

# Análise de Imagens Médicas através de Sistemas Computacionais Inteligentes para Apoio ao Diagnóstico Clínico

**Anderson Alvarenga de Moura Meneses**  
COPPE/Universidade Federal do Rio de Janeiro, Caixa  
Postal 68509, 21941-972, Rio de Janeiro, RJ, Brasil  
FUNEMAC/FeMASS (Fundação Educacional de Macaé/  
Faculdade Professor Miguel Ângelo da Silva Santos)  
USS (Universidade Severino Sombra)  
[ameneses@imp.ufrj.br](mailto:ameneses@imp.ufrj.br)

**Christiano Jorge Gomes Pinheiro**  
COPPE/UFRJ e UERJ  
[cpinheiro@con.ufrj.br](mailto:cpinheiro@con.ufrj.br)

**Onair José Laudelino Valente**  
FUNEMAC/FeMASS  
[valenteonair@gmail.com](mailto:valenteonair@gmail.com)

**Tarcísio Nunes Cardoso**  
FUNEMAC/FeMASS  
[darkcisio@gmail.com](mailto:darkcisio@gmail.com)

**João Victor Barbosa Alves**  
FUNEMAC/FeMASS  
[joao.victor.mecatronica@gmail.com](mailto:joao.victor.mecatronica@gmail.com)

**Roberto Schirru**  
COPPE/UFRJ  
[schirru@imp.ufrj.br](mailto:schirru@imp.ufrj.br)

**Regina Cely Barroso**  
UERJ  
[cely\\_barroso@hotmail.com](mailto:cely_barroso@hotmail.com)

**Delson Braz**  
COPPE/UFRJ  
[cpinheiro@con.ufrj.br](mailto:cpinheiro@con.ufrj.br)

**Luiz Fernando Oliveira**  
UERJ  
[lfoliveira@oi.com.br](mailto:lfoliveira@oi.com.br)

**Resumo** *Histomorfometria óssea é uma importante análise na prevenção e tratamento de câncer e osteoporose, fornecendo informação quantitativa para diagnóstico clínico. A Microtomografia Computadorizada por Raios X é uma técnica de imagens não-destrutiva e não-invasiva com uma alta resolução que permite imagens ampliadas. Na análise histomorfométrica de tais imagens, é possível usar técnicas de tratamento tais como filtros morfológicos e binarização. Tais técnicas, no entanto, podem causar perda de informação relevante para a quantificação da massa óssea. Neste trabalho é descrita a aplicação de Redes Neurais Artificiais (RNA) para reconhecimento de tecido ósseo como parte de uma pesquisa sobre análise histomorfométrica em imagens cuja aquisição foi feita no Laboratório ELETTRA, em Trieste, Itália, na linha de pesquisa SYRMEP (Synchrotron Radiation for Medical Physics – Radiação Síncrotron para Física Médica). Nestes testes iniciais, uma RNA Perceptron Multi-Camadas (PMC) Feed-Forward (FF) com algoritmo de aprendizagem de Retro-Propagação de Erro foi utilizada na tarefa de reconhecimento. A qualidade dos resultados na tarefa da classificação de subimagens foi verificada através de Curvas ROC (Receiver Operating Characteristic). Para este tipo de RNA obtivemos uma área sob a curva de 1,000, o que significa que a arquitetura e o treinamento da RNA se mostraram adequados para a tarefa de reconhecimento de tecido ósseo. As imagens obtidas também são mostradas neste trabalho. Os resultados dos testes demonstraram a viabilidade de aplicação metodológica de Redes Neurais Artificiais e sua adequação às características das imagens obtidas por Microtomografia Computadorizada por Raios X, para evitar*

*perdas ocasionadas por outras técnicas de manipulação e tratamento de imagens. Também apresentamos uma breve descrição das principais tecnologias de implementação do projeto.*

**Palavras-Chave:** *Redes Neurais Artificiais, Microtomografia Computadorizada por Raios X, Histomorfometria Óssea*

**Abstract** *Bone Histomorphometry is an important analysis in preventing and treatment of cancer and osteoporosis, providing quantitative information for clinical diagnosis purposes. X Ray micro-Computed Tomography is a non-invasive and non-destructive imaging technique, with a high space resolution that enables magnified images. In the histomorphometric analysis of such images, it is possible to use morphological filters and binarization. Nevertheless, these techniques may cause loss of relevant information for the quantification of bone mass. In this paper the application of Artificial Neural Networks (ANNs) for recognizing bone tissue as a part of a histomorphometric analysis research with images obtained at the Synchrotron Radiation for Medical Physics (SYRMEP) beamline of the ELETTRA Laboratory at Trieste, Italy. In these preliminary tests, a Multilayer Perceptron ANNs with Error Back-Propagation has been used in the recognition task. The quality of the results of the subimages classification task was verified with Receiver Operating Characteristic (ROC) Curves. For this type of ANN, we have obtained an area under curve of 1.000, which means that the ANN is able to distinguish the bone mass successfully. The images obtained are also depicted herein. The results of the tests demonstrated the viability and methodological application of ANN and its compability to the images obtained by micro-Computed Tomography to avoid losses due to other image manipulation techniques. We also present a brief description of the main implementation technologies of the project.*

**Keywords:** *Artificial Neural Networks, X-Ray MicroComputed Tomography, Bone Histomorphometry*

## 1 Introdução

A Tomografia Computadorizada com Raios X [1, 2] tem permitido avanços recentes em imagens médicas de tecidos biológicos. A possibilidade de reproduzir imagens em três dimensões possibilita a descoberta de aspectos cuja observação não seria possível através de radiografia X convencional. A análise histomorfométrica [3, 4], que em linhas gerais representa uma série de medidas e cálculos referentes à massa de tecidos, fornece importantes dados para o apoio ao diagnóstico clínico para diversos pacientes, incluído aqueles com câncer e osteoporose. Assim, através de imagens podem ser realizados estudos não-invasivos e não-destrutivos, enquanto procedimentos tradicionais podem precisar de biópsias e outras técnicas mais complexas e que demandem tempo.

