

# Análise pela Lógica Difusa da Condição de Risco e Sinais Vitais para Atendimento em Unidade de Emergência

Elizabeth A. Nishio<sup>1</sup>, Milton Urrutia<sup>1</sup>, Ernesto Araujo<sup>1,2,3</sup>

<sup>1</sup> Departamento de Informática em Saúde (DIS), Universidade Federal de São Paulo (UNIFESP), Brasil

<sup>2</sup> Hospital Municipal Dr. José de Carvalho Florence, Brasil

<sup>3</sup> Laboratório de Integração e Teste (LIT), Instituto Nacional de Pesquisas Espaciais (INPE), Brasil

**Resumo** – A análise das relações dos sinais vitais com a classificação de risco em atendimento de um pronto socorro pelo uso de lógica difusa (*fuzzy logic*) é apresentada neste trabalho. A extração do conjunto de regras e das funções de pertinência que compõem o mapeamento difuso é realizada ao se utilizar dados reais, que são fornecidos por um hospital, em conjunto com o algoritmo Gath-Geva de agrupamento fixo. O objetivo principal é verificar a viabilidade de se representar sinais vitais humanos para admissão e atendimento em unidades de emergência de maneira automática ao mesmo tempo em que se busca determinar mecanismos para projetar sistemas de suporte a decisão para auxiliar especialistas nesta tarefa que, muitas vezes, envolvem condições críticas. Adicionalmente, pretende-se identificar possíveis características inerentes ou idiossincráticas quando empregando sinais vitais humanos experimentais. Desta forma, a lógica difusa vem a ser uma alternativa para gerar ou aprimorar um sistema de classificação de risco de pacientes considerando as possíveis variáveis envolvidas, as bases de conhecimentos, e as características locais neste processo por meio das bases de dados existentes.

**Palavras-chave:** Risco, Sinais Vitais, Pronto Socorro, Lógica difusa, Algoritmo Gath-Geva.

**Abstract** – The relationship of vital signals and risk classification in an emergency department by employing fuzzy logic is presented in this paper. The extraction of membership functions and the set of rules that comprise the fuzzy mapping is performed when using actual data, which are furnished by a hospital, in conjunction with the fixed clustering Gath-Geva algorithm. The main objective is to verify the feasibility of representing human vital signals during admission and treatment in emergency units in an automatic manner meanwhile it is desired to determine mechanisms for designing Decision Support Systems (DSS) for helping specialists in this task that mostly involve critical conditions. Moreover, it is intended to identify possible inherent or idiosyncratic characteristics when employing experimental human vital signals. In this way, the use of fuzzy logic becomes an alternative to generate or to improve a risk classification system of patients when taking into account the fundamental variables, the knowledge-base, and local characteristics in this process when using available databases.

**Key-words:** Risk, Vital Signals, Emergency Department, Fuzzy Logic, Gath-Geva Algorithm.

## Introdução

No Brasil, a maioria dos atendimentos de urgência e emergência ocorre em Pronto Socorros. O prognóstico do paciente crítico na urgência e emergência está diretamente relacionado com o tempo e presteza do atendimento médico. Todavia, a maioria destes atendimentos é realizada por serviços públicos que obedece, de forma geral, a uma ordem de chegada e não à prioridade de assistência. Pacientes com doenças em fase aguda requerem atendimento imediato e mediano e correm riscos maiores de sofrerem agravos ou retardos durante o processo do tratamento e, como tal, deveriam ser priorizados.

Considerando a importância do tempo do atendimento médico nos serviços de urgência e emergência, profissionais de diversos países

definiram critérios de classificação de risco em pacientes que requerem atendimento oportuno em unidades de emergência [1]. Estes critérios datam de 1920 e utilizam o conceito econômico da indústria que visa especificar processos e procedimentos que gerem um mecanismo mais eficiente. Assim, muitos sistemas de classificação do paciente (*Patient Classification System – PCS*) têm sido projetados e validados para responder à demanda de classificação de pacientes [2]. Estes sistemas são definidos em dois tipos O primeiro é o *protótipo* que está relacionado ao tipo subjetivo que emprega características de pacientes típicos. O segundo é o *fator* e está relacionado ao tipo objetivo que identifica uma ampla lista de tarefas que são ponderadas (ligado ao tempo) e que determina a classificação do paciente [1,2,3].

