

ALGORITMO INTELIGENTE APLICADO NA ÁREA DA SAÚDE: UM ESTUDO DE CASO EM ECG PARA PREDIÇÃO DE REGIÃO INFARTADA

Robinson Luís de Souza Alves

Mestre em Engenharia Elétrica e de Computação pela Universidade Federal do Rio Grande do Norte (UFRN), Natal, Brasil, in 2002, e é estudante de doutorado na UFRN, Atualmente é Professor Efetivo no departamento de informática do Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte, IFRN. Sua área de pesquisa está relacionada a aprendizado de máquina. E-mail: robinson.alves@ifrn.edu.br

Jorge Dantas de Melo

Doutor em informatique et automatique from Laboratoire d'Automatique et d'Analyses des Systèmes (LAAS) and Université Paul Sabatier, Toulouse, France, in 1990. Atualmente, ele é Professor no Departamento de Engenharia da Computação e Automação na Universidade Federal do Rio Grande do Norte (UFRN), Natal, Brasil. Sua área de pesquisa abrange o campo de sistemas inteligentes e algoritmos paralelos e distribuídos. E-mail:

jdmelo@dca.ufrn.br

Adrião Duarte Dória Neto

Doutor em eletrônica pela Ecole Nationale Supérieure d'Electrotechnique, d'Electronique, d'Informatique et d'Hydraulique de Toulouse (ENSEEIH), França, in 1989. Atualmente é Professor do Departamento Engenharia da Computação e Automação, UFRN. Sua área de pesquisa abrange inteligência computacional e processamento digital de sinais. E-mail:

adriao@dca.ufrn.br

Ricardo Alexandro de Medeiros Valentim

Doutor em Engenharia Elétrica e de Computação

Coordenador do Laboratório de Inovação Tecnológica em Saúde do Hospital Universitário Onfre Lopes, Professor do Departamento de Engenharia Biomédica da Universidade Federal do Rio Grande do Norte. E-mail: ricardo.valentim@ufrnet.br

Leila Raulino Câmara Cavalcanti

Graduanda em Engenharia Biomédica pela Universidade Federal do Rio Grande do Norte, Natal, Brasil, é aluna de iniciação científica do Laboratório de Inovação Tecnológica em Saúde do Hospital Universitário Onfre Lopes. E-mail: leila.rccavalcanti@bct.ect.ufrn.br

RESUMO

Nesse trabalho um novo algoritmo para o treinamento de redes ARTMAP é proposto. Um estudo de caso é aplicado a detecção da área de infarto do miocárdio através do uso de ECG (eletrocardiograma). Nesse algoritmo, o conceito de politopos foi utilizado para treinar redes do tipo ART com categorias de geometria não fixa. Com isso, foi possível melhorar a qualidade da generalização da rede neural. A rede ART consegue atingir excelentes resultados tanto para a generalização quanto no número de categorias recrutadas treinada com o novo algoritmo. Essas significativas melhoras ocorreram em relação a outras redes da família ART e também em relação a outros tipos de classificadores.

PALAVRAS-CHAVE: ECG, Infarto do miocárdio, Fuzzy ARTMAP (FAM), proliferação de categorias, Geometria das categorias, Teoria da Ressonância Adaptativa.

ALGORITHM APPLIED TO HEALTH: A CASE STUDY IN PREDICTION FOR INFARCTED REGION WITH THE USE OF ECG

ABSTRACT

In this paper a new algorithm for training networks ARTMAP is proposed. A case study is applied to the detection of myocardial infarction area through the use of ECG (electrocardiogram). In this algorithm, the concept was used to train polytopes ARTMAP networks having categories non-fixed geometry. Thus, it was possible to achieve excellent results for both the general and in the number of categories recruited trained with the new algorithm. These significant improvements have occurred in relation to other networks ART family and also for other types of neural networks.

KEYWORDS: ECG, Myocardial infarction, Fuzzy ARTMAP (FAM), Proliferation of categories, Geometry of categories, Adaptive Resonance Theory.

ALGORITMO INTELIGENTE APLICADO NA ÁREA DA SAÚDE: UM ESTUDO DE CASO EM ECG PARA PREDIÇÃO DE REGIÃO INFARTADA

INTRODUÇÃO

O avanço da medicina tem proporcionado o desenvolvimento de uma infinidade de equipamentos médicos cujo propósito tem sido a aquisição e monitoramento dos sinais vitais dos pacientes. Com isso, um grande volume de informações passou a estar presente nesses processos de cuidado dos pacientes, principalmente quando se trata dos internados em leitos hospitalares. Nesse ambiente, o controle e o gerenciamento dos dados sustentam a informação que servirá de base para a decisão ou diagnóstico e está se tornam-se cada vez mais complexo. Essa característica dificulta essencialmente a interpretação das informações oriundas de uma gama de dispositivos, sensores, sistema e equipamentos médicos, que por outro lado foram desenvolvidos sob a demanda de melhorar a qualidade da assistência ao paciente. Como esses aspectos, refletem efetivamente na qualidade da saúde da população, pois os pacientes passam agora a utiliza-se de diversos instrumentos que tem auxiliado a medicina, tais avanços são considerados fundamentais e de interesse comum a saúde. Um desses dispositivos é o ECG (Electrocardiogram) que tem uma característica não invasiva e é um auxiliar muito importante no diagnóstico de grande número de cardiopatias. Alinhada a essas demandas, aumenta a pesquisa aplicada ao uso de técnicas de Redes Neurais Artificiais [Begg et al, 2007] no auxílio do diagnóstico médico ([zhu, 2010], [Shin et al, 2000], [Barakat et al, 2010], [Van den Berghe, 2004] e [Tseng, 2008]). Tais pesquisas, fundamentam-se na melhoria do processo de interpretação dessa massa de informação gerada com resultados que podem auxiliar de forma significativa o diagnóstico de pacientes com problemas cardíacos.

Nesta perspectiva, foram identificadas algumas pesquisas relevantes que influenciaram fortemente o desenvolvimento deste trabalho. Valentim [Valentim et al, 2008] especificou, simulou e validou um protocolo de tempo real baseados em multiciclos temporais e endereçamento multicast para monitoramento de pacientes em ambiente hospitalar. Na mesma área que Valentim [Valentim et al, 2008], Varshney [Varshney, 2006] apresentaram alguns requisitos específicos para a realização de monitoramento de pacientes, propondo redes sem fio modelo orientado no processo de monitoramento. No contexto do processamentos de sinais vitais de pacientes utilizando sistemas inteligentes,

existem algumas pesquisas utilizam variações de Redes Neurais Artificiais, Lógica Fuzzy, Aprendizado de Máquina. Por exemplo, Rogal Jr [Rogal et al, 2005] usou uma Rede Neural Artificial do tipo ART2 para classificar grupos com arritmias cardíacas, batimentos cardíacos normais, contrações prematuras atrial (CPA) e contrações ventriculares prematuras (CVP). Jara [Jara et al, 2009] propôs um sistema de informação inteligente para detectar e prever doenças do miocárdio usando sinais vitais, para detectar sintomas através de um conjunto de regras e também realizar previsões de doenças por meio de algoritmos de cronobiologia. Neste mesmo sentido, Shin [Shin et al, 2000] desenvolveu uma pesquisa para monitoramento de pacientes via Web, utilizando lógica fuzzy como mecanismo de pré-inferências paradiagnósticos. Zhu [Zhu e Ying, 2010] desenvolveu sua pesquisa utilizando aprendizagem de máquina com o objetivo de criar um sistema detecção automática de anomalias no sangue ocasionada pelos níveis de glicose.

A revisão apresentada, permite identificar que o processo de monitoramento de pacientes tem como objeto principal o apoio ao diagnóstico médico por meio de sistema especialistas. Todavia, nenhum dos trabalhos estudados preocupou-se em auxiliar o processo de diagnóstico por meio de previsões, ou prognósticos do quadro clínico dos pacientes. Esse tipo de inferência representa uma ferramenta importante no processo de tratamento preventivo dos pacientes, pois permite antecipar medidas que poderão ser fundamentais para o sucesso no tratamento.

Diante do exposto, este artigo apresenta um classificador neural ARTMAP modificado na geometria das categorias para diagnósticos da região cardíaca de infarto em pacientes com sinais vitais monitorados através de ECG e compará-los com outra abordagem neural. O classificador desenvolvido é capaz de processar o ECG e melhorar a interpretação dos dados, apresentando a região infartada do coração que pode auxiliar a equipe médica quanto ao diagnóstico do pacientes (vale salientar que o presente trabalho se propõe a detectar os casos de infarto do miocárdio que promovem alterações no segmento ST de um ECG).

ECG e segmento ST: Infarto no coração

O eletrocardiograma (ECG) é o registro dos fenômenos elétricos que se originam durante a atividade cardíaca por meio de um aparelho denominado eletrocardiógrafo. O eletrocardiógrafo é um galvanômetro que mede pequenas intensidades de corrente que são captadas a partir de dois eletrodos dispostos em determinados pontos padrão do corpo humano. O ECG é um auxiliar muito importante no diagnóstico de grande número de cardiopatias [Schlant et al, 1992].

O infarto é uma lesão no tecido que causa a morte das células devido a isquemia (falta de oxigenação do tecido), ele é um fenômeno irreversível causando sérios danos ao paciente. Esse evento pode ocorrer nas mais diversas partes do corpo, o presente trabalho limita-se a um caso específico de infarto, o infarto no coração ou infarto do miocárdio (nome dado ao tecido do coração)[Thygesen et al, 2007].

A isquemia que leva ao infarto do miocárdio é causada pelo mau funcionamento da artéria coronária que é responsável pela oxigenação do miocárdio. Diversos fatores podem levar a esse evento como bloqueio ou obstrução da artéria através de trombo (coagulação de sangue no interior de um vaso sanguíneo) ou ateroma (placas formadas por lipídios nas paredes do vaso). A artéria coronária também pode estar sendo comprimida através de um tumor ou uma hérnia e por fim ela pode ter sido rompida através de um trauma.

A isquemia pode se manifestar ou não no sinal de ECG. Caso ela se manifeste, ela causa alteração na onda T ou mais comumente no segmento ST [Clifford, 2006]. Sua manifestação no segmento ST ocorre de maneira muito sutil, uma mudança só é considerada significativa quando ocorrer em pelo menos duas derivações.

Existem diversos trabalhos na área de inteligência artificial para a detecção de isquemia nos segmentos ST e conseqüentemente a prevenção do infarto do coração. Trabalhos envolvendo redes neurais [Srintzis et al, 1992], [Stamkopoulos et al, 1992], [Maglaveras et al, 1998a], [Maglaveras et al, 1998b] e [Silipo e Marchesi, 1998]. Nesta perspectiva, o presente artigo traz uma nova abordagem para detecção de infarto do coração, porque com base na literatura pesquisada, foi aplicado um conjunto de técnicas baseadas em sistemas inteligentes ainda não utilizadas para esse tipo de contexto. Neste trabalho, o modelo desenvolvido foi aplicado para predição da região do coração que está infartada. Esse elemento apresenta como uma ferramenta auxiliar no diagnóstico médico para casos onde o paciente está com suspeita de infarto, podendo contribuir na qualidade do tratamento dos pacientes, principalmente em casos de urgência e emergência.

