

# IDENTIFICAÇÃO DAS PATOLOGIAS CORONARIANAS HUMANAS ATRAVÉS DE ESPECTROSCOPIA RAMAN E PCA UTILIZANDO INTELIGÊNCIA ARTIFICIAL.

*Thiago Siqueira Pinto<sup>1</sup>, Oswaldo Luiz Bueno dos Santos Junior<sup>2</sup>,  
Luis Filipe Wiltgen Barbosa<sup>3</sup>, Landulfo Silveira Jr<sup>4</sup>.*

<sup>1,2,3,4</sup>FEAU/UNIVAP, Av. Shishima Hifume, 2911 – Urbanova

<sup>1</sup>thiagosp10@hotmail.com, <sup>2</sup>oswaldo-bueno@uol.com.br, <sup>3</sup>wiltgen@univap.br, <sup>4</sup>landulfo@univap.br

Neste será desenvolvido e treinado uma Rede Neural Artificial para o reconhecimento de patologias nas coronárias humanas utilizando a espectroscopia Raman e o PCA, com auxílio do MATLAB para o desenvolvimento da rede, com intuito de desenvolver uma técnica de análise em tempo real das amostras de tecido 'in vivo' com classificação do resultado em poucos segundos, aumentando a eficiência do resultado e o tempo para análise dos resultados do paciente.

**Palavras-chave:** Espectroscopia Raman, Análise do Componente Principal(PCA), Redes Neurais Artificiais.

**Área do Conhecimento:** Engenharias

## Introdução

Nesse trabalho será estudado, desenvolvido e treinado uma rede neural artificial no programa de computador MATLAB®, na análise de espectros Raman de amostras das carótidas Humanas, para a identificação de patologias pela rede neural utilizando PCA (Principal Components Analysis) para filtrar os espectros; Esse trabalho mostrara eficiência de uma rede neural artificial em conjunto com a espectroscopia Raman e a análise do componente principal (PCA) na identificação de tecidos coronários saudáveis e com alguma patologia; Assim sendo mostrando a eficiência da RNA no diagnóstico rápido e preciso para casos de identificação de tecidos.

Hoje em dia há um crescente interesse por métodos de análise que sejam específicos, confiáveis e não destrutivos, que possam ser usados no estudo de bens culturais. Principalmente o caráter não destrutivo de uma técnica é uma qualidade altamente prezada devido ao fato dos objetos em estudo freqüentemente serem únicos ou muito valiosos. A espectroscopia Raman vem sendo largamente empregada nesse tipo de investigação exatamente por contemplar esses três aspectos (OTERO; PORFIRIO, 2002).

A natureza da técnica permite que seja empregada tanto na investigação de compostos inorgânicos, como pigmentos e substratos, quanto de orgânicos, como resinas, corantes, aglutinantes etc.

Alem do que a área de Espectroscopia visando o diagnóstico de doenças é uma área em pleno desenvolvimento sendo que o reconhecimento de padrões insere-se dentro

desta área principalmente na busca de formas de identificação de características espectrais que diferenciem tecidos saudáveis dos tecidos com patologias; Estas características de identificação podem ser obtidas por técnicas estatísticas do tipo PCA, que identificam as variações principais no conjunto de espectros e podem ser associadas às variações histopatológicas (PINTO, 2005).

Redes neurais são formas biológicas ou artificiais que englobam um conjunto de elementos (neurônios) interconectados, formando uma rede de distribuição de sinais que tem como objetivo: armazenar, processar e transmitir sinais quando for solicitada (BARBOSA; 2003).

Os avanços na área de computação permitem criar através de linguagens de programação, redes neurais artificiais, dando origem a um novo segmento na área de Inteligência Artificial; estas redes são capazes de reconhecer informações e produzir respostas seguindo a teoria de aprendizagem cognitiva, se adaptando a mudanças de controle, classificação e processamento ao longo do tempo.

O neurônio artificial é a peça chave para a construção das redes neurais artificiais, sendo possível identificar três elementos básicos no modelo de um neurônio. A região de conexão entre as sinapses, que pode ter tanto valores positivos quanto negativos; região de junção das sinapses e a saída do sinal do neurônio, a qual varia em amplitude com relação à somatória dos sinais de entrada (XEREZ; 1996).

O neurônio artificial é então a representação matemática do neurônio biológico. Este é capaz de cumprir as funções básicas do neurônio


(receber, processar, transmitir sinais) (BARBOSA; 2003).

Nesse trabalho será analisado entorno de 100 amostras de espectros Raman de tecidos das coronárias humanas onde será feito nessa amostras o tratamento com o PCA, onde se escolhera os melhores espectros para serem utilizados como base de aprendizado para rede neural. Logo após disso será feito o teste com a rede neural com amostras de espectros com patologias conhecidas, caso o resultado seja positivo será realizada a segunda fase de teste onde seria aplicado o teste com amostra de espectros desconhecidos essa parte do teste seria a parte fundamental do trabalho, pois o nessa parte colocaria em teste o treinamento da rede neural,

## Metodologia

Um espectro Raman é obtido fazendo-se a luz monocromática de um laser incidir sobre a amostra que se quer estudar, a luz espalhada é dispersa por uma rede de difração no espectrômetro e suas componentes são recolhidas em um detector que converte a intensidade da luz em sinais elétricos que são interpretados em um computador na forma de um espectro Raman.

Os espectros que serão usados para esse trabalho foram obtidos de amostras de tecidos das carótidas humanas onde temos três tipos de definições, Normal, Aterosclerose, calcificado.



\*Figura 1 – Espectro Raman do tipo 'Normal' sem a técnica PCA.


A análise do componente principal é uma técnica estatística útil na aplicação de campos como o reconhecimento e compressão de dados, é uma técnica comum para achar padrões em dados com muitos pontos estatísticos.

A análise de componentes principais também pode ser usada para julgar a importância das próprias variáveis originais escolhidas, ou seja, as variáveis originais com maior peso (*loadings*) na combinação linear dos primeiros componentes principais são as mais importantes do ponto de vista estatístico.

Portanto, a tarefa de quem trabalha com estatística multivariada, consiste em interpretar a

distribuição dos pontos no gráfico de componentes principais e identificar as variáveis originais com maior peso na combinação linear das componentes principais mais importantes.

Assim sendo iremos aplicar o PCA nas amostras de espectros para extrair desses espectros padrões que ajudem a rede neural a identificar possíveis alterações nas amostras de tecidos da carótida humana.



\*Figura 2 – Espectro Raman do tipo 'Normal' após ser aplicado o PCA.

As Redes Neurais Artificiais podem ser aplicadas a diversos problemas da Bioinformática, que costumam envolver reconhecimento de padrões. Adequar-se aos casos onde há necessidade de manipulação de conhecimento impreciso; além de possibilitarem a construção de modelos a partir de exemplos depositados em bancos de dados. O modelo do neurônio artificial de McCulloch é bem simples, ele possui várias entradas  $X(n)$  com um peso associado a cada uma  $P(n)$ , alguns pesos com sinais excitatórios (+) e outros com sinais inibitórios (-).

De acordo com uma ponderação dos sinais de entrada, realizada pela função de ativação, o neurônio pode ser ativado, enviando um sinal de saída. Este sinal de saída será propagado de acordo com a topologia de interconexão da rede de neurônios.


Uma rede neural artificial é composta por várias unidades de processamento, cujo funcionamento é bastante simples. Essas unidades geralmente são conectadas por canais de comunicação que estão associados a determinados pesos. As unidades executam operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. O comportamento "inteligente" de uma rede neural artificial vem das interações entre as suas unidades de processamento.

O aprendizado geralmente ocorre através de ciclos iterativos de treinamento. Denomina-se ciclo uma apresentação de todos os  $N$  pares (entrada e saída) do conjunto de treinamento no processo de aprendizado.

"Backpropagation" é um algoritmo para treinamento de Redes multicamadas mais difundidas. Baseia-se no Aprendizado Supervisionado por Correção de Erros.

Propagação: Depois de apresentado o padrão de entrada, a resposta de uma unidade é propagada como entrada para as unidades na camada seguinte, até a camada de saída, onde foi obtida a resposta da rede e o erro é calculado; Retropropagação ("backpropagation"): Desde a camada de saída até a camada de entrada, são feitas alterações nos pesos sinápticos.

Durante a fase treinamento devemos apresentar um conjunto formado pelo par: entrada para a rede e valor desejado para resposta a entrada. A saída será comparada ao valor desejado e será computado o erro global da rede, que influenciará na correção dos pesos no passo de retropropagação. Apesar de não obter garantias que a rede forneça uma solução ótima para o problema, este processo é muito utilizado por apresentar uma boa solução para o treinamento de Multi - Camadas.



\*Figura 3 - Estrutura de uma rede neural do tipo 4-3-2(4 entradas, 3 neurônios na camada escondida, 2 neurônios de saída).

Para o desenvolvimento da rede neural artificial nesse trabalho esta sendo utilizado o programa MATLAB. Onde a rede esta sendo moldada para o fim de reconhecer e diferenciar os tipos de anomalias presentes nas amostras dos tecidos, esta sendo usado o algoritmo Backpropagation feedforward, pois é o melhor que se encaixa para essa aplicação com amostras com muitas variáveis.

Na rede Feedforward é apresentado um padrão a camada de entrada de rede, e o processo de treinamento é propagado através da rede indo de camada em camada até que o padrão seja reproduzido na saída.

Para uma aplicação pratica em RNA do tipo Backpropagation Feedforward deve-se utilizar o comando computacional do MATLAB®, conforme abaixo:


```
New = newff([ vetores de entrada] ,
[arquitetura da RNA] ,{Tipos de função de
transferência} 'Tipo de treinamento da RNA' )
```

Juntamente com os comandos de treinamento da rede que são:

```
net.trainParam.epochs - numero de interações.
```


```
net.trainParam.show - Números de passos
mostrados.
net.trainParam.goal - meta para o valor do erro
quadrático médio.
net=train(net,entrada,alvo) -inicio do treinamento.
net = init(net) - inicialização aleatória dos pesos e
Bias.
net.iw{1,1} - Pesos
net.b{1} - Bias
```

E o comando de saída da Rede Neural:  
Saída= sim(net,entrada) - Função da saída já treinada



\*Figura 4 – estrutura neural utilizada no MATLAB.

A Figura 4 mostra a entrada da rede neural com 669 linhas, com os pesos sinápticos e as Bias, e com a função de ativação do tipo de TANSIG(n), sendo umas das mais indicadas para casos onde se utiliza sinal não linear, e duas camadas de neurônios escondidas utilizando o tipo de treinamento BackPropagation Gradiente Descendente, e uma saída.



\*Figura 5 – Tipo de Função de ativação presente nesse Trabalho.

### Resultados

Após vários estudos se obteve a formula necessária para se obter os resultados mais satisfatórios para esse projeto a formula da rede no MATLAB® ficou dessa maneira:


```
net = newff([minmax(a)],[3 2],{'tansig' 'logsig'
'purelin'},'traingd');
Saída_inicial = sim(net,a);
net.trainParam.epochs = 3000;
net.trainParam.show = 50;
net.trainParam.goal = 0.002;
net= train(net,a,T);
net = init(net);
net.iw{1,1}
net.b{1}
Saída_final = sim(net,a);
```

Onde foi treinada a rede com três tipos de alvos possíveis um para cada caso de tipo de pele, com isso obteve uma rede para tecido normal, tecido com aterosclerose, tecido calcificado.


Com os inúmeros testes verificou-se que por se tratar de treinamento de rede você consegue calibrar a rede através das quantidades de interações e do erro quadrático. Assim é possível dar o ajuste fino a sua rede.

Com resultados satisfatórios demonstrando claramente que o treinamento foi bem sucedido.


Definindo bem as diferenças entre os espectros analisados assim separando bem uns dos outros.



\*Figura 6 – Espectro de saída da rede neural do tipo de tecido normal.



\*Figura 7 – Espectro de saída da rede neural do tipo de tecido aterosclerose.



\*Figura 8 – Espectro de saída da rede neural do tipo de tecido calcificado.

Nas Figuras acima apresentam os espectros de saídas das redes neurais, cada um dos espectros que saem da rede tem suas característica únicas sendo assim facilmente identificados uns dos outros.

## Conclusão

Após todos os ensaios realizados, com todos os treinos da rede se conclui que a rede teve seu treinamento satisfatório para a

identificação de patologias coronarianas utilizando a Rede Neural Artificiais.

Assim sendo possível continuar os teste com mais tipos de amostras espectrais, e começar a montar a automatização desse processo no Matlab, para que a rede possa ficar mais precisa e rápida viabilizando o seu uso em hospitais e clinicas.

## Referencias:

- OTERO, U.; PORFIRIO, E. Raman spectroscopy for diagnosis of calcification in human herat valves. 2002 – Dissertação (Mestrado em Eng<sup>a</sup> Biomédica) - Instituto de Pesquisa e Desenvolvimento, Universidade do Vale do Paraíba, 2002.
- PINTO, T.S., Identificação de tecido com Aterosclerose pelo método de Analise do Componente Principal. **IX INIC V EPG**, 2005.
- BARBOSA, L.F.W., Estudo de Sistema Inteligente para Controle de Posição do Plasma no Tokamak – ETE. 2003 - Tese (Doutorado em Eng<sup>a</sup> Eletrônica e Computação) ITA –INPE 2003.
- XEREZ, M.A.M. Redes Neurais Artificiais Introdução e Princípios de Neurocomputação. S. **Lógica em Redes Neurais**. 1. ed. Blumenau: Ed. Eko, 1996.
- SILVEIRA, L.JR., Universidade do Vale do Paraíba, Instituto de Pesquisa e Desenvolvimento. Disponível em: <http://www1.Univap.br/~landulfo/pesq3.htm>. Acesso em 5 de fev. 2007
- DE PAULA, A.R.JR.; SATHIAH, S. Raman spectroscopy for diagnosis of atherosclerosis: a rapid analysis using neural networks. **Medical Engineering & Physics**, V. 27, n. 3, p. 237-244, 2005.
- MATSUMOTO, E.Y. -MATLAB<sup>®</sup> 7 – Fundamentos. S. **Linguagem de Programação**. 2. ed. Rio de Janeiro: Ed. Érica, 2004.