



## Comunicação entre agentes de software especialistas em doenças cardíacas

Communication between software agents specializing in heart diseases

Comunicación entre agentes de software especializados en enfermedades del corazón

Vinícius Borges Martins<sup>1</sup>, Thiago Ferreira Dantas<sup>1</sup>, Cleo Zanella Billa<sup>2</sup>, Diana Francisca Adamatti<sup>2</sup>

### RESUMO

**Descritores:**

Cardiologistas; Mineração de dados; Tomada de decisões

**Objetivos:** Este artigo relata a construção de um Sistema Multiagente para a tomada de decisão sobre o estado cardíaco de pacientes, usando uma base de dados real. **Métodos:** O sistema foi implementado com dois cardiologistas principais (Médico e Doutor) e um especialista (Especialista), onde, se houver discordância entre os dois primeiros, o Especialista é chamado para ser feito o desempate. Foi utilizado o framework Jason (que une AgentSpeak-L e Java) para o sistema e o software Weka para a criação da árvore de decisão do agente Especialista. **Resultados:** Como resultado, o agente Médico (com 72% de acerto) obteve melhores resultados que o agente Doutor, onde o Especialista foi utilizado como o validador. **Conclusão:** O uso de Sistemas Multiagentes pode auxiliar no processo de tomada de decisão em sistemas de área da saúde.

### ABSTRACT

**Keywords:** Cardiologists; Data mining; Decision making

**Objectives:** This paper presents a Multiagent System to assist decision making on patients' heart state, using a real dataset. **Methods:** The system has two cardiologists (Physician and Doctor) and one expert (Specialist). If the Physician and Doctor Agents do not agree with each other, the Specialist agent is called to give a third opinion. We have used the Jason platform (which merge AgentSpeak-L and Java) for the system and the software Weka to generate the decision tree used by the Specialist. **Results:** As a result, the Physician (with 72% of accuracy) obtained better results than the Doctor. The Specialist was used as the validator. **Conclusion:** The use of Multiagent Systems can help in the decision-making process in healthcare systems.

### RESUMEN

**Descriptores:**

Cardiólogos; Minería de datos; Toma de decisiones

**Objetivos:** Este artículo informa sobre la construcción de un Sistema Multiagente para la toma de decisiones sobre el estado cardíaco de los pacientes, utilizando una base de datos real. **Métodos:** El sistema se implementa de tal manera que hay dos cardiólogos principales (Médico y Doctor) y un especialista (Especialista), donde, si hay desacuerdo entre los dos primeros, el Especialista es llamado para que sea el desempate. Utilizamos la plataforma Jason (que une AgentSpeak-L y Java) para el sistema y el software Weka para crear el árbol de decisión del agente experto. **Resultados:** Como resultado, el Agente Médico (con 72% correcto) obtuvo los mejores resultados entre los dos y el Experto fue validado como experto para la base. **Conclusión:** El uso de sistemas multiagente puede ayudar en el proceso de toma de decisiones en los sistemas de salud.

<sup>1</sup> Mestrando, Programa de Pós-Graduação em Computação, Universidade Federal do Rio Grande - PPGComp/FURG, Rio Grande (RS), Brasil.

<sup>2</sup> Professor do Centro de Ciências Computacionais, Universidade Federal do Rio Grande - C3/FURG, Rio Grande (RS), Brasil.

## INTRODUÇÃO

Ainda que computadores consigam executar tarefas consideradas difíceis e demoradas por seres humanos (como organizar, procurar e calcular), eles não são capazes de reconhecer rostos, fazer decisões de próximos passos e serem criativos. Ao menos, não sem a Inteligência Artificial (IA)<sup>(1)</sup>.

Na área da medicina, o uso de redes neurais (uma das áreas da IA) tem sido constantemente utilizada por diversos especialistas a fim de melhorarem seus diagnósticos<sup>(2)</sup>. Outra área da IA em crescimento no âmbito clínico é a de Sistemas Multiagente<sup>(3)</sup>.

Em um sistema multiagente a comunicação é muito importante devido a troca de informações para atingir um objetivo em conjunto<sup>(4)</sup>. Agentes, por sua vez, podem ser definidos como entidades de *software* que utilizam de técnicas para escolher, dentre as opções possíveis, as ações que melhor se aplicam para alcançar o objetivo especificado pelo usuário<sup>(5)</sup>.

Levando em consideração os conceitos abordados, desenvolveu-se um trabalho onde, com o uso da base de dados chamada *Heart Disease*, implementou-se um sistema no qual três cardiologistas atendem pacientes e definem seus diagnósticos sobre a saúde destes pacientes. O objetivo do trabalho foi a implementação da comunicação entre vários agentes, além da criação de regras de tomadas de decisão diferentes, a fim de verificar qual dos cardiologistas tinha o maior índice de acertos.

O artigo está dividido em seções, onde a Seção 2 apresenta a base teórica para a execução do trabalho; a Seção 3 expõe as ferramentas que foram utilizadas na implementação deste; a Seção 4 descreve as regras de cada agente; a Seção 5 ilustra os resultados obtidos com a execução da simulação; e, por fim, na Seção 6 conclui-se o texto e se apresentam as considerações finais.

## EMBASAMENTO TEÓRICO

Nesta seção será feita a apresentação do embasamento teórico para o desenvolvimento do projeto.

### Agentes e Comunicação

Um agente autônomo é um sistema existente inserido em um ambiente que interage com este ambiente ao longo do tempo, de modo a atingir suas metas e importar informações para futuras tomadas de decisões<sup>(6)</sup>. As principais diferenças entre um objeto padrão de programação e um agente são: os agentes tomam suas próprias decisões “porque querem”, têm comportamento reativo, proativo e social flexível, ou seja, podem mudar o modo como se comportam por eles próprios, e, por fim, tem suas próprias *threads* (linhas de execução), o que os fazem ter execuções independentes<sup>(7)</sup>.