O Ministério da Saúde, no Brasil, recomenda a implantação de *Programa de*

*Acolhimento com Classificação de Risco em Prontos Socorros.* Este programa surgiu na Austrália, na década de 90, onde foram propostos 5 níveis de classificação de pacientes e associado ao tempo máximo que o paciente deve esperar para o atendimento médico. De acordo com este programa, o atendimento médico do nível 1 ao nível 5 deve variar em um intervalo de 120 minutos. Por sua vez, a escala canadense denominada *Canadian Triage and Acuity Scale* (CTAS) [4,5], apresenta definições e critérios clínicos mais completos para cada nível de classificação e também estabelece tempo máximo de espera para o atendimento médico para cada nível [6]. Todavia, a adoção de um PCS requer confiabilidade e validação para ser aplicado [2,3,7], já que as condições variam de local para local, profissional para profissional. Isto não é condição suficiente para que seja usado da mesma forma por todas as unidades clínicas [8] e, portanto, vai requerer uma validação local [9]. Um sistema de classificação do paciente foi validado no Brasil em 2002 [10]. É enfatizado ainda que este tipo de instrumento de avaliação deve ser ajustado para a realidade local juntamente com um consenso do grupo de profissionais enfermeiros da unidade clínica. Desta forma, o CTAS foi validado para o português e adaptado para as inerentes mudanças semânticas, culturais e conceituais [5]. Diante disto, o protocolo do Ministério da Saúde, relacionado ao *Projeto Humaniza SUS* [11], de 2004, utiliza-se da mesma lógica do modelo canadense. Todavia, varia daquele ao empregar categorias representadas por cor, e por utilizar 4 níveis: (i) vermelho para atendimento imediato, (ii) amarelo para mediato, (iii) verde para priorização possível e (iv) azul para atendimento por ordem de chegada. Estes projetos têm como objetivo priorizar o atendimento do paciente baseado em risco.

A classificação de risco logo após a chegada do paciente na unidade de atendimento é realizada pelo profissional enfermeiro através do preenchimento de uma ficha de atendimento. A classificação de risco se dá em 2,5 a 3 minutos aproximadamente, através de um diagnóstico sintomático, baseados em sinais vitais como, por exemplo, pressão arterial (PA), frequência cardíaca (FC), frequência respiratória (FR), temperatura (T), oximetria (OX), glicemia capilar (G), relato breve da história atual com sintomas (H) e, se necessário, exame complementar eletrocardiograma (ECG).

Os pacientes são classificados em quatro categorias de risco, sendo que cada categoria indica o tempo que o paciente deve ser atendido pelo médico. Neste cenário, o enfermeiro pode classificar em média 500 a 700 pacientes dia, onde incerteza e imprecisão na conduta classificatória é uma constante devido às

características inerentes deste tipo de informação.

A imprecisão e incerteza são os insumos da lógica difusa para produzir decisões [12,13] e tem sido utilizada em diversos campos da medicina [14] de maneira que representa uma ferramenta para estudar a classificação de risco de pacientes. Este trabalho visa estudar pelo uso da lógica difusa os sinais vitais considerados como uma variável da classificação de risco visa, ainda, investigar suas relação com a atual classificação de risco utilizada por um pronto socorro do município da Grande São Paulo.

## **Materiais e Método**

Foram coletados dados de classificação de condição de risco (R) e dados de sinais vitais: pressão sistólica (PS), pressão diastólica (PD), frequência cardíaca (FC), oximetria (X) e glicemia capilar (G) de pacientes para atendimento em pronto socorro no ano 2008. O pronto socorro se localiza no município da Grande São Paulo, realiza 14.000 atendimentos ao mês e o profissional enfermeiro faz a classificação de risco, tanto para adulto como infantil 24 horas/dia.

Para a extração das regras difusas e das funções de pertinência foi utilizado o algoritmo Gath-Geva baseado em agrupamento fixo [15,16]. O método GG foi escolhido por ser este um algoritmo cujas funções de pertinência assumem uma distribuição adaptativa e móvel visto que ele é limitado no número máximo de agrupamentos (clusters) a serem modelados dentro da base de dados e, por isto, obtém um número reduzido de regras. Os universos de discurso de entrada utilizados para construir os relacionamentos foram os sinais vitais e o universo de discurso de saída foi a condição de risco. O método de Gath-Geva é configurado para quatro agrupamentos (*clusters*) com funções de pertinência gaussianas. Quando empregando o termo  $A \in T$  na forma de gaussiana, a função de pertinência é representada pela dupla,  $(m, \sigma)$ , de acordo com a função  $\exp [ - (x-m)^2 / (2\sigma^2) ]$ , sendo  $m$  = média, e  $\sigma$  o desvio padrão, respectivamente, a posição central – i.e., seu núcleo – e a sua forma. A função de pertinência de saída é selecionada para ser singular (*singleton*). Finalmente, mas não menos importante, o operador de conjunção escolhido foi o mínimo.

## **Resultados**

A fim de se obter o modelo difuso através o algoritmo Gath-Geva (GG) foi utilizada uma amostra de 55 pacientes com dados para seis universos de discurso.


A base de conhecimento contém quatro regras como foi prefixado na configuração de treinamento e é dada na expressão (1).

- R<sub>1</sub>: Se PS é MF0 E PD é MF0 E FC é MF0 E ...  
E OX é MF0 e G é MF0 ENTÃO risco é MF0;
- R<sub>2</sub>: Se PS é MF1 E PD é MF1 E FC é MF1 E ...  
E OX é MF1 e G é MF1 ENTÃO risco é MF1;
- R<sub>3</sub>: Se PS é MF2 E PD é MF2 E FC é MF2 E ...  
E OX é MF2 e G é MF2 ENTÃO risco é MF2;
- R<sub>4</sub>: Se PS é MF3 E PD é MF3 E FC é MF3 E ...  
E OX é MF3 e G é MF3 ENTÃO risco é MF3;
- (1)


O particionamento dos universos de discurso de entrada pelas funções de pertinência gaussianas é mostrado nas Fig. de 1 a 5. Por sua vez, o particionamento do universo de discurso de

saída dada pela função de pertinência singular (*singleton*) é apresentado na Fig. 6. Os universos de discurso foram particionados nos seguintes intervalos: PS [90 240], PD [40 113], FC [41 197], OX [71 100], G [61 437] e R [1 4]. Os valores para o risco assumem as classificações de condições: espera, tardio, mediato, imediato.


As relações entre as variáveis de entrada e a saída são vistas nas Fig. 7 a 15. Visto que existem mais de duas variáveis de entrada para a mesma saída e diante da limitação do ser humana quanto à visão tridimensional, as relações são apresentadas com as entradas agrupadas duas-a-duas.




**Figura 1** – Partição do universo de discurso da pressão sistólica (PS).




**Figura 2** – Partição do universo de discurso da pressão diastólica (PD).




**Figura 3** – Partição do universo de discurso da frequência cardíaca (FC).



**Figura 4** – Partição do universo de discurso da oximetria (OX).



**Figura 5** – Partição do universo de discurso da glicemia capilar (G).




**Figura 6** – Partição do universo de discurso da condição de risco (R).

---

---

### Pressão Sistólica (PS)




**Figura 7** – Modelo de condição de risco medido pela PS versus FC.


---

---


### Pressão Diastólica (PD)




**Figura 10** – Modelo de condição de risco medido pela PD versus FC.




**Figura 8** – Modelo de condição de risco medido pela PS versus OX.



**Figura 11** – Modelo de condição de risco medido pela PD versus OX.



**Figura 9** – Modelo de condição de risco medido pela PS versus G.



**Figura 12** – Modelo de condição de risco medido pela PD versus G.

---

---

As bases de conhecimento em gráficos 3D para os modelos construídos com a pressão sistólica versus frequência cardíaca, oximetria e glicose capilar são dadas nas Fig. 7 a 9.

As bases de conhecimento em gráficos 3D para os modelos construídos com a pressão diastólica versus frequência cardíaca, oximetria e glicose capilar são apresentadas nas Fig. 10 a 12. As bases de conhecimento em gráficos 3D para os modelos construídos com a frequência cardíaca versus oximetria e glicose capilar são mostradas nas Fig. 13 a 14. A base de

conhecimento em gráfico 3D para o modelo construídos com a oximetria versus glicose capilar é vista na Fig. 15.

### Discussão e Conclusões

A modelagem difusa obtida pelo algoritmo Gath-Geva de agrupamento fixo permite a determinação e sintonia de quatro partições nos universo de discurso de entrada. Estas partições mostram uma forte superposição entre elas, sugerindo talvez que um menor número de regras

fosse possível de ser obtido. No entanto, o universo de saída é claramente diferenciado e inequivocamente traduzido na base de regras.

O conjunto de pares de gráficos mostrados, respectivamente, nas Fig. 7 e 10, Fig. 8 e 11, e Fig. 9 e 12, mostram resultados onde pode-se verificar que independente do tipo de pressão (sistólica ou diastólica) as superfícies formadas por OX, FC e G são equivalentes para a classificação do risco. Pode-se observar assim que para cada combinação entre os universos de entrada dispostos nas Fig. 7 a 15 a condição de risco descreve um valor diferente. Isto sustenta a importância que representam os sinais vitais em um sistema de classificação.

Atualmente, existe uma grande base de conhecimento na literatura a respeito dos PCS. Somando-se a isto o argumento que se devem considerar as necessidades locais para sua adoção, a lógica difusa associada a um algoritmo de treinamento pode vir a ser uma alternativa para análise da condição de risco e análise vitais em unidades de pronto socorro. Seria possível, então, integrar o conhecimento já descrito na literatura, o saber local e as bases de dados disponíveis para adaptar ou gerar novas maneiras de classificar o risco do paciente em uma unidade de emergência satisfazendo critérios regionais e globais simultaneamente. Desta maneira, é possível construir um sistema difuso de suporte a decisão (*Fuzzy Decision Support System – FDSS*) a fim de destinar oportunamente o cuidado necessário em cada caso de tratamento.

Atualmente, técnicas CTAS e JDT [7] funcionam como mecanismos de classificação de risco quando empregados sinais vitais e outras variáveis amplamente utilizadas em unidades de emergência (p.ex. hemorragia, entre outros). O especialista (a enfermeira ou técnico em enfermagem) pondera estes dados e faz uma classificação direta em relação ao tipo de atendimento. A valoração feita pelo profissional é em base de uma ponderação qualitativa do tempo de espera e com a necessidade do atendimento de quando o paciente deve ser atendido. Para isto, o profissional responde a perguntas em relação às variáveis de análise (sinal vital ou outra) e pelo uso de uma tabela aponta um índice que diz qual é a classificação de risco. Todavia, esta ponderação e índice final são construídos pela instituição não há um padrão. O uso da lógica difusa utilizado tanto na construção de um índice de classificação de risco quanto no projeto de um sistema de suporte a decisão permite mudar este paradigma. Seja através do conhecimento de especialistas, seja através de dados experimentais como realizado neste trabalho, é possível construir um mecanismo automático e representando a realidade que possa ser utilizado como ferramenta de suporte a profissionais e especialistas nesta tarefa de tomada de decisão que, muitas vezes, envolvem

condições críticas devido ao caráter do atendimento.

Se por um lado este trabalho alcançou seu objetivo primeiro de verificar a viabilidade de se empregar ferramentas de inteligência computacionais como um mecanismo auxiliar na análise de dados vitais em unidades de emergência; por outro mostrou que é possível identificar possíveis características inerentes ou idiossincráticas em sinais vitais humanos de maneira gráfica através de sinais vitais humanos experimentais.




Figura 13 – Modelo de condição de risco medido pela FC versus OX.




Figura 14 – Modelo de condição de risco medido pela FC versus G.




Figura 15 – Modelo de condição de risco medido pela FC versus OX.

Devido a inovadora característica dos resultados encontrados, não existe descrição similar na literatura quando relacionado à prática médica. Este potencial de ruptura de paradigmas deve, por isto mesmo, ser investigado com maior profundidade ao mesmo tempo que deve ser testado de maneira sistemática em unidades de emergência como um sistema de suporte a decisão para atendimento e indicação de tratamento em tempo real. Assim, trabalhos futuros visam estender esta análise através de teste de rastreamento de um padrão ouro dado pela prática – observações de classificação, p.ex., corretamente classificadas pela equipe clínica – com a classificação gerada pelo modelo proposto e com outras formas de classificação – p.ex. utilizando uma equipe clínica que utiliza essa outra classificação. Neste caso, as medidas a comparar seriam a sensibilidade e a precisão. Da mesma maneira, deve ser comparado às curvas ROC a fim de se verificar a capacidade de acerto.

## Referências

1. Connors AM. Patient classification system in a rural emergency department. *Accid Emerg Nurs*. 1994 Jan;2(1):7-20.
2. Williams S, Crouch R. Emergency department patient classification systems: A systematic review. *Accid Emerg Nurs*. 2006 Jul;14(3):160-70.
3. Butler WR. ED patient classification matrix: development and testing of one tool. *J Emerg Nurs*. 1986 Sep-Oct;12(5):279-85.
4. Australasian College for Emergency Medicine. Guidelines for implementation of the Australasian triage scale in Emergency departments. 2000.
5. Pires P. Tradução para o português e validação de instrumento para triagem em serviços de emergência: "Canadian Triage and Acuity Scale" (CTAS) Sao Paulo: USP; 2003.
6. Cooke MW, Jinks S. Does the Manchester triage system detect the critically ill? *J Accid Emerg Med*. 1999 May;16(3):179-81.
7. Crouch R, Williams S. Patient dependency in the emergency department (ED): reliability and validity of the Jones Dependency Tool (JDT). *Accid Emerg Nurs*. 2006 Oct;14(4):219-29.
8. Considine J, LeVasseur SA, Villanueva E. The Australasian Triage Scale: examining emergency department nurses' performance using computer and paper scenarios. *Ann Emerg Med*. 2004 Nov;44(5):516-23.
9. Goransson KE, Ehrenberg A, Ehnfors M. Triage in emergency departments: national survey. *J Clin Nurs*. 2005 Oct;14(9):1067-74.
10. Carmona LMP, YDM E. Sistema de Classificação de pacientes Aplicação de um instrumento validado. *Rev Esc Enferm USP*. 2002;36(1):42-9.
11. Ministério da Saúde. HumanizaSUS: acolhimento com avaliação e classificação de risco: um paradigma ético-estético no fazer em saúde. . Journal [serial on the Internet]. 2004 Date: Available from: [www.saude.gov.br](http://www.saude.gov.br).
12. Zadeh L. Fuzzy Logic. *Computer*. 1988;21(4):83-93.
13. Lee CC. Fuzzy logic in control systems: fuzzy logic controller. II. *Systems, Man and Cybernetics, IEEE Transactions on*. 1990;20(2):419-35.
14. Torres A, Nieto JJ. Fuzzy logic in medicine and bioinformatics. *J Biomed Biotechnol*. 2006;2006(2):91908.
15. Hasanzadeh RPR., Moradi MH, SHH S. Fuzzy Clustering to the Detection of Defects from Nondestructive Testing. 3rd International Conference: Sciences of electronic Technologies of Information and Telecommunications; 2005; Tunisia..
16. Gil-Garcia RJ, Badía JM. Algoritmos de Agrupamiento. Castellón: Departamento de Ingeniería y Ciencia de Computadores / Universidad Jaime I; 2002 Contract No.: Document Number].

## Contato

Elizabeth Akemi Nishio, [bethakemi@gmail.com](mailto:bethakemi@gmail.com).

Ernesto Araujo, Prof. Dr. [ernesto.araujo@unifesp.br](mailto:ernesto.araujo@unifesp.br)