Fuzzy ARTMAP (FAM)

A *fuzzy ARTMAP* [Carpenter et al, 1992] é uma rede neural que aprende a associar padrões de entrada e saída com valores difusos, ou seja, valores no intervalo $[0,1]$ e que é possível interpretar, essas associações, como medida de presença ou graus de associação de uma característica, presente em um padrão de entrada, com conjunto de membros *fuzzy* entre 0 e 1. A *fuzzy ARTMAP* (figura 1) inclui dois módulos (ART^a e o ART^b) que são responsáveis por clusterizar o espaço de entrada e o espaço de saída através da criação de categorias internas no espaço M-dimensional. Em um treinamento supervisionado, os padrões de entrada a são apresentados a rede ART^a e a resposta desejada b é apresentada a rede ART^b (mais detalhes na seção B - Treinamento). Para a rede ART^a tem-se que: a saída da camada F_1^a é X^a , sendo definida por $X^a = (x_1^a, \dots, x_{2M}^a)$; a saída da camada F_2^a é Y^a , sendo definida por $Y^a = (y_1^a, \dots, y_{2M}^a)$; $w_j^a = (w_{j1}^a, \dots, w_{j,2M}^a)$ representa os ganhos sinápticos de cada categoria j. Têm-se os mesmos elementos em ART^b . Por fim, as categorias internas são ligadas através do terceiro módulo o Mapfield.

A *fuzzy ARTMAP* pode trabalhar de forma supervisionada ou não. Em problemas de classificação de padrões supervisionados, os padrões de entrada são mapeados em uma classe de saída o que permite que a rede ART^b seja suprimida e esses padrões de saída sejam mapeados diretamente no módulo Mapfield [Kasuba, 1993]. Ou seja, não existe o processo de auto organização. Essa rede é chamada de *fuzzy ARTMAP simplificada*.

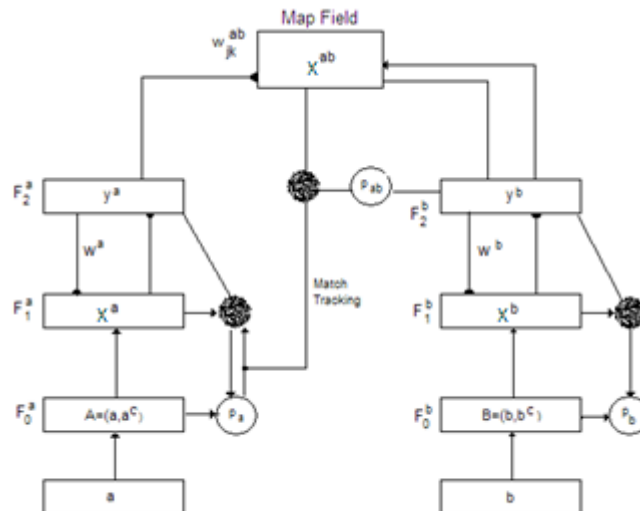


Figura 1 - Arquitetura *fuzzy* ARTMAP. A camada F_0^a é responsável por pré-processar o vetor a de tamanho M_a e transformá-lo em um vetor $A = (a, a^c)$ de tamanho $2M_a$. O mesmo é feito para ART^b e gerando o vetor $B = (b, b^c)$. As camadas F_1^a e F_1^b calculam a função de escolha de categoria e os neurônios das camadas F_2^a e F_2^b são acionados. Caso não haja correspondência entre o predito por ART^a e ART^b o mecanismo de *match tracking* é acionado elevando o valor do parâmetro de vigilância (ρ_a).

Treinamento

O primeiro passo do treinamento do *fuzzy* ARTMAP (Figura 1) é a apresentação de cada padrão de entrada para a camada F_0^a . A camada F_0^a é responsável por calcular a codificação em complemento do padrão apresentado à rede. Ou seja, o pré-processamento na camada F_0^a transforma o vetor de entrada a de tamanho M em um vetor $A = (a, a^c)$ de tamanho $2M$, onde $a^c = (1 - a)$ sendo definido como o complemento de a . O vetor de ganhos sinápticos é inicializado $w_{jk}^a = 1$, onde $j = 1, \dots, N^a$, representa as N^a categorias da rede ART^a e $k=1, \dots, 2M$ representa cada elemento que compõem os ganhos sinápticos de cada categoria. Além disso, os ganhos sinápticos do *Mapfield* são colocados também em 1 ($w_{jk}^{ab} = 1$). Após o processo de inicialização, o vetor A é enviado a camada F_1^a para que seja calculado a função de escolha de categoria $T_j(A)$ que pode ser definida como:

$$T_j(A) = \frac{|A \wedge w_j^a|}{\alpha + |w_j^a|}, \quad \text{equação (1)}$$

Onde o operador *fuzzy* E (\wedge) é definido por

$$(p \wedge q)_i \equiv \min(p_i, q_i) \quad \text{equação (2)}$$

Onde a norma $|\cdot|$ é definida por

$$|p| \equiv \sum_{i=1}^M |p_i| \quad \text{equação (3)}$$

Onde $\alpha > 0$ é um pequeno valor positivo. O processo de escolha é iniciado fazendo com que o maior valor para a função de escolha de categoria seja escolhido através do processo de competição (WTA – *winner take all*) onde o vencedor leva tudo:

$$T_{venc} = \max\{T_j\}, j = 1, \dots, N^a \quad \text{equação (4)}$$

Após a escolha da categoria vencedora a verificação do critério de similaridade ou condição de ressonância deve ser realizada na camada F_1^a :

$$\frac{|A^w_j^a|}{|A|} \geq \rho_a \quad \text{equação (5)}$$

onde, ρ_a é o parâmetro de vigilância. Se o teste da condição de ressonância falhar com a primeira categoria (vencedora), o mecanismo de *reset* é acionado e a categoria vencedora é inibida, então a segunda categoria (segundo lugar) é selecionada e o processo de verificação da condição de ressonância é refeito. Se não for possível encontrar uma categoria que passe no teste de similaridade para o padrão apresentado uma nova categoria pode ser criada e que inicialmente representa exclusivamente o padrão apresentado. Por outro lado, se a categoria promove uma ressonância com o padrão apresentado o processo de aprendizagem é acionado:

$$w_j^a(n+1) = (1 - \beta)w_j^a(n) + \beta (A^w_j^a(n)) \quad \text{equação (6)}$$

onde $0 \leq \beta \leq 1$ é a taxa de aprendizado. Um procedimento similar é realizado em ART^b , gerando N^b categorias que serão associadas às categorias de ART^a através do *mapfield* que é responsável por manter a associação de predição entre as categorias das duas redes ART^a e ART^b . Esse módulo implementa o mecanismo de *Match-Tracking* que promove um aumento do parâmetro de vigilância $\rho_a = |A^w_j^a|/|A| + \delta$ em resposta a uma associação incorreta entre categorias das redes ART^a e ART^b . O processo de treinamento termina quando as mudanças nos ganhos sinápticos permanecem inalteradas durante uma época de treinamento (uma época compreende a apresentação de todos os padrões a rede) ou quando um número máximo de iterações é alcançado.

Um aspecto interessante a ser notado no algoritmo do *fuzzy ARTMAP* é que quando duas categorias obtêm um valor de ativação para um dado padrão a categoria com menor hipercaixa será aquela que ficará responsável por representá-lo.

Método

Considerando a necessidade de classificação para processamento de dados relativos ao ECG foi aplicado um método de extração de características [Grünbaum, 2003], Além disso, uma nova arquitetura neural que melhora de forma significativa a qualidade da generalização é proposta. Essa nova arquitetura consegue ótimos resultados na classificação de padrões como será visto na seção de resultados. O método proposto inicia-se com a detecção do complexo QRS no sinal amostrado. Após determinar o local do complexo QRS no sinal de ECG, localiza-se o segmento ST e o segmento PR. A partir da localização do complexo QRS, do segmento ST e do segmento PR, pode-se calcular o desvio do segmento ST:

$$\hat{a}_y^{st} = \frac{(\sum_{x=1}^{N^x} |p_{x,y} - \hat{p}_{x,y}|)}{N^x} \quad \text{equação (7)}$$

onde, \mathcal{X} representa \mathcal{X} -ésimo padrão do ECG, \mathcal{Y} representa o \mathcal{Y} -ésimo canal, $p_{x,y}$ e $\hat{p}_{x,y}$ representam o \mathcal{X} -ésimo ponto indicativo do segmento PR e ST, respectivamente, no canal \mathcal{Y} e N^x representa o número de padrões do ECG. Ou seja, para cada canal do ECG é calculado a elevação ou depressão para o sinal de ECG especificamente no segmento ST em relação ao segmento PR. Com isso, é possível determinar se o ECG de um dado paciente tem um indicativo de infarto, bastando ter dois canais com valores alterados. Após a extração das características dos \mathcal{Y} canais do ECG, a rede neural é então treinada para determinar qual o local da ocorrência infarto. Foram elencadas três possibilidades de locais para o infarto do miocárdio: inferior, superior e lateral. Nesse trabalho foram utilizados ECG com 12 canais para o problema de detecção de infarto do miocárdio. Nesse sentido, a rede neural foi alimentada com 12 entradas (uma para cada canal) e cada entrada dessa representa a média de um canal para o sinal amostrado. Por exemplo, com um sinal de ECG de um paciente com 12 canais de 30 segundos, tem-se 12 entradas para a rede sendo a primeira entrada representando a média da amplitude do segmento ST para os 30 segundos de monitoramento do canal 1, a segunda entrada representando a média da amplitude do segmento ST para os 30 segundos de monitoramento do canal 2 e assim por diante para os 12 canais. A figura 2 mostra um diagrama de fluxo que mostra a metodologia de treinamento da rede neural empregada nesse trabalho.

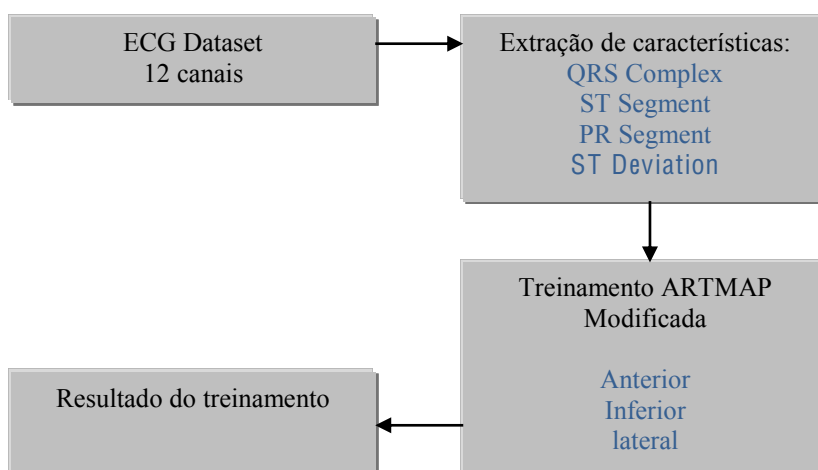


Figura 2-Diagrama de fluxo que mostra a metodologia de treinamento

A arquitetura proposta, ARTMAP Modificada, é baseada no uso de polítopos para substituir a geometria das categorias internas da rede neural e com isso conseguindo reduzir os problemas inerentes a redes ART [Carpenter e Grossberg, 1988]. A grande vantagem dessa abordagem é que as categorias internas podem se moldar de forma mais fácil e natural às classes de cada problema e com isso diminuir o número de categorias com um erro de classificação muito baixo. Com essa nova arquitetura de rede neural é possível representar de forma mais plástica e eficiente as classes construídas através de sinais biológicos. Os padrões de ECG representam medições biológicas e essas medições podem ter valores absolutos iguais, porém com significados distintos dependendo do paciente. Dessa forma, é fundamental usar uma técnica que não esteja limitada a limiares fixos, pois esses limiares fixos estão sujeitos a valores absolutos e não relativos a cada caso. Como exemplo, pode-se verificar que uma frequência cardíaca de 120 bpm pode ser normal ou

não. Nesse caso, uma criança recém nascida deve ter uma frequência cardíaca em torno de 120 bpm, porém num adulto isso representaria um problema. Em um sistema de classificação de padrões é necessário que esses problemas sejam equacionados de forma correta para o sucesso do mesmo. Em problemas simples como determinar a normalidade ou não de uma frequência cardíaca é fácil criar regras que modelem de forma satisfatória o problema apresentado. Porém em um problema de ordem mais complexa utilizando ECG é difícil determinar regras fixas pré-estabelecidas.

A geometria interna de uma rede do tipo *fuzzy* ARTMAP é uma hipercaixa no hiperespaço M-dimensional, sendo definida através dos ganhos sinápticos escrito na forma de codificação em complemento $w_j^a = (v_j, v_j^c)$, como visto anteriormente. Por outro lado, os ganhos sinápticos de uma rede ARTMAP Modificada não utilizam codificação em complemento e é substituído por politopos.




Figura 3 – Problema do Círculo no Quadrado. (a) Mapeamento feito com um conjunto de Politopos convexos sem sobreposição (adaptado de [Amorim et al, 2000]). (b) Mapeamento feito com sobreposição de politopos convexos.

Além da vantagem de se utilizar uma geometria mais flexível através do uso de politopos para substituir a geometria interna de cada categoria (como visto anteriormente), algumas outras alterações foram feitas na arquitetura do ARTMAP Modificada que contribuem para a diminuição do número de categorias recrutadas pela rede. Essas alterações incluem substituir o módulo *map-field* por um mapa probabilístico igual à PROBART [Marriott e Harrison, 1995] e utilizar um parâmetro de vigilância para cada categoria ρ_j^a como em BARTMAP [Verzi et al, 1998]. Outra alteração foi a introdução de um fator limitador máximo de quantidade de pontos em uma categoria, chamado de μ_{max} . Esse limite máximo de pontos por categoria é útil para fornecer compressão de código para a rede neural, evitando em alguns casos, que pontos desnecessários sejam incluídos nos ganhos sinápticos das categorias da rede, sem que haja um ganho em termos de generalização da mesma. Além disso, cada parâmetro de vigilância ρ_j^a é selecionado de forma adaptativa para cada categoria e incorporando um mecanismo de *reset* similar ao utilizado em μ ARTMAP [Sanchez et al, 2000]. Nesse caso, porém, não é utilizada a entropia, como em μ ARTMAP, e sim a probabilidade local pr_j de cada categoria e a probabilidade global Pr_j da rede (as probabilidades locais pr_j e globais Pr_j serão definidas na subseção A-Treinamento, nessa seção).

Diferentemente da rede PTAM [Amorim et al, 2000] que não permite a sobreposição de categorias, a rede ARTMAP Modificada permite preservar essa importante característica das redes *fuzzy* ARTMAP. A sobreposição de categorias é importante porque ela pode reduzir o número de categorias recrutadas pela rede. Um exemplo simples desse conceito é

o problema do círculo-no-quadrado. Nesse problema, com apenas dois polítopos convexos sobrepostos (figura 3b) é possível mapeá-lo com uma grande precisão. Por outro lado, se não for possível efetuar a sobreposição dos polítopos será necessário recrutar um número bem maior do que apenas dois polítopos convexos para obter um resultado satisfatório (figura 3a). Isso ocorre porque para mapear a classe no formato de quadrado atendendo a restrição imposta de não sobreposição, deve-se obrigatoriamente criar vários pequenos polítopos convexos que margeiam a classe no formato circular. A figura 3 ilustra esse conceito mostrando uma possível solução de treinamento com e sem sobreposição de categorias.

O treinamento inicia-se apresentando cada padrão à rede neural que calcula o campo de atividade u_j para as categorias (figura 4, linha 6). Na prática, percebe-se que o campo de atividade u_j é calculado através do volume quando o padrão de entrada está dentro de um ou mais de um polítopo ou categoria e é calculado através da menor distância quando o padrão de entrada não está dentro de nenhum polítopo. Após o campo de atividade ser calculado para cada categoria, faz-se uma escolha da categoria com maior campo de atividade da mesma forma que em *fuzzy ARTMAP*. Após a escolha da categoria vencedora a verificação do critério de similaridade ou condição de ressonância deve ser realizada (figura 4, linha 10). Para que um padrão entre em ressonância com alguma categoria j , ela deve estar no espaço de influência de categoria j definido pelo parâmetro de vigilância. Percebe-se que a menor distância entre o padrão de treinamento e as faces do polítopo são normalizadas pela maior distância possível no espaço euclidiano de ordem M . Uma vez passado no teste de ressonância, o cálculo de pr_{jk} – probabilidade da ocorrência da classe ϕ_j (existe N^a subconjuntos do espaço de entrada ϕ) em ART^a – é feito:

$$pr_{jk} = \frac{x_{jk}^{ab}}{|X_j^{ab}|} \quad \text{equação (8)}$$

onde k é a categoria vencedora em ART^b ou resposta desejada e j é a categoria vencedora em ART^a . Com pr_{jk} calculado pode-se verificar o teste de condição de erro. Ou seja, se $pr_{jk} < \varepsilon_{max}$ o padrão poderá ser mapeado pela categoria. Caso contrário, a probabilidade pr_{jk} é retornada ao estado anterior a inclusão do padrão e uma nova categoria é criada. Outro fator que pode levar a rejeição de um padrão é se a categoria já tiver atingido o limite máximo de padrões por categoria o μ_{max} . Neste caso, o padrão será rejeitado para essa categoria e uma outra será responsável por representar esse padrão. Ou seja, o mecanismo de *reset* é acionado quando um padrão é apresentado e o erro local da categoria selecionada para representar esse padrão ultrapassar o limiar máximo de erro local permitido ε_{max} ou a categoria atingiu o número máximo de padrões permitido.

Quando uma nova categoria j é recrutada, faz-se $\rho_j^a = \rho^a$, onde ρ^a é o padrão de vigilância padrão da rede e com ganhos sinápticos representados por um simplexo s^a (menor polítopo para a dimensão M) derivado do padrão a ser representado. Os padrões derivados são sintetizados através de uma constante γ que é adicionada ao padrão original (figura 4, linha 13).

Com isso, o novo simplexo é gerado com $M+1$ pontos e γ representa a variação em torno do padrão original utilizado para geração do simplexo. O *conv* calcula o *convexhull* do polítopo utilizando o algoritmo do QUICKHULL [Barber, 1996].

Por outro lado, se a condição de ressonância e a condição de erro forem satisfeitas a categoria selecionada será responsável por mapear o padrão apresentado à rede. Com isso, o padrão será incluído no conjunto de pontos do polítopo associado à categoria, o número de pontos associados a essa categoria será incrementado e um novo polítopo será calculado. Com isso, os ganhos sinápticos do neurônio j serão atualizados (figura 4, linha 24).

Uma vez que o padrão foi apresentado e aprendido por alguma categoria, ele é marcado como aprendido e não será reapresentado em uma época de treinamento posterior, mesma técnica utilizada que em [Sanchez et al, 2000]. Após cada época de treinamento dá-se início a avaliação *Off-line*. Nessa avaliação o *map-field off-line* é inicializado por $x'_{jk}{}^{ab} = 0, j = 1, \dots, N^a$ e $k = 1, \dots, N^b$, os dados são reapresentados e os ganhos sinápticos são atualizados de forma *off-line* em $x'_{jk}{}^{ab}$ e então a probabilidade local *off-line* pode ser calculada. Uma vez calculada a probabilidade local *off-line* para cada categoria, calcula-se o erro *off-line* de toda a rede. Verifica-se se o critério de convergência foi atingido e em caso afirmativo deve-se parar o treinamento. Caso contrário, a categoria com menor probabilidade local *off-line* (a categoria com maior erro) será removida, os padrões serão desmarcados, o parâmetro de vigilância base ρ^a será incrementado e os padrões estarão disponíveis para serem reapresentados na próxima época. O resumo do algoritmo do ARTMAP Modificada pode ser visto na figura 4.

```

1. O mapa probabilístico é inicializado  $p_{ji} = 0$ 
2. Enquanto  $epoca \leq numMáxEpoca$  faça
3.   % on-line
4.   Para cada padrão a faça
5.     Calcula o campo de atividade para cada categoria:
6.     
$$u_j = \begin{cases} v^{mc} - v_{p,p_j}^c, se \exists v_{p,p_j}^c \geq tol\_max \\ v^{mc} + (v^{mp} - v_j), caso\ contr\acute{a}rio \end{cases}$$

7.     Acha a categoria vencedora:
8.      $u_{venc} = \max\{u_j\}, j = 1, \dots, N$ 
9.     Verifica se reset é necessário através
10.     $\frac{-\max\{c_{ii}^j a_i - o_i^j\}}{\sqrt{M}} \geq \rho_j^a$ 
11.     Calcula o novo simplexo
12.     $a'_{ik} = \begin{cases} a_{ik} + \gamma, se i = k \\ a_{ik}, caso\ contr\acute{a}rio \end{cases}, i = 1, \dots, M, k = 1, \dots, M$ 
13.     $\varphi = \bigcup_{i=1}^M a'_i = \{a'_1, \dots, a'_M\}$ 
14.     $s^a = conv(a \cup \varphi)$ 
15.     Se novo neurônio recrutado
16.       Atualiza  $pr_{jk}$ 
17.       Se categoria não deve representar o padrão, ou seja, não passar nos testes:
18.        $pr_{jk} < \varepsilon\_max$ 
19.        $lim\_max\_pad\_categ \leq \mu\_max$ 
20.     então
21.     desfaz inclusão
22.     senão
23.       Atualiza ganhos sinápticos:
24.        $w_j^a(new) = conv(w_j^a(old) \cup s^a)$ 
25.     Senão
26.       Cria nova categoria através de um simplexo
27.        $w_j^a(new) = s^a$ 
28.     Fim se
29.   Fim para

```

```

30.
31. % off-line
32.  $Pr_{ji} = 0$ 
33. Classifica todos os padrões calculando  $Pr_{ji}$ 
34. Se  $e' \leq E_{max}$  parar treinamento
35. A categoria com maior erro será removida
36. Os padrões serão desmarcados
37. O parâmetro de vigilância base  $\rho^a$  será incrementado
38. Fim enquanto

```

Figura 4 – Algoritmo ARTMAP Modificado

Resultados

Um estudo comparativo da performance método e arquitetura propostos foi realizado com o objetivo de demonstrar a sua eficácia na detecção da região infartada. Para isso, foi utilizado um conjunto de dados referencia em pesquisas dessa natureza o banco de dados The PTB Diagnostic ECG Database [Goldberger et al, 2000]. Esse banco de dados é composto por conjunto de sinas de ECG com 12 canais, sendo distribuído conforme Tabela 1.

Tabela 1 - distribuição do banco de dados The PTB Diagnostic ECG Database.

Diagnostic class	Number of subjects
Myocardial infarction	148
Cardiomyopathy/Heart failure	18
Bundle branch block	15
Dysrhythmia	14
Myocardial hypertrophy	7
Valvular heart disease	6
Myocarditis	4
Miscellaneous	4
Healthy controls	52

Especificamente para esse trabalho foram utilizados apenas os registros da primeira e última classe (Myocardial infarction e Healthy controls). Como essa pesquisa tem o objetivo de detectar a presença e a região em que ocorreu o infarto do miocárdio, as outras ocorrências foram retiradas. Para o presente trabalho foi utilizada a mesma estratégia que em [Shivajirao et al, 2010, Waseemet al, 2011], onde o *ten-fold cross validation scheme* foi utilizado. Assim, o conjunto de dados foi particionado em 10 partes; o treino ocorreu em nove partes e o teste ocorreu na parte restante. Esse procedimento foi repetido dez vezes alterando as partes para treino e teste.

Para esse trabalho a metodologia adotada é fazer a detecção da região do infarto. O resultado para o processamento leva em consideração as três classes:

- Pacientes com infarto do miocárdio na região anterior do coração;
- Pacientes com infarto do miocárdio na região inferior do coração;
- Pacientes com infarto do miocárdio na região lateral do coração.

A tabela 2 mostra o resultado de classificação para o treinamento do ECG levando em consideração pacientes somente com infarto do miocárdio e com três classes. Nela, pode-se ver que a rede ARTMAP Modificada obtém o melhor resultado. Já as redes MLP e FAM ficaram com desempenho inferior em todas as regiões. A figura 5, representa o comparativo da classificação das redes nas três regiões de infarto.

Tabela 2 – Resultados dos testes para o acerto no conjunto de testes com ARTMAP Modificada, Fuzzy ARTMAP e MLP.

Classificador/Região	Anterior	Inferior	Lateral
ARTMAP Modificada	75,34%	73,01%	49,93%
MLP	73,19%	59,27%	43,67%
FAM	71,44%	52,80%	47,20%




Figura 5 – Resultado dos testes para todas as redes e regiões de infarto

Análise geral dos resultados

Uma nova arquitetura, ARTMAP Modificada, e metodologia foram propostas e mostraram-se eficazes no auxílio em detectar a área de infarto do miocárdio, analisando apenas o sinal do ECG. Como foi visto nos experimentos realizados nesse artigo, a rede ARTMAP Modificada, conseguiu um bom resultado de classificação para os casos de infarto quando comparados com as outras redes. Nessa nova arquitetura a geometria interna das categorias da rede fuzzy ARTMAP foi alterada com o uso de politopos convexos, o que permitiu essa melhora em relação a outras redes. A ARTMAP Modificada ficou em primeiro lugar na classificação dos pacientes apresentados. Uma dificuldade da nova arquitetura é que há a necessidade de se determinar quatro parâmetros iniciais, ao passo que a MLP e fuzzy ARTMAP tem apenas um. Apesar disso, não houve grande dificuldade em ajustar esses parâmetros de forma empírica. Um outro ganho importante da utilização dessa arquitetura é a possibilidade de extrair regras, de forma fácil, do tipo se/senão a partir das categorias geradas pela rede ARTMAP Modificada, algo que é mais difícil de ser feito para arquiteturas como MLP. Essas regras podem ser extraídas e depois embarcadas em dispositivos da área médica, isso com um baixo custo computacional de execução, o que é atraente para área de sistema embarcado. Portanto, utilizar tais regras torna-se, portanto, muito menos custoso do que embarcar uma rede neural completa no dispositivo biomédico, por exemplo.

Um dos aspectos que podem ser explorados como perspectivas futuras são melhorar o desempenho quanto à detecção da região de infarto utilizando comitês de redes neurais. Esses comitês podem ser mais adequados a classificação de dados com classes sobrepostas, pois trabalham com informações de várias arquiteturas distintas, aproveitando as características de cada rede para melhorar a predição.

Agradecimentos

Ao Laboratório de Inovação Tecnológica em Saúde do Hospital Universitário Onofre Lopes e ao Laboratório de Sistemas Inteligentes do Departamento de Computação e Automação, ambos da Universidade Federal do Rio Grande do Norte, por terem viabilizado as condições necessárias ao desenvolvimento dessa pesquisa.

Referências

1. Zhu , Ying : Automatic detection of anomalies in blood glucose using a machine learning approach. In Information Reuse and Integration (IRI), 2010 IEEE International Conference on. Las Vegas, NV, USA; 2010:92-97.
2. Shin JW, Cha DY, Lee KJ, Yoon YR: The Web-based fuzzy patient monitor system. Engineering in Medicine and Biology Society 2000. Proceedings of the 22nd Annual International Conference of the IEEE 20102000, 2:1265-1266.
3. Barakat N, Bradley AP, Barakat MNH: Intelligible Support Vector Machines for Diagnosis of Diabetes Mellitus. Information Technology in Biomedicine, IEEE Transactions on, USA 2010, 14:1114-1120.
- 4 Begg R, Lai DTH, Palaniswami M: Computational Intelligence in Biomedical Engineering. 1st edition.CRC Press, Inc., Boca Raton, FL, USA; 2007.
5. Van den Berghe G: How does blood glucose control with insulin save lives in intensive care? The journal of Clinical Investigaton, Published in Volume 114, Issue 9, 2004.
6. Valentim, RAM, Brandão, GB, Guerreiro, AMG. Morais, Antonio, HF, Xavier, MA, Bezerra, HU: MP-HA:Multicycles Protocol for Hospital Automation over Multicast Addressing, 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 2008, 1498-1501.
7. Tseng , Vincent S, Chen , Lee-Cheng , Lee , Chao-Hui , Wu , Jin-Shang , Hsu , Yu-Chia : Development of a Vital Sign Data Mining System for Chronic Patient Monitoring, Complex, Intelligent and Software Intensive Systems, International Conference. International Conference on Complex, Intelligent and Software Intensive Systems 2008, 649-654.
8. Varshney U: Patient monitoring using infrastructure - oriented wireless LANs. International Journal of Electronic Healthcare, v. 2, Number 2/2006 2006, 149-163.
9. Jara AJ, Blaya FJ, Zamora MA, Skarmeta A: An ontology and rule based intelligent information system to detect and predict myocardial diseases. In Information Technology and Applications in Biomedicine.ITAB 2009, 9th International Conference on.Larnaca, Chipre; 2009:1-6.
10. Zhu , Ying : Automatic detection of anomalies in blood glucose using a machine learning approach. In Information Reuse and Integration (IRI), 2010 IEEE International Conference on. Las Vegas, NV, USA; 2010:92-97.
11. Rogal Jr, Sérgio R, Parais EC, Kaestner CAA, Figueredo MVM, Beckert Neto A: Agrupamento de Arritmias Cardíacas Utilizando ART2. In I Workshop sobre Algoritmos de Mineração de Dados. Uberlândia, MG, Brazil; 2005.

12. Schlant RC, Adolph RJ, DiMarco JP: Guidelines for electrocardiography. A report of the American College of Cardiology/American Heart Association Task Force on Assessment of Diagnostic and Therapeutic Cardiovascular Procedures (Committee on Electrocardiography). *J Am CollCardiol*. Mar 1 1992. 19(3):473-81. [Medline].
13. Thygesen, K., Alpert, J. S., White, H. D., Jaffe, A. S., Apple, F. S., Galvani, M., Katus, H, et. all: Universal definition of myocardial infarction. *Circulation*, 116(22), 2634-53. doi:10.1161/CIRCULATIONAHA.107.187397. 2007.
14. Clifford, G. D.; Azuaje, F.; McSharry, P. E: *Advanced Methods and Tools for ECG Data Analysis*. Norwood, Artech House, 2006.
15. Strintzis, M.G., et al., "Use of Neural Networks for Electrocardiogram (ECG) Feature Extraction and Classification," *Neural Network World*, Vol. 3–4, 1992, pp. 313–327.
16. Stamkopoulos, T., et all: One-Lead Ischemia Detection Using a New Backpropagation Algorithm and the European ST-T Database. *Proc. Computers in Cardiology*, Durham, NC, October 11–14, 1992, pp. 663–666.
17. Maglaveras, N., et all: ECG Processing Techniques Based on Neural Networks and Bidi-rectional Associative Memories. *Journal of Medical Engineering & Technology*, Vol. 22, No. 3, 1998a, pp. 106–111.
18. Maglaveras, N., et all: An Adaptive Backpropagation Neural Network for Real-Time Ischemia Episodes Detection: Development and Performance Analysis Using the European ST-T Database. *IEEE Trans. Biomed. Eng.*, Vol. 45, No. 7, 1998b, pp. 805–813.
19. Silipo, R., and C., Marchesi: Artificial Neural Networks for Automatic ECG Analysis. *IEEE Trans. on Signal Processing*, Vol. 46, No. 5, 1998, pp. 1417–1425.
20. Carpenter, G.A., Grossberg, S., Markuzon, N., Reynolds, J.H., & Rosen, D.B., Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps, *IEEE Transactions on Neural Networks*, 3, 698-713, 1992.
21. Carpenter G. A., Grossberg S., "The ART of adaptive pattern recognition by a self-organizing neural network," *Computer*, vol. 21, no. 3, pp. 77–88, 1988.
22. Kasuba T., "Simplified fuzzy ARTMAP," *AI Expert*, vol. 8, pp. 19–25, 1993.
23. Grünbaum B., "Convex Polytopes," 2nd edition (prepared by Volker Kaibel, Victor Klee, Günter Ziegler), Springer, 2003.
24. Marriott S. , Harrison R. F, "A modified fuzzy ARTMAP architecture for the approximation of noisy mappings," *Neural Netw.*, vol. 8, pp. 619–641, 1995.
25. Verzi, S. J. , Heileman G. L., Georgiopoulos M., and Healy M. J, "Boosted ARTMAP," *Proc. IEEE World Congr.Comput.Intell. /IEEE Int. Joint Conf. Neural Netw.*, 1998, pp. 396–401.
26. Sanchez E. G., Dimitriadis Y. A., Cano-Izquierdo J. M., Coronado J. L., "MicroARTMAP: Use of mutual information for category reduction in fuzzy ARTMAP," in *Proc. IEEE-INNS-ENNS Int. Joint Conf. Neural Netw.*, 2000, pp. 47–52.
27. Amorim G D, Fernández Delgado M, BarroAmeneiro S., Polytope ARTMAP: pattern classification without vigilance based on general geometry categories. *IEEE Transactions on Neural Networks*. 18(5):1306-25, 2007.

28. Barber, C.B., Dobkin, D.P., and Huhdanpaa, H.T., "The Quickhull algorithm for convex hulls," ACM Trans. on Mathematical Software, 22(4):469-483, Dec 1996, <http://www.qhull.org>
29. Shivajirao M. Jadhav, Sanjay L. Nalbalwar, Ashok A. Ghatol. ECG Arrhythmia Classification using Modular Neural Network Model, IEEE EMBS Conference on Biomedical Engineering & Sciences (IECBES), 2010.
30. Komal W, Awais J, Rashad R and Muddassar F. Using Evolutionary Algorithms for ECG Arrhythmia Detection and Classification. IEEE Seventh International Conference on Natural Computation, 2011