Os agentes podem trabalhar sozinhos (de forma independente) ou em conjunto, formando os chamados Sistemas Multiagente (SMA). Dentro destes sistemas, os agentes podem ser homogêneos, onde todos agentes aprendem da mesma forma ou heterogêneos, onde cada agente aprende de uma forma diferente, mas, ainda assim,

trabalham assincronamente uns com os outros<sup>(8)</sup>. Os agentes inseridos em um sistema podem, ainda, tentar entrar em um acordo sobre uma decisão ou percepção.

Neste contexto, existe a teoria da argumentação, onde é considerado que os agentes não têm uma simples troca de mensagens, mas um engajamento real em conversas<sup>(9)</sup>. Um objetivo traçado ou uma tarefa de um agente orienta a conversa, que pode ser entendida como um protocolo pré-organizado ou um padrão de troca de mensagens.

Linguagens baseadas na teoria dos atos de fala são compostas por algumas performativas<sup>(10)</sup>. As performativas podem ser vistas como sentenças que, ao mesmo tempo descrevem e influenciam um ambiente.

Neste trabalho, foi proposto um diálogo entre o paciente e três cardiologistas, de modo a enviar de um para os outros (separadamente) as crenças sobre os atributos extraídos da base de dados.

### Doenças Cardíacas

Embora as taxas de morte por doenças cardiovasculares (DCV) tenham diminuído nas últimas décadas, estas ainda são a maior causa de morte em diversos países<sup>(11)</sup>.

No Brasil, estas doenças são a principal causa de morte na população, e apresentaram um aumento de incidência nos últimos anos<sup>(12)</sup>.

De acordo com a Federação Mundial do Coração (World Heart Federation), fatores como obesidade, estresse, histórico familiar, genética, sedentarismo, hipertensão, níveis alterados de HDL-colesterol, idade, diabetes e tabagismo são possíveis Fatores de Risco associados a DCV<sup>(13)</sup>.

Posto isto, as DCV também causam um prejuízo para o Estado através de custos diretos e indiretos. Em 2015, o gasto com internações decorrentes de DCV custou aproximadamente 5,1 bilhões aos cofres públicos, além de outros custos com remédios, dias de trabalho perdido e consultas<sup>(14)</sup>.

### Dataset

O *dataset* escolhido é de livre acesso e contém dados reais de pacientes (<https://archive.ics.uci.edu/ml/datasets/Heart+Disease>), criado por cinco institutos diferentes: Instituto Húngaro de Cardiologia, em Budapeste; Hospital Universitário de Zurique, na Suíça; Hospital Universitário de Basel, também na Suíça; e Veterans Affairs Medical Center em Long Beach e Fundação Clínica de Cleveland, nos Estados Unidos. O objetivo do trabalho foi criar um SMA com agentes com diferentes regras para previsão de doenças cardíacas, logo, escolheu-se um conjunto de dados já existente.

Este é composto por 303 instâncias e 76 atributos cada, incluindo o alvo (atributo que diz se está ou não com uma doença cardíaca - gabarito). Por motivos de simplificação, o número de atributos usado foi reduzido. O *dataset* original continha 76 atributos, mas só foram utilizados 9, porque os primeiros modelos de tomada de decisão dos agentes foram construídos sem o auxílio de alguma técnica automática de aprendizado. Os nove atributos utilizados são apresentados no Quadro 1.

Os dados obtidos na base de dados eram incompletos, ou seja, existiam dados faltantes no arquivo, porém, nos nove atributos escolhidos para a pesquisa não haviam valores faltantes, portanto, não houve necessidade de utilizar de procedimentos de pré-processamento dos dados para preenchimento de valores faltantes.

### Trabalhos Relacionados

Um exemplo do uso de sistemas multiagente no contexto da saúde apresenta uma ferramenta que objetiva facilitar o tratamento domiciliar de doenças, o que atualmente é um problema sério, pois vários fatores dependem da atenção do paciente como tomar remédio no horário certo, dieta e medição de indicadores de saúde. A ferramenta conta com 3 agentes<sup>(15)</sup>:

- Agregador: solicita dados dos sensores conforme a frequência necessária para um tratamento seguro, caso necessário enviar informações ao paciente com o procedimento a ser seguido. Consegue as informações necessárias para um procedimento seguro através do agente “mediador” ou através de sensores espalhados pela casa;

- Mediador: Recebe a solicitação do agregador e organiza a alocação de tarefas dos agentes “serviço de saúde”;

- Serviços de Saúde: Agentes que contém conhecimento sobre domínios específicos da medicina e aprendem com o feedback enviado pelo agregador.

Outro trabalho, que é voltado para a simulação de políticas públicas em hospitais de Angola através do uso de sistemas multiagente, a fim de verificar possíveis problemas e maneiras a aprimorá-las. Para isto, o sistema consta com um conjunto de agentes para cada tarefa<sup>(16)</sup>:

- Agente Utente: É um agente do tipo interface responsável pelas atualizações de dados, criar registros, e pedidos de diagnósticos feitos pelos utentes. Quando

recebe um pedido o agente utente deve passar as informações para o agente operador;

- Agente Prestador: Agente do tipo interface, representa clínicas e hospitais, é responsável por auxiliar o prestador de cuidados de saúde na interface da aplicação dentre outras tarefas relacionadas a pedidos de unidades de saúde;

- Agente Operador: É um agente responsável por receber pedidos do agente utente como atualização de dados do formulário e triagens;

- Agente coordenador: É o agente responsável pela coordenação do diagnóstico e encaminhamento no SIEMA (Sistema Integrado de Emergências Médicas Angolanas);

- Agente Diagnóstico: é um agente colaborativo responsável por implementar o algoritmo de diagnóstico dos utentes, para isto conta com os sintomas adquiridos pelo agente operador;

- Agente Encaminhamento: Recebe as informações das entidades hospitalares, administra as filas de espera e recebe do agente operador a localização e a identificação do utente e com base nisso o envia para a unidade hospitalar adequada.

Este trabalho teve resultados promissores mostrando várias possibilidades de melhorias e problemas encontrados nas políticas adotadas pelos hospitais, demonstrando o potencial de simulações em multiagente na área da saúde.

Outra pesquisa avaliou o uso de SMA para aperfeiçoar o monitoramento de pacientes com insuficiência cardíaca, especialmente aos que se encontram em casa, visto que essa medida reduz o índice de óbitos nesses pacientes. Neste modelo, os agentes são responsáveis por acessar dados médicos, se comunicar com outros agentes, analisar dados, processar dados médicos e pela tomada de decisões. Com base nisso, os agentes foram alimentados com fatores importantes no diagnóstico e tratamento de pacientes, a partir de dados da Europa, Estados Unidos da América e

**Quadro 1-** Atributos utilizados do *dataset*.

Atributo	Descrição	Tipo	Valores
Idade ( <i>Age</i> )	Contém a idade dos pacientes.	Numérico	Entre 29 e 77 anos
Sexo ( <i>Sex</i> )	Contém o sexo dos pacientes.	Categórico	0 = feminino 1 = masculino
Tipo de dor no peito ( <i>Chest Pain Type</i> )	Define o tipo de dor que o paciente estava sentindo.	Categórico	0 = angina típica 1 = angina atípica 2 = dor não causada pela angina 3 = assintomático
Pressão sistólica sanguínea quando descansado ( <i>Resting Blood Pressure Systolic</i> )	Atributo que diz o maior valor de pressão arterial alcançado durante a medida.	Numérico	Entre 94 e 200 mmHg
Colesterol ( <i>Serum Cholesterol</i> )	Total de colesterol encontrado no sangue.	Numérico	Entre 126 e 564 mg/dl
Glicemia ( <i>Fasting Blood Sugar</i> )	Medida de açúcar no sangue em mg/dl.	Categórico	0 = valores < 120 mg/dl 1 = valores > 120 mg/dl
Frequência cardíaca máxima alcançada ( <i>Maximum Heart Rate Achieved</i> )	Maior valor de frequência do coração alcançado durante a medida.	Numérico	Entre 71 e 202 batidas/minuto
Angina induzida pelo exercício ( <i>Exercise Induced Angina</i> )	Dor causada pela falta de oxigênio em algum músculo causado pelo exercício físico (angina).	Categórico	0 = não presente 1 = presente
Doença Cardíaca ( <i>Heart Disease</i> )	Atributo “alvo”.	Categórico	0 = não tem doença cardíaca 1 = tem doença cardíaca

da Austrália. O sistema proposto foi capaz de aprender e melhorar a si mesmo sendo útil como uma ferramenta auxiliar aos cardiologistas<sup>(17)</sup>.

## METODOLOGIAS E FERRAMENTAS

O trabalho foi desenvolvido, inicialmente, para prover um ambiente com trocas de mensagens entre um paciente aleatório do *dataset* e um médico com regras próprias, para decisão se o paciente está ou não doente.

Então usou-se, o *framework* Jason, que une as linguagens *AgentSpeak-L* e Java para o desenvolvimento multiagente. Na primeira versão do trabalho foram feitos dois cardiologistas (Doutor e Médico), cada um com uma regra de decisão, em dois programas diferentes.

Na segunda versão, além de juntar ambos os cardiologistas em um único programa, foi ainda incluído outro agente cardiologista: o Especialista. Nesse caso, realizou-se mineração de dados sobre a base de informações, utilizando o software Weka e o algoritmo J48 de árvores de decisão. Porém, o Especialista somente é utilizado se o Médico e o Doutor têm respostas divergentes.

Assim, o programa foi modificado para não mais consultar um único paciente do arquivo, mas todos. As decisões foram colocadas em um arquivo CSV (*Comma-Separated Values*), onde, além das três saídas dos agentes cardiologistas, foi incluída uma quarta coluna: o *target* do próprio *dataset* (ou seja, o gabarito), para ser feita a análise de acertos e erros dos agentes criados

### Jason

Jason é um *framework* de código aberto, utilizado no desenvolvimento de softwares baseados em agentes, utilizando a arquitetura cognitiva BDI (*Belief-Desire-Intentions*)<sup>(7)</sup>, atuando como um interpretador para uma versão estendida do *AgentSpeak-L*, com características customizáveis, além de prover uma linguagem de programação com semântica formalizada. O fluxo do programa está ilustrado na Figura 1.

Além de interpretar a linguagem *AgentSpeak-L*, o Jason ainda conta com outros recursos, como: é possível o tratamento de planos e comunicações baseadas em atos

de fala, suporta a criação de ambientes gráficos, especializar no Java funções de seleção de planos e de confiança, entre outros<sup>(18)</sup>.

### Weka

Weka (<https://www.cs.waikato.ac.nz/ml/weka/>) é um *software* que contém diversos algoritmos de mineração de dados, com objetivo de auxiliar a utilização de técnicas de aprendizado de máquina em diversas situações do mundo real. O *software* permite, ainda, o pré-processamento dos dados da base a ser utilizada, visualização dos resultados e contém em sua biblioteca algoritmos de classificação, regressão, agrupamento e associação.