Tais medidas e cálculos a respeito da massa óssea para análises podem ser feitas com o auxílio de imagens de Microtomografia Computadorizada ( $\mu$ TC), ou seja, uma técnica não-destrutiva e não-invasiva tendo em vista técnicas tradicionais que necessitem de biópsias e outros procedimentos demorados e complexos. Recentes avanços no processamento de imagens compreendem o uso de técnicas computacionais e softwares específicos que permitem a quantificação de tecidos e estruturas para fins de análise e diagnóstico. No entanto, tratamentos de imagens específicos como *binarização* e o uso de *filtros de imagens* podem acabar ocasionando a perda de informação. Desta forma foi motivada a aplicação de Redes Neurais Artificiais (RNAs) [5, 6] para quantificação de imagens para fins de análise histomorfométrica.

Soluções que envolvam RNAs na área de imagens são avaliadas na extensa revisão bibliográfica feita em [7], que permite observar o crescente uso de Computação Neuronal nas diversas etapas de tratamento e análise de imagens médicas. A Computação Neuronal busca representar computacionalmente modelos com inspiração no funcionamento do cérebro humano. Tratam-se de modelagens que se baseiam nas relações entre neurônios, sinapses e aprendizado, já que o cérebro é um computador "altamente complexo, não-linear e paralelo" [5], cujas funcionalidades estão ligadas à execução de tarefas de percepção, reconhecimento e controle motor. Na aplicação descrita neste artigo, utilizamos uma RNA para a tarefa de reconhecimento de padrões de sub-imagens e sua classificação com o intuito de aplicação no apoio ao diagnóstico clínico através da histomorfometria. Como pode ser observado na Figura 1, existem três padrões de tonalidade na imagem: a de tecido ósseo (com tonalidades mais claras), a de gordura (com tonalidades médias) e a de fundo, ou *background* (com tonalidades mais escuras). O objetivo da aplicação da rede nesta pesquisa foi a de

pesquisar o reconhecimento de padrões de tecido ósseo. Realizamos também a quantificação dos resultados através de curvas ROC (*Receiver Operating Characteristic*), e a aplicação das redes que apresentaram melhores desempenhos na tarefa de classificação para eliminar da imagem as fases de gordura e fundo, que não eram de interesse na pesquisa. O restante deste artigo é organizado da seguinte forma: a seção 2 apresenta a fundamentação teórica; na seção 3 é feita uma breve apresentação das tecnologias de implementação; a seção 4 discute a arquitetura e a implementação da rede; a seção 5 apresenta os resultados; a discussão é apresentada na seção 6; as conclusões e propostas de trabalhos futuros são feitas na seção 7.

## 2 Fundamentação Teórica

### 2.1 Microtomografia Computadorizada

A Microtomografia Computadorizada ( $\mu$ TC) é uma técnica não-destrutiva e não-invasiva utilizada para investigação, com uma resolução espacial na faixa de  $10\mu\text{m}$  [2]. Tendo em vista técnicas tradicionais que necessitem de biópsias e outros procedimentos demorados e complexos, a microtomografia é um avanço considerável no contexto de aplicações médicas, pois a partir de suas imagens podem ser obtidas relevantes informações para apoio ao diagnóstico e tratamento de doenças como câncer e osteoporose.

A imagem de interesse (Figura 1) no trabalho desenvolvido foi obtida pelo método de Microtomografia Computadorizada usando a técnica de contraste de fase na Linha de Pesquisa de Radiação Síncrotron para Física Médica (Synchrotron Radiation for Medical Physics, SYRMEP) do Laboratório ELETTRA, em Trieste, Itália.

### 2.2 Análise Histomorfométrica

A análise histomorfométrica é baseada em conceitos estereológicos e foi inicialmente aplicada a amostras biológicas [3, 4]. Esta técnica tem sido usada para avaliar estruturas complexas como filtros cerâmicos e demais objetos com estrutura interna conectada, como tecido ósseo. A histomorfometria tri-dimensional corresponde a uma evolução dos métodos convencionais aplicados às imagens 2D. São utilizados índices como *conectividade* e *anisotropia*, úteis para avaliar tais estruturas complexas.

### 2.3 Redes Neurais Artificiais

As RNAs [5] são amplamente utilizadas em tarefas de reconhecimento de padrões e controle, entre outras. As RNAs são modelos computacionais inspirados no funcionamento e características do cérebro humano. Suas modelagens se baseiam nas relações entre neurônios, sinapses e aprendizado.

Neste trabalho, utilizamos a arquitetura de uma rede Perceptron Multi-Camadas (PMC), com algoritmo de aprendizado de Retro-Propagação de Erro (RPE) [8].

### 2.4 Curvas ROC (Receiver Operating Characteristic)

Para validação dos primeiros resultados obtidos, foi utili-

zada a metodologia das curvas ROC [6]. Trata-se de um teste não-paramétrico que leva em conta a comparação entre algum teste realizado e um teste “padrão-ouro” (*gold standard*). Os resultados do teste realizado são comparados aos do teