2 contém trabalhos prévios, a Seção 3 contém a apresentação da proposta, na Seção 4 são apresentados resultados experimentais, a Seção 5 contém trabalhos relacionados e a Seção 6 apresenta a conclusão.

2. Trabalhos Prévios de Suporte

O Centro Médico Social e Comunitário de Vila Lobato (CMSC Vila Lobato) é uma unidade de atendimento primário à saúde em Ribeirão Preto/SP que exerce atividades clínicas, de ensino e de pesquisa há quase 40 anos. Um dos focos de trabalho do CMSC Vila Lobato é o acompanhamento em puericultura à saúde da criança e do adolescente de uma população aproximada de 18 mil pessoas. O Grau de Vigilância (GV) está sendo implantado na rotina de trabalho do CMSC Vila Lobato para suportar o funcionamento de um programa de intervenção para promoção da saúde e do desenvolvimento.

Buscando melhorias no atendimento de seus pacientes e no fluxo de informação gerada por atendimentos, o CMSC Vila Lobato estabeleceu uma parceria com pesquisadores de Informática Biomédica. Dessa parceria, nasceu o Sistema de Informação Vila Lobato (SI-VilaLobato) que visa à informatização dos procedimentos de atendimento e acompanhamento de saúde das crianças e adolescentes atendidos pelo CMSC Vila Lobato, assim como suas respectivas famílias [Costa et al 2008].

Inserido no contexto do sistema SI-VilaLobato, o GV-Automático é um projeto que propõe a definição automática do GV do paciente a partir da manipulação e análise de informações provenientes dos prontuários de atendimento do CMSC Vila Lobato. Em trabalhos prévios, foram investigadas técnicas de reconhecimento de padrões como *k*-vizinhos mais próximos e redes neurais artificiais para o desenvolvimento de classificadores capazes de definir o GV dos pacientes [Pollettini et al 2008]. O GV-Automático foi desenvolvido para proporcionar as seguintes funcionalidades:

- *verificação e correção do GV*: apresenta um resumo de atendimentos realizados, permitindo que os profissionais analisem o GV de cada atendimento e, caso julguem necessário, corrijam-no ou marquem-no como “*confirmado*”.
- *consulta do GV*: disponibiliza aos profissionais de saúde uma segunda opinião para a atribuição do índice, de acordo com informações fornecidas pelo próprio profissional e referentes a um dado atendimento.

- *configuração de classificadores*: permite que os classificadores a serem usados sejam reconfigurados e atinjam um aprendizado melhor. Para o treinamento dos classificadores apenas exemplos confiáveis (confirmados pela primeira função) são considerados.
- *comparação e seleção de classificador*: disponibiliza um mecanismo para o administrador do sistema comparar os resultados dos módulos de classificação de determinada coleção de atendimentos, uma vez que o classificador com melhores resultados pode variar dependendo do conjunto de treinamento.

É interessante ressaltar que os módulos classificadores usando vizinhos próximos e redes neurais possuem interface com classes do pacote Weka [Witten e Frank 2005], fazendo chamadas aos algoritmos IBk e MultilayerPerceptron. Outras classes do processo de classificação e os métodos usados pelos módulos de classificação podem ser vistos na Figura 1.

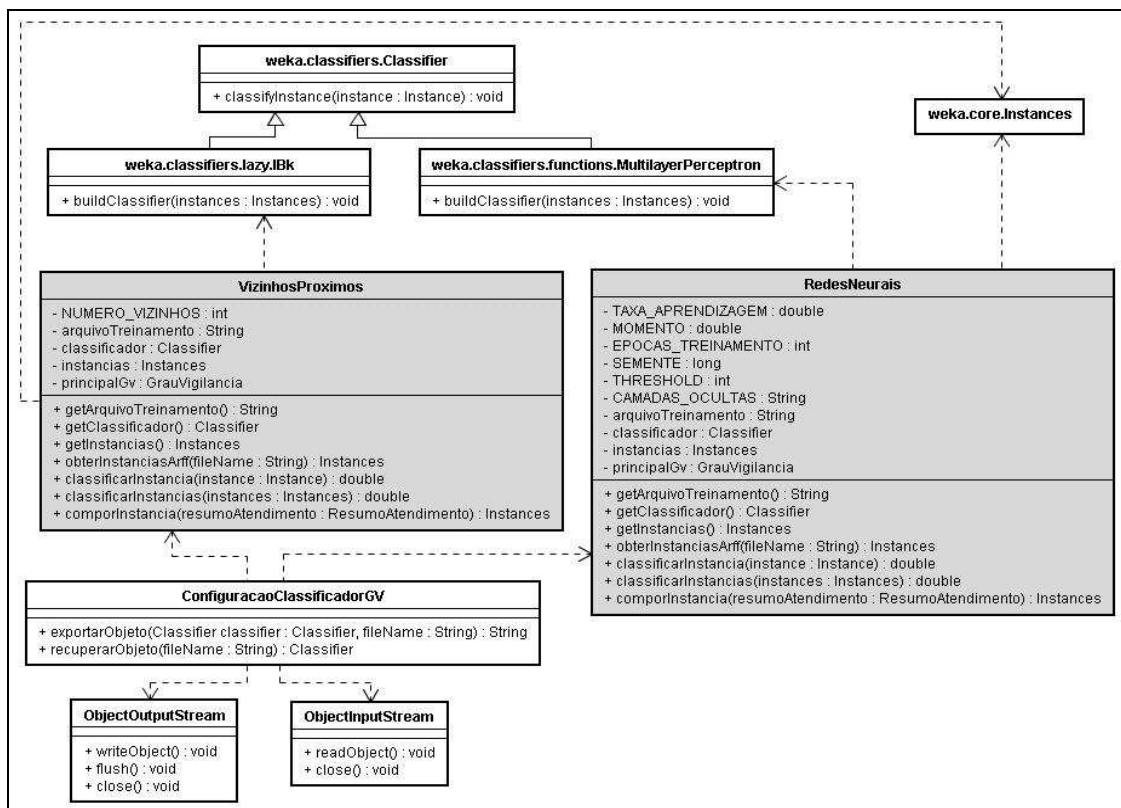


Figura 1: GV-Automático com redes neurais e vizinhos mais próximos

Para a criação do classificador usando vizinhos próximos, a classe VizinhosProximos gera um arquivo contendo os atributos considerados pelo classificador e os exemplos de atendimentos para o treinamento. Em seguida, a mesma classe chama o construtor weka.classifiers.lazy.IBk, passando como parâmetro o número k de vizinhos mais próximos. Para representar os exemplos, o módulo instancia a classe weka.core.instances considerando o arquivo com os atributos e exemplos, e estabelece como classe o atributo que indica o GV dos mesmos. Finalmente o algoritmo chama o método buildClassifier da classe weka.classifiers.lazy.IBk e exporta o classificador instanciado em uma chamada ao método exportarObjeto da classe ConfiguracaoClassificadorGV, a qual acessa a classe ObjectOutputStream para salvar de maneira persistente o estado do objeto naquele instante. Em novos atendimentos, o módulo recupera o classificador cujo estado foi salvo e classifica os novos exemplos com os métodos classificarInstancia e classificarInstancias.

O módulo de classificação usando redes neurais é similar ao módulo com vizinhos próximos em relação ao acesso a classes externas. Porém em vez de utilizar a classe `weka.classifiers.lazy.IBk`, esse módulo chama métodos da classe `weka.classifiers.functions.MultilayerPerceptron`.

3. Vigilância em atenção básica a partir do GV com *relevance feedback*

Considerada como uma área de estudos do domínio de sistemas de recuperação de informação, *relevance feedback* é um processo por meio do qual consultas de usuário em sistemas de recuperação de informação podem ser seletivamente modificadas na tentativa de recuperar os documentos mais relevantes de uma coleção [Baeza-Yates e Ribeiro-Neto 1999][Rocchio 1971]. A consulta pode ser modificada com ajustes de pesos de termos, da inclusão de novos termos ou ainda da combinação das duas abordagens. Essas abordagens de modificação da consulta original podem ser efetuadas via interação com usuários ou pela utilização automática de propriedades dos documentos recuperados. Segundo Hersh [Hersh 2003], *relevance feedback* possibilita que novos documentos sejam adicionados a um resultado baseando-se em sua similaridade para com documentos considerados como relevantes pelo usuário, além de permitir uma redefinição de pesos de documentos relevantes recuperados.

Os autores deste artigo propõem pesquisar os benefícios que *relevance feedback* pode trazer a uma abordagem de vigilância automática de pacientes a partir da classificação automática de GVs. Pretende-se aprimorar no projeto GV-Automático a definição automática do GV do paciente, a qual se dá a partir da manipulação e análise de informações provenientes dos prontuários de atendimento médico em unidades básicas de saúde. A seguir são apresentados para o módulo de classificação proposto com *relevance feedback*: o modelo de representação das informações de pacientes, o processamento dessas informações usando métodos de pré-processamento (eliminação de *stopwords* e *stemming*), atribuição de pesos a termos de índice de documentos, classificação e aplicação de *relevance feedback* nos documentos, a fim de aprimorar sua adesão aos clusters pré-definidos pelo cálculo de centróides. Em seguida é apresentada a estruturação em classes do módulo proposto e sua incorporação à estrutura prévia de classes do GV-Automático. Ao final é apresentada a adequação do sistema de 2ª opinião GV-Automático a um sistema de vigilância em atenção básica a saúde.

3.1. Mecanismos de processamento, classificação e *relevance feedback*

O módulo de classificação com *relevance feedback* manipula informação distinta dos sistemas de recuperação de informação, uma vez que esses normalmente utilizam documentos em formato texto e o GV-Automático armazena informações estruturadas de atendimento médico. Por esse motivo, foi definida a junção das informações dos campos do registro médico criando-se um texto a ser manipulado pelo módulo. Em seguida, foram estudados modelos de representação de documentos para servirem como documento textual de entrada do módulo proposto. Optou-se pela utilização da abordagem *bag of words* para representar as informações, visto que, apesar de ocasionar perda das relações semânticas e sintáticas das palavras, foi suficiente para o processo de classificação realizado com a abordagem *relevance feedback*.

Após a transformação dos dados para a representação de *bag of words*, foram realizados processos de retirada de *stopwords* e de *stemming*, com o objetivo de reduzir o número de termos a serem utilizados pelo módulo. As palavras resultantes são

consideradas como os termos de índice do documento e o conjunto dos termos de índice de todos os documentos consiste no conjunto de termos classificadores a ser usado nas etapas seguintes do módulo de classificação. Após essa etapa de pré-processamento das informações é gerada uma matriz de frequência de termos por documento e os pesos de cada termo em cada documento são calculados. Esses pesos são reunidos em uma matriz de pesos e, para esse cálculo, é utilizada a abordagem *TF*IDF Weighting*, a qual, segundo Hersh [Hersh 2003], consiste em uma métrica que atribui valores, denominados de pesos, mais significantes às palavras mais importantes de um documento. Essa técnica combina a frequência com que um termo ocorre em um documento (*term frequency* - TF) e o logaritmo da razão do número total de documentos pelo número de documentos que contém o termo (*inverse document frequency* - IDF).

A partir da matriz de pesos, pode-se preparar um espaço vetorial em que cada documento é representado por um vetor e cada dimensão é formada por uma palavra do conjunto de termos classificadores. O resultado de cálculos de similaridade é armazenado em uma matriz de similaridade entre os documentos e, considerando-a, inicia-se um processo de classificação dos documentos. Através desse processo, quando um novo atendimento é submetido ao classificador, analisa-se sua distância aos centróides dos clusters formados, assim como o GV majoritário do cluster mais próximo e o GV do atendimento é classificado com o valor do GV majoritário encontrado. Caso o atendimento não seja similar a nenhum cluster, ou caso não seja possível definir o GV majoritário, o sistema informa ao usuário que não é possível classificar o GV com base apenas nos conhecimentos existentes.

Depois de gerados os clusters da coleção, inicia-se a fase de *relevance feedback*. Nessa fase, informações sobre o GV pré-estabelecido pelos profissionais especializados são consideradas para avaliar os pesos de cada índice de termo por documento e recalculá-los inserindo informações sobre relevância de outros documentos para a determinação do índice. Os cálculos de *relevance feedback* são realizados com a aplicação da fórmula de Rocchio [Rocchio 1971]. Em seguida, aplica-se novamente o algoritmo de criação de clusters e repete-se o processo *n* vezes, sendo o *n* um valor de entrada do algoritmo.

3.2. Estruturação em classes do módulo de classificação com *relevance feedback*

O módulo de classificação com *relevance feedback* se assemelha aos módulos previamente criados para o GV-Automático, uma vez que se pretendia manter uma padronização com relação aos demais módulos (classificação usando vizinhos próximos e usando redes neurais). Essa decisão de projeto favoreceu a alta coesão entre as classes do subsistema. Na Figura 2 é apresentado um diagrama de classes simplificado (ocultando atributos e métodos das classes) e integrado do projeto GV-Automático. Nele é possível encontrar as classes envolvidas diretamente no processo de classificação automática de GVs. A classe principal de cada um dos três módulos criados é representada na cor cinza. As classes cujos nomes se iniciam com o termo “*weka*” são classes pertencentes ao pacote Weka [Witten e Frank 2005], com as quais os módulos do GV-Automático possuem interface.

Para suportar a proposta, criou-se uma classe denominada *ClassificadorRFCatGV* que implementa os mecanismos de processamento, classificação e *relevance feedback* apresentados na Seção 3.1. Essa classe estende a classe *weka.Classifiers.Classifier*, assim como as classes *weka.classifiers.lazy.IBk* e *weka.classifiers.functions.MultilayerPerceptron*. O módulo *RFCatGV* instancia exemplos através da classe *Documentos*, a qual possui relação com a classe *weka.core.instances*, reservadas particularidades originadas por diferenças técnicas entre as abordagens.

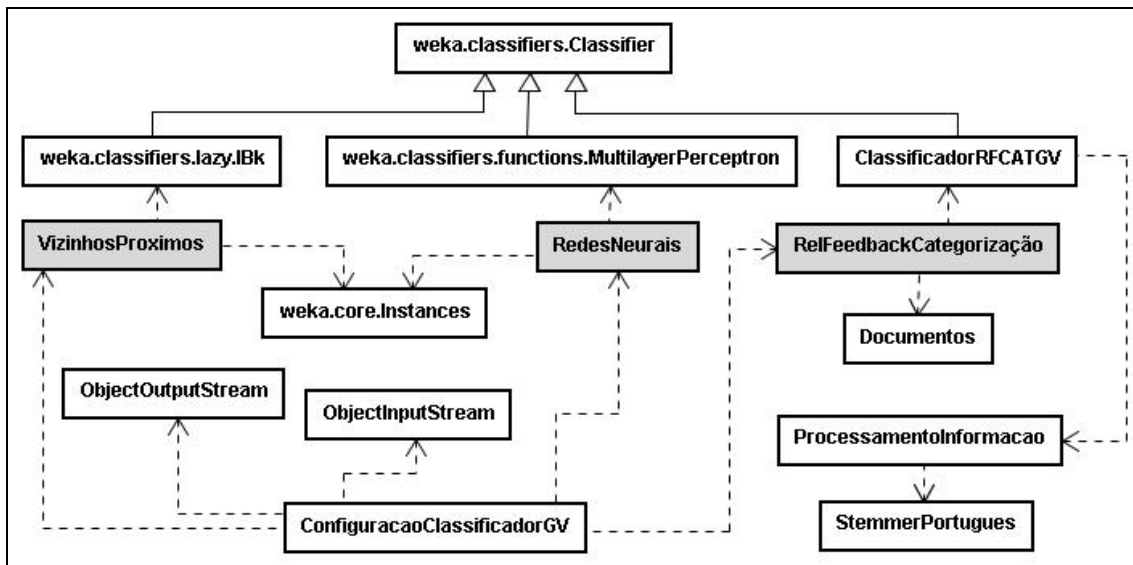


Figura 2: Diagrama de classes simplificado representando os três módulos de classificação automática do GV

3.3. GV-Automático: um sistema de 2ª opinião para um sistema de vigilância

Na versão anterior a esta proposta, o sistema GV-Automático possuía apenas funcionalidades que forneciam aos profissionais de saúde uma segunda opinião sobre o GV. Esse resultado descaracterizava a determinação do GV como verdadeiramente automática. Por esse motivo, algumas adaptações foram realizadas, tornando-o um sistema de vigilância.

Assim, com a configuração da funcionalidade de vigilância do GV-Automático, a cada inserção de novo atendimento no sistema de informação ou em períodos regulares de tempo, o GV-Automático classifica o GV dos atendimentos inseridos na base de dados e armazena essa classificação automática em um campo criado no banco de dados especificamente para esse fim. Caso encontre algum atendimento que classifique como GV3 ou GV Urgência, alerta os profissionais de uma equipe interdisciplinar (familiarizada com o GV) sobre a ocorrência, ajudando esses profissionais a detectar, o mais cedo possível, pacientes em situação de risco e, assim, promover encaminhamentos ou intervenções que corrijam ou, ao menos, minimizem problemas detectados.

4. Resultados Experimentais

Com o objetivo de avaliar o classificador proposto e comparar seu desempenho com os classificadores prévios do GV-Automático, utilizou-se a metodologia *Stratified Cross-Validation* com divisão dos exemplos em 10 partições [Kohavi 1995]. Essa avaliação foi realizada para dois conjuntos de exemplos fornecidos por profissionais das áreas de pediatria e psicologia do CMSC Vila Lobato. Os conjuntos de exemplos são compostos por 103 atendimentos do início de pesquisa e 534 atendimentos mais recentes. Esses conjuntos não foram unidos por conterem exemplos que, além de se sobreporem, apresentam variação na definição do GV. A seguir são apresentados os resultados experimentais da aplicação do classificador proposto com o uso de *relevance feedback* e categorização (RFCatGV) e gráficos comparativos do RFCatGV com os outros módulos do GV-Automático: classificador com vizinhos próximos (VPGV) e com redes neurais (RNGV).

4.1. O módulo RFCatGV

Para experimentar o classificador RFCatGV foram realizados testes com duas abordagens de seleção de atendimentos relevantes: (i) uma mais ampla que considera como relevantes todos os atendimentos de mesmo GV que aquele cujo peso estiver sendo recalculado e como atendimentos não relevantes todos aqueles com GV diferente daquele do atendimento em análise; e (ii) uma abordagem mais restrita que considera como relevantes apenas atendimentos de mesmo GV e pertencentes ao mesmo cluster e como não relevantes todos os atendimentos do mesmo cluster com GV diferente. Comparou-se resultados de testes com números variados de iterações do algoritmo de redefinição de pesos de Rocchio, ou seja, “quantas vezes os pesos são recalculados e os *clusters* rearranjados durante o treinamento” e diferentes combinações de valores de entrada para os pesos considerados pela fórmula de Rocchio. Os melhores resultados para cada uma das abordagens de seleção de exemplos relevantes e de números de iterações do algoritmo de Rocchio são apresentados nas Figuras 3 e 4. Na Figura 3 são apresentados os resultados do módulo RFCatGV para a abordagem mais ampla de seleção de atendimentos relevantes. Nele é possível observar duas curvas, uma contendo taxas de acerto do classificador para o conjunto de 103 exemplos, enquanto a outra contém os resultados para o conjunto de 534 exemplos. A Figura 4 é similar à primeira, entretanto apresenta os resultados para a abordagem mais restrita de seleção de atendimentos relevantes.




Figura 3: Taxas de acerto do módulo RFCatGV para a abordagem de seleção de relevância baseada em todos os atendimentos de mesmo GV




Figura 4: Taxas de acerto do módulo RFCatGV para a abordagem de seleção de relevância restrita a atendimentos de mesmo GV e pertencentes ao mesmo cluster

4.2. Análise comparativa dos módulos VPGV, RNGV e RFCatGV

Para os classificadores VPGV e RNGV foram realizados testes para cada conjunto de exemplos mencionados e os resultados podem ser observados pela análise da Figura 5, que apresenta uma comparação entre os resultados dos diferentes módulos de classificação automática do GV. O gráfico apresentado possui três curvas, contendo as taxas de acerto para cada um dos classificadores criados. Através do gráfico é possível perceber que, apesar de o módulo baseado em Redes Neurais Artificiais (RNGV) ter apresentado a princípio os melhores resultados para o conjunto de 103 exemplos de treinamento, o módulo baseado em *Relevance Feedback* (RFCatGV) manteve uma estabilidade maior nos resultados perante os dois conjuntos de treinamento.

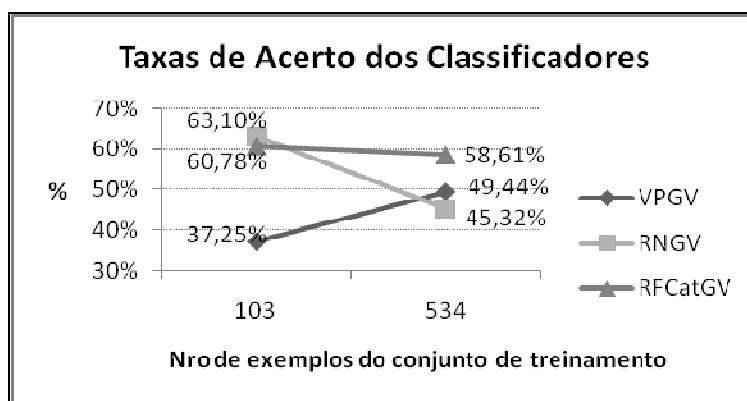


Figura 5: Melhores taxas de acerto para os diferentes tipos de classificadores

4.3. Análise dos resultados experimentais

Os módulos de classificação automática RFCatGV, VPGV e RNGV foram experimentados para diversos conjuntos de valores atribuídos às variáveis das quais os classificadores são dependentes. A partir de análises dos resultados, os módulos foram comparados e chegou-se à conclusão de que, a princípio, o algoritmo de classificação baseado em redes neurais artificiais apresentou os melhores resultados para a solução do problema em questão, enquanto o módulo baseado em *relevance feedback* se manteve mais estável com a variação do conjunto de treinamento. Entretanto, uma análise estatística será aplicada para esclarecer as diferenças entre os resultados dos três módulos. Por considerar que as taxas de acertos de cada classificador podem variar dependendo da coleção, o administrador do sistema pode configurar e selecionar o classificador a ser utilizado pelo GV-Automático.

Uma análise a respeito da taxa de acertos da atribuição manual do GV durante a atividade diária de profissionais de saúde depende do início da utilização efetiva do GV-Automático, principalmente da Verificação/Correção do GV. Até o momento, essas comparações foram realizadas apenas considerando os dois conjuntos de exemplos de GVs manuais e os resultados automáticos do sistema.

5. Trabalhos Relacionados

Um grupo de pesquisadores ingleses propõe a aplicação de lógica Fuzzy a informações médicas em um projeto que visa criar um sistema de apoio à decisão para diagnosticar precocemente doenças de difícil diagnóstico. Segundo os mesmos, no atendimento primário à saúde, médicos podem se deparar com casos em que doenças raras e perigosas,

mas com tratamento, podem, em estágios iniciais, ser confundidas com doenças comuns que, no entanto, não possuem tratamento. O grupo desenvolveu um sistema que analisa cada sintoma de uma doença, atribuindo uma medida M+ caso o mesmo tenha sido observado em um período de tempo e uma medida M- caso um sintoma esperado não tenha sido observado. Essas medidas são combinadas em um índice S, que é utilizado para o suporte à decisão [Innocent, John e Garibaldi 2001].

Outro exemplo de trabalho que apresenta relação com o proposto pelo presente artigo consiste no sistema de Grupos Relacionados de Diagnósticos (do inglês *Diagnosis Related Groups* – DRGs). Os DRGs estão relacionados à classificação de pacientes para instrumentalização da gestão hospitalar, tornando possível a mensuração e avaliação do desempenho dos hospitais [Noronha, Portela e Lebrão 2004] [Fetter 1991]. De acordo com Escrivão Junior [Escrivão Junior 2007], o conceito de agrupamento de casos de acordo com o perfil de recursos recebidos durante a internação parte do pressuposto de que grupos de doentes tenham atributos demográficos, diagnósticos e terapêuticos comuns que determinam as condutas médicas adotadas. Algumas variáveis como diagnóstico e procedimento principais, presença de complicações ou diagnósticos associados, outros procedimentos operatórios, idade e condição de saída da internação estão relacionados à classificação dos casos hospitalares entre os grupos presentes nos DRGs. O diagnóstico principal utilizado pelo sistema é baseado na Classificação Internacional de Doenças (CID-10).

Cenci e Heizle desenvolveram um sistema de informação hospitalar para classificação automática de pacientes através da complexidade assistencial aos mesmos. Eles consideram informações como nível de consciência, oxigenação, sinais vitais, nutrição e hidratação, mobilidade, locomoção, entre outros, para classificar pacientes em quatro grupos: (i) cuidados mínimos ou autocuidado; (ii) cuidados intermediários; (iii) cuidados semi-intensivos; e (iv) cuidados intensivos [Cenci e Heinzle 2002].

Macedo et al [Macedo et al 2007] realizam o pré-processamento de documentos a serem relacionados por serviços de criação automática de ligações e aplicam categorização usando centróides a um contexto de informações médicas. Os trabalhos encontrados na literatura são, de alguma maneira, análogos ao proposto pelos autores neste artigo; porém não apresentam um contexto muito semelhante, visto que a definição de graus de vigilâncias em atenção básica a saúde é um diferencial do grupo de pesquisa e as propostas dos módulos classificadores estão diretamente relacionadas aos GVs.

6. Conclusão

Neste trabalho, foi proposto o uso de *relevance feedback* para o desenvolvimento de um terceiro módulo do sistema GV-Automático. Para avaliar os módulos, foram realizados experimentos com diversas combinações de valores para os parâmetros utilizados pelo sistema. Acredita-se que os resultados dos módulos VPGV e RNGV possam ser melhorados através da padronização de atributos de acordo com a Classificação Internacional de Doenças e a UMLS, que consiste em uma coleção de referências cruzadas de dados médicos e uma série de fontes de conhecimento, que pretende auxiliar a troca de informações no campo da Saúde. O sistema de DRGs utiliza a CID-10 como base para codificar seu atributo *diagnóstico principal*. Como a classificação do GV também se baseia em diagnósticos chegou-se à conclusão de que a utilização da CID-10 poderia ajudar a padronizar e agrupar Impressões Diagnósticas. Isso diminuiria o número de atributos e valores considerados pelos módulos VPGV e RNGV, resolvendo o problema

de alta dimensionalidade com dados esparsos enfrentado pelos classificadores. Atividades nesse sentido estão sendo desenvolvidas e resultados iniciais comprovam que podem trazer grandes benefícios aos resultados finais desses classificadores. Acredita-se que os resultados do módulo RFCatGV podem ser otimizados através da utilização de conceitos de ontologias, mineração de textos e processamento de linguagem natural.

7. Agradecimentos.

À FAPESP pelo financiamento. A Evandro Ruiz, Thiago da Costa, Joaquim Felipe e a equipe do CMSC Vila Lobato pela participação no desenvolvimento do SI-VilaLobato e do GV-automático. A Lucas Pellozo pela contribuição ao módulo RFCatGV.

Referências

- Baeza-Yates, R.; Ribeiro-Neto, B. *Modern Information Retrieval*. Addison Wesley, Jan 1999.
- Cenci, V.; Heinzle, R. “Sistema inteligente de classificação de pacientes”. In: *Anais do Congresso Brasileiro de Computação – II Workshop de Informática Aplicada a Saúde*, Itajaí, 2002.
- Costa, T. M.; Daneluzzi, J. C.; Panico, S. R. G.; Felipe, J. C. “Projeto de Dados de Sistema para Integração Longitudinal de Informações e Procedimentos em Centros Médicos”. In: *Anais do XI Congresso Brasileiro de Informática em Saúde*. Campos de Jordão, 2008.
- Escrivão Junior, A. “Uso da informação na gestão de hospitais públicos”. In: *Ciência e Saúde Coletiva*, 2007. v.12, n.003, p. 655-666.
- Fetter, R. B. “The DRG patient classification system – Background”. In: Fetter, R. B.; Brand, D. A.; D. Gamache (editors). *DRGs their design and development*. Ann Arbor: Health Administration Press, 1991. p.3-27 apud [Noronha, Portela e Lebrão 2004].
- Hersh, W. R. *Information Retrieval: A Health and Biomedical Perspective*. 2. ed. New York, NY: Springer, 2003 (Health Informatics Series).
- Innocent, P. R.; John, R. I.; Garibaldi, J. M. “The Fuzzy Medical Group in the Centre for Computational Intelligence”. In: *Artificial Intelligence in Medicine*, v. 21, n. 1, p. 163-170, 2001.
- Kohavi, R. A. “Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection”. In: *International Joint Conference on Artificial Intelligence (IJCAI)*, 1995.
- Macedo, A. A.; Guerrero, J. A. C.; Ruiz, E. E. S.; Pellozo, L. R. “Criação Automática de Hiperligações Semânticas a partir da Categorização Vetorial por Definição de Centróides”. In: *WebMedia 2007, 2007*, Gramado. *Anais do WebMedia 2007*, 2007.
- Noronha, M. F.; Portela, M. C.; Lebrão, M. L. “Potenciais usos dos AP-DRG para discriminar o perfil da assistência de unidades hospitalares”. In: *Cad. Saúde Pública*, Rio de Janeiro, 20 Sup 2:S242-S255, 2004.
- Panico, S. R. G. ED. *Indicadores NIPE 1997: Subsídios para políticas públicas municipais de saúde*. 1. ed. São Carlos: NIPE, 1998. v. 1. 243 p.
- Pollettini, J. T.; Tinos, R.; Panico, S. R. G.; Daneluzzi, J. C.; Macedo, A. A. “Classificação automática de pacientes para atendimento médico pediátrico multidisciplinar a partir do seu Grau de Vigilância”. In: *Anais do XXVIII Congresso da SBC. VIII Workshop de Informática Médica (WIM)*. Belém, 2008a.
- Rocchio, J. J. “Relevance feedback in information retrieval”. In: Salton, G. (Ed.), *The Smart Retrieval System – Experiments in Automatic Document Processing*, pp. 313 - 323. Englewood Cliffs, NJ, USA: Prentice Hall, Inc. 1971.
- Salles, R. F. *Análise de um programa de intervenção com bebês e famílias atendidas em unidades básicas de saúde – SUS*. 2001. 0 f. Dissertação (Mestrado em Educação Especial) - Universidade Federal de São Carlos. Orientador: Sylvia Panico.
- Witten, I. H.; Frank, E. *Data Mining: Practical machine learning tools and techniques*, 2nd Edition, Morgan Kaufmann, San Francisco, 2005.