No trabalho, ao agente Paciente receber duas respostas diferentes dos dois cardiologistas criados pelos autores, ele vai à procura de um terceiro agente, o Especialista. As regras deste agente foram definidas a partir do algoritmo J48 de árvore de decisão disponível no Weka. Este algoritmo é uma versão de código aberto para gerar uma árvore de decisão C4.5, que, levando em conta os atributos de um conjunto de dados, calcula a entropia relacionada com cada atributo para gerar cada nó da árvore. Entropia de X é o menor número de bits em média por símbolo necessário para representar os valores de X. Quanto menor a entropia, maior o ganho de informação. Após achar um nó, o algoritmo refaz o cálculo da entropia utilizando os outros atributos com base no nó anterior<sup>(19)</sup>.

O algoritmo foi utilizado de forma simples, com seus atributos nos valores pré-determinados pelo software (“binarySplits”: false; “confidenceFactor”: 0,25; “debug”: false; “minNumObj”: 2; “numFolds”: 3; “reducedErrorPruning”: false; “saveInstanceData”: false; “seed”: 1; “subtreeRaising”: true; “unpruned”: false; “useLaplace”: false) e utilizando cross-validation de 10 *folde*s para teste. A árvore resultante foi transcrita em *AgentSpeak-L* para a tomada de decisão do Especialista, e, assim como a matriz de confusão, é apresentada na Seção 4.

## DESENVOLVIMENTO DOS AGENTES

Nesta seção são descritas as regras que cada agente

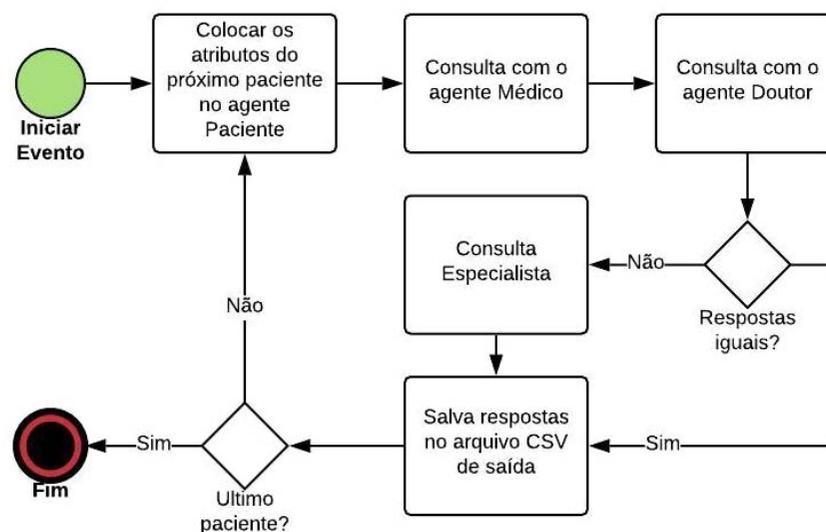


Figura 1 - Fluxo de execução do programa

cardiologista criado tem para a tomada de decisão sobre o estado de saúde dos pacientes.

Por ser uma arquitetura BDI, o paciente envia uma “mensagem” para os outros agentes (durante cada consulta) com as suas percepções de cada atributo do arquivo de entrada. Os cardiologistas recebem estes atributos como crenças, podendo então decidir com suas regras próprias o estado de saúde do paciente.

### Médico

A árvore de decisão, apresentada na Figura 2, sintetiza as regras definidas para o funcionamento do agente Médico. Esta árvore foi criada a partir de uma análise de forma empírica sobre o *dataset*, a fim de identificar quais dados tem maior importância para identificar se o paciente está saudável (valor 0) ou doente (valor 1).

Pela Figura 2 pode ser visto que o atributo com maior importância para o agente Médico é a prática de exercícios físicos. Seguida da dor no peito, caso o mesmo não pratique exercícios, ou da idade, se o paciente fizer exercícios. Conforme a idade do paciente sedentário aumenta, a presença de dor no peito ou o nível do colesterol são considerados, para garantir a precisão do diagnóstico. Já atributos como pressão sanguínea, batimentos cardíacos e açúcar no sangue não foram considerados.

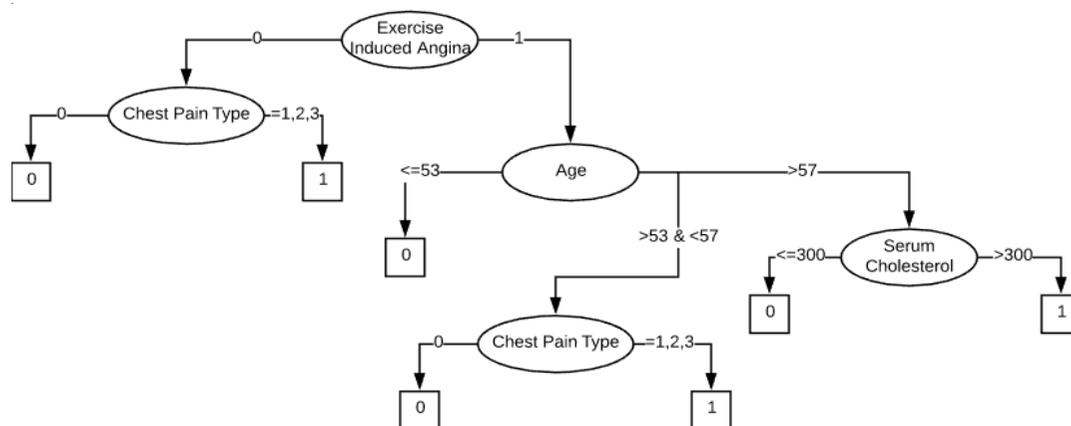


Figura 2 - Árvore de decisão pelo agente Médico

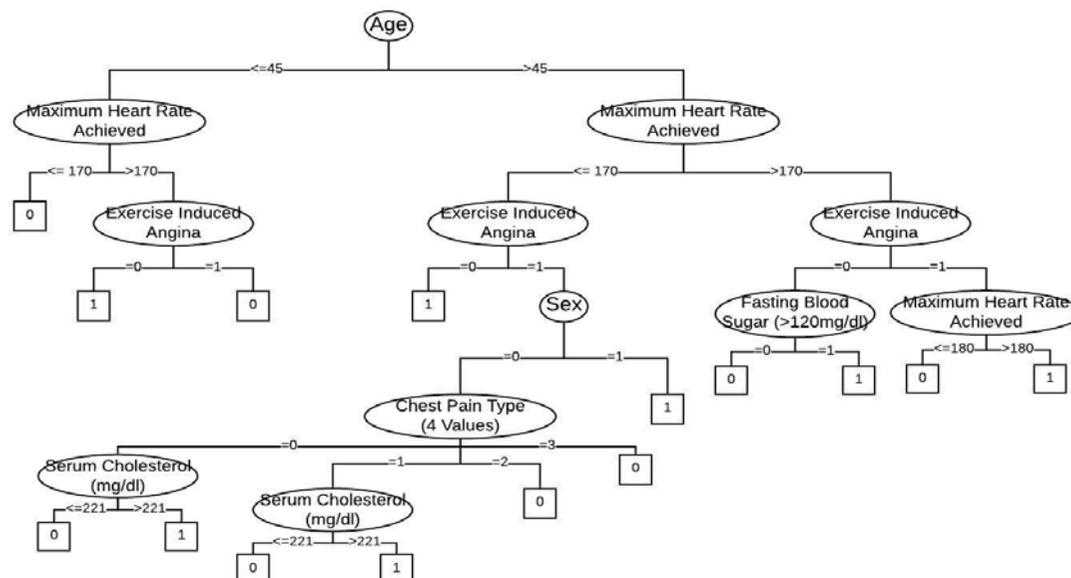


Figura 3 - Árvore de decisão utilizada pelo agente Doutor

### Doutor

O segundo agente cardiologista Doutor, também foi criado a partir de uma análise empírica do *dataset*.

Como mostrado na Figura 3 para este agente, o atributo que mais importa para a decisão é a idade. Logo após, vem a frequência máxima das batidas do coração. Porém, a pressão sistólica não foi levada em consideração, pois, por uma inferência empírica (ou seja, pelos valores no arquivo dos dados), essa não aparentava ter relação direta com doença cardíaca.

### Especialista

O agente Especialista, por sua vez, foi criado a partir do uso da ferramenta Weka, executando o algoritmo J48 de árvore de decisão para a descoberta de uma estratégia baseada em um algoritmo de mineração de dados, a ser usada onde houve divergência entre as decisões anteriores.

O resultado para este agente é apresentado na Figura 4, que mostra que o atributo com maior ganho de informação foi o que diz se o paciente teve angina induzida com exercício. Entretanto, não é levada em consideração a presença de colesterol ou máxima na frequência cardíaca. Aqui, pode-se observar também que a pressão sistólica somente importa em um caso específico: ausência de angina. Mulher com mais de 56 anos e sem dor no peito,

onde, se a pressão sistólica do sangue for menor ou igual a 134, ela tem uma doença cardíaca.

Ao executar o algoritmo da árvore no Weka, ele retorna a matriz de confusão da árvore dada, que informa a quantidade de vezes que a árvore acerta e erra a classificação, além de diferenciar para qual das classificações acertou ou errou (os chamados verdadeiros positivos/negativos e falsos positivos/negativos). No caso da árvore do Especialista, a matriz de confusão (Tabela 1) mostra que, dos 138 pacientes saudáveis, 93 ela classificou como “sadio” e 45 ela classificou como “doente”; no caso dos pacientes doentes, dos 165, 38 ela classificou como “sadio” e 127 ela classificou como “doente”. Ou seja, dos 303 pacientes, a árvore classificou corretamente 220 (~72.6% de acerto).

**Tabela 1** - Matriz de confusão obtida através do Weka com o Algoritmo de árvore de decisão J48.

Sadio	Doente	
93	45	Sadio
38	127	Doente

Entretanto, ao analisar-se a árvore retornada pelo Weka, percebeu-se que nem todos os pacientes foram enquadrados nos ramos da árvore. Por este motivo, a acurácia dada pelo Weka (72.6%) não foi a mesma retornada pelo agente na simulação deste trabalho (vide Seção 5). A ocorrência disso ocorreu pelo fato de que o Jason enquadrou todos os pacientes nas regras dadas.

**RESULTADOS E DISCUSSÕES**

A análise dos resultados está dividida em duas subseções. A primeira mostra a comparação dos diagnósticos entre os agentes Médico e Doutor. A segunda subseção, por sua vez, descreve a validação do agente Especialista. Para a validação, porém, foi necessária uma nova execução do programa, onde o Especialista foi chamado em todas as consultas pois nos testes anteriores era chamado apenas para desempatar.

**Comparação entre os agentes Médico e Doutor**

A Figura 5 mostra a relação de diagnósticos dados

pelos dois cardiologistas Médico e Doutor e o Gabarito da base de dados, ou seja, o valor real se os pacientes estavam ou não doentes. Dos 303 diagnósticos do Médico (número total de pacientes da base), 43 (14,19%) não foram iguais aos diagnósticos do Doutor e nem do Gabarito; 42 (13,46%) foram iguais aos do Doutor, mas diferentes do Gabarito; e 108 (35,64%) foram diferentes aos do Doutor, mas iguais ao Gabarito. Em contrapartida, o agente Doutor diagnosticou errado (ou seja, diferente do Gabarito) e diferente do Médico 108 (35,64%) pacientes; e 43 (13,46%) iguais ao Gabarito, mas contrários ao Médico. Ambos tiveram o diagnóstico certo (ao mesmo tempo) em 110 (36,30%) dos 303 pacientes.

As Tabelas 2 e 3 ilustram as matrizes de confusão dos agentes Médico e Doutor, respectivamente. Essas matrizes foram obtidas através dos resultados da simulação.

**Tabela 2** - Matriz de confusão do agente Médico.

Sadio	Doente	
103	35	Sadio
50	115	Doente

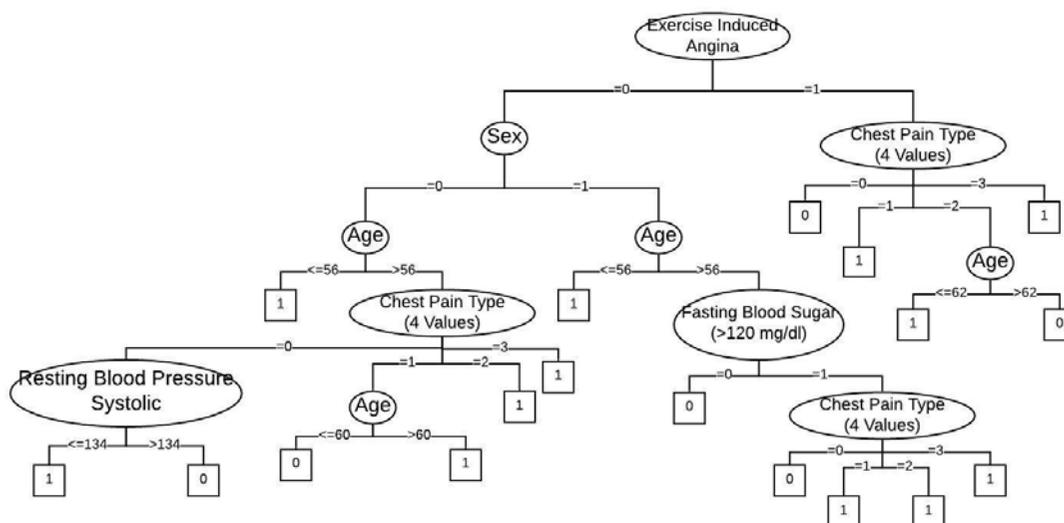
**Tabela 3** - Matriz de confusão do agente Doutor.

Sadio	Doente	
32	106	Sadio
44	121	Doente

O Médico, como mostrado na Tabela 2, acertou no diagnóstico de 103 (33,99%) pacientes saudáveis e 115 pacientes doentes, totalizando 218 (33,99%) diagnósticos corretos (~ 72% de taxa de acerto). Porém, classificou como “doente” 35 (11,55%) pacientes saudáveis e como “sadios” 50 (16,50%) pacientes doentes.

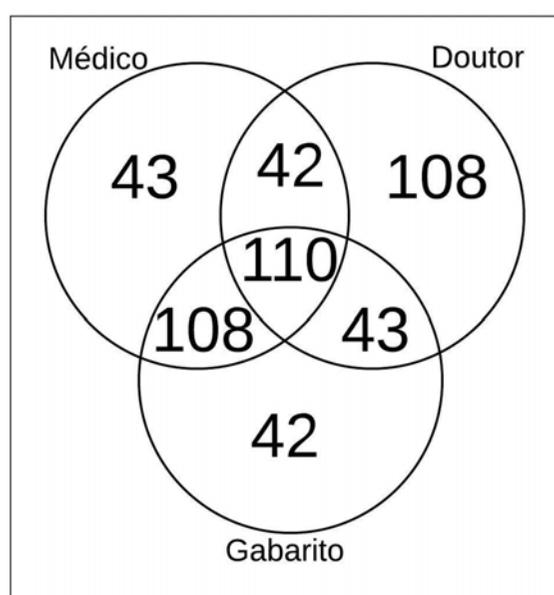
O Doutor, ilustrado na Tabela 3 teve uma taxa de acerto de 50%, sendo que 32 (10,56%) desses diagnósticos corretos foram para os pacientes saudáveis e 121 (39,93%) para pacientes doentes. Classificou como “sadio” 44 (14,52%) pacientes doentes e, como “doentes”, 106 (35%) pacientes saudáveis.

Na Tabela 4 percebe-se a diferença de diagnósticos de cada cardiologista. O agente Médico, por exemplo,



**Figura 4** - A árvore de decisão utilizada pelo agente especialista

dos 165 doentes reais da base de dados, ele resultou em 150 doentes. O Doutor, por sua vez, retornou 227 doentes. No âmbito da medicina, porém, por mais que o Médico tenha encontrado um número de doentes mais próximos do Gabarito que o Doutor, somente por esses valores, levando em consideração que 15 pessoas doentes seriam diagnosticadas como saudáveis pelo Médico, o Doutor seria a melhor escolha. Porém, ao se observar as matrizes de confusão apresentadas, o uso do agente Médico é o mais recomendado, pois os diagnósticos feitos por este são mais reais que o do Doutor, ou seja, por mais que o Doutor tenha diagnosticado menos falsos positivos, o que na área da saúde é mais aceitável que falsos negativos, o Médico teve muito mais acertos que ele no total.



**Figura 5** - Diagrama de Venn que mostra a relação de diagnósticos dos agentes Médico e Doutor com o Gabarito da Base.

**Tabela 4** - Quantidade de doentes diagnosticados pelos dois cardiologistas comparados a base de dados.

	Gabarito	Médico	Doutor
Quantidade	165	150	227

Viu-se que o agente Especialista foi chamado 151 (49,83%) vezes. Dentre estas, foi analisado que, como mostrado na Tabela 5, 110 vezes ele concordou com o Médico (sendo que 97 destes diagnósticos estava de acordo com o Gabarito) e somente em 41 das chamadas dele foi em concordância com o Doutor (sendo 31 destas iguais ao Gabarito). Ou seja, os agentes Médico e Doutor concordaram em 152 diagnósticos ~50% dos casos. E, nos 151 casos de discordância (completando os 303 pacientes) do Médico com o Doutor, o Especialista acertou ~84%.

#### Validação do agente Especialista

Entretanto, após a execução da simulação onde o Especialista foi chamado em todas as “consultas”, obteve-se os valores referentes à quantidade de “doentes” e

“sadios” diagnosticados pelo Especialista. A Tabela 6 mostra a quantidade de “doentes” classificados pelo Especialista somados à Tabela 4. Vê-se que o Especialista conseguiu o valor mais próximo ao Gabarito da base de dados, com apenas dois “doentes” a mais.

**Tabela 5** - Relação entre as vezes que foi chamado o Especialista com os diagnósticos iguais aos outros cardiologistas e o valor do Gabarito.

	Especialista	Especialista e Gabarito
Médico	110	97
Doutor	41	31
Total	151	128

**Tabela 6** - Quantidade de doentes diagnosticados pelos agentes Médico, Doutor e Especialista comparados à base de dados.

	Gabarito	Médico	Doutor	Especialista
Quantidade	165	150	227	167

A Tabela 7, porém, mostra a quantidade de diagnósticos iguais entre o Especialista com os outros dois cardiologistas e o Gabarito da base. Com o agente Médico, o Especialista teve concordância em 226 dos 303 diagnósticos; com o Doutor, em 157 dos pacientes; e, dos 303 diagnósticos dados, 253 (~83.5%) foram verdadeiros positivos, ou seja, de acordo com a base de dados (Gabarito).

**Tabela 7** - Quantidade de diagnósticos iguais entre os cardiologistas e o gabarito da base de dados

	Especialista-Médico	Especialista-Doutor	Especialista-Gabarito
Quantidade	226	157	253

Na Tabela 8, observa-se a quantidade de diagnósticos iguais e diferentes que os três cardiologistas tiveram juntos em relação à base de dados. Os três deram, juntos, o diagnóstico certo à 100 pacientes, ou seja, nessas 100 consultas, o diagnóstico dos três foram iguais ao Gabarito. Em contrapartida, os três deram falsos positivos ou negativos, juntos, em 16 “consultas”.

**Tabela 8** - Quantidade de diagnósticos iguais e diferentes que os três cardiologistas obtiveram no mesmo paciente.

	Iguais	Diferentes
Quantidade	100	16

A Tabela 9, por fim, apresenta a matriz de confusão extraída da simulação. Esta se apresenta diferente da Tabela 1, visto que o Weka não enquadrou todos os pacientes dentro de uma folha da árvore gerada por ele.

A árvore do Especialista, diferentemente da árvore dos outros cardiologistas, foi gerada com o uso de um algoritmo, ou seja, de uma forma metodológica. O algoritmo J48 que gerou esta árvore de decisão, por meio

do cálculo da entropia, mostrou que o atributo com mais ganho de informação, no caso deste *dataset*, foi o *Exercise Induced Angina* (como foi visto na Figura 4), o que significa que é o atributo que mais tem valor para a classificação da instância. Por exemplo, se todos os pacientes que tiveram angina durante o exercício tivessem problemas no coração e todos que não apresentaram angina não tivessem problemas no coração, somente o primeiro nó da árvore seria necessário para a classificação do paciente. Observando a árvore, porém, percebe-se que nem todos os atributos do conjunto de dados estão presentes, o que mostra que estes atributos ausentes não tiveram nenhum ganho de informação para a classificação buscada na construção da árvore com os parâmetros definidos de entrada (*Serum Cholesterol*, por exemplo).

**Tabela 9** - Matriz de confusão obtida através dos resultados da simulação

Sadio	Doente	
112	26	Sadio
24	141	Doente

## CONCLUSÃO

Sistemas Multiagente é uma área interdisciplinar que vêm aumentando sua atuação na área da saúde. Uma das aplicações de SMA dentro desta área pode ser ajudar no diagnóstico de doenças de pacientes utilizando regras para auxílio na tomada de decisão.

Os dois agentes principais (Médico e Doutor) apresentados neste texto foram criados pelos autores para o trabalho de forma empírica. Ao juntar-se os dois em um único sistema, porém, viu-se a necessidade de algum outro agente para quando as decisões de ambos fossem

diferentes, sendo criado o agente Especialista.

Os resultados mostraram que o agente Médico foi o que mais acertou dos dois, onde conseguiu 218 diagnósticos verdadeiros positivos e verdadeiros negativos dos 303 pacientes, ou seja, ~72% dos casos. O agente Doutor, por sua vez, igualou somente 157 diagnósticos (~52%) ao Gabarito. O agente Especialista foi provado “especialista” com seus ~83% de acertos em diagnósticos (se chamado em todas as consultas). Sendo chamado somente quando ambos os outros dois discordavam, o Especialista acertou ~85% dos 151 diagnósticos, ou seja, 128 diagnósticos.

O agente Médico, por sua vez, mostrou-se melhor que o Doutor devido aos atributos escolhidos para a análise do paciente. Observou-se que a raiz da árvore do Médico se igualou a raiz da árvore do Especialista, o que, com base no algoritmo usado para a construção da árvore do último agente, é o atributo com o maior ganho de informação, ou seja, com menor entropia na base de dados. Deste modo, pela raiz da árvore do Doutor ser outro atributo, ele obteve a menor taxa de acerto dos três.

Analisando a área da saúde, percebe-se que a computação pode ajudar profissionais da área da saúde a decidirem diagnósticos de pacientes. No caso no sistema proposto, vislumbra-se que o sistema multiagente poderia ir aprendendo com os erros cometidos (se corrigidos por alguém de fora) e se aperfeiçoando para diagnósticos cada vez mais fidedignos.

Como trabalhos futuros, pode-se considerar a inclusão de mais cardiologistas no sistema, deixando o paciente escolher por qual quer ser “atendido”. Pode ser implementado, também, agentes de saúde de outras áreas (como pediatra ou dermatologista, por exemplo), onde o paciente “escolheria”, no sistema, o médico que gostaria de ir.

## REFERÊNCIAS

1. Millington I. AI for games. CRC Press: Boca Raton, Florida, USA; 2019. 983p.
2. Lobo C. Inteligência artificial e medicina. Rev Bras Educ Med. 2017; 41(2):185-93.
3. Vicari RM, Flores CD, Silvestre AM, Seixas LJ, Ladeira M, Coelho H. A multi-agent intelligent environment for medical knowledge. Artif Intell Med. 2003 Mar; 27(3):335-66.
4. Frozza R. Simula: ambiente para desenvolvimento de sistemas multiagente reativos [dissertação]. Porto Alegre: Universidade Federal do Rio Grande do Sul. Instituto de Informática. Curso de Pós-Graduação em Ciência da Computação; 1997.
5. Moreno A. Medical applications of multi-agent systems. In: Computer Science and Mathematics Department. University of Rovira, Spain; 2003. (Palestra) Disponível em: <https://deim.urv.cat/~itaka/Xerrades/EUNITEworkshop.pdf>
6. Franklin S, Graesser A. Is it an agent, or just a program? A taxonomy for autonomous agents. Proceedings of the International Workshop on Agent Theories, Architectures and Languages. 1996 Aug 12. Berlin, Heidelberg: Springer; 1996. p. 21-35.
7. Wooldridge M. An introduction to multiagent systems. United Kingdom: John Wiley & Sons Ltd; 2009.
8. Lesser VR. Cooperative multiagent systems: a personal view of the state of the art. IEEE Transactions on knowledge and data engineering. 1999 Jan; 11(1):133-42.
9. Luck M, Marik V, Stepankova O, Trapp R, editors. Multi-Agent systems and applications. In: 9th ECCAI Advanced Course ACAI 2001 and Agent Link's 3rd European Agent Systems Summer School; 2001 July 2-13; Prague, Czech Republic: Springer Science & Business Media; 2001.
10. Searle JR. Speech acts. An essay in the philosophy of language. Cambridge: University Press; 1969.
11. Godoy MD, Lucena JM, Miquelin AR, Paiva FF, Oliveira DL, Augustin Junior JL, Chiaravalloti Neto F. Mortalidade por doenças cardiovasculares e níveis socioeconômicos na população de São José do Rio Preto, estado de São Paulo, Brasil. Arq Bras Cardiol. 2007 Feb;88(2):200-6.
12. Mansur AD, Favarato D, Souza MD, Avakian SD, Aldrighi JM, César LA, Ramires JA. Trends in death from circulatory diseases in Brazil between 1979 and 1996. Arq Bras Cardiol. 2001 Jun;76(6):504-10.
13. de Oliveira MA, Fagundes RL, Moreira EA, de Moraes Trindade EB, de Carvalho T. Relação de indicadores antropométricos com fatores de risco para doença cardiovascular. Arq Bras Cardiol. 2010 Mar;94(4):478-85.
14. Ministério da Saúde. Benefícios por incapacidade concedidos por classificação internacional de doenças (COD). DATAPREV - Empresa de Tecnologia e Informações da Previdência. Brasília: MS; 2016.
15. Martins AF. Sistema físico cibernético multiagente para monitoramento remoto de pacientes [tese]. Campina Grande, Paraíba: Universidade Federal de Campina Grande. Programa de Pós-Graduação em Engenharia Elétrica, Centro

- de Engenharia Elétrica e informática; 2015.
16. Calado MP. Serviço de emergência médica angolano: otimização utilizando sistemas multiagente [dissertação]. Lisboa, Portugal: Instituto Superior de Engenharia do Porto. Curso de Engenharia Electrotécnica e de Computadores; 2015.
  17. Mohammadzadeh N, Safdari R. Chronic heart failure follow-up management based on agent technology. *Healthc Inform Res.* 2015 Oct; 21(4):307-14.
  18. Hübner JF, Bordini RH, Vieira, R. Introdução ao desenvolvimento de sistemas multiagentes com Jason. XII Escola de Informática da SBC. 2004; 2:51-89.
  19. Larose DT, Larose CD. Decision trees. In: *Discovering knowledge in data: an introduction to data mining*, 2<sup>th</sup> ed. New Jersey: John Wiley & Sons; 2014. p.165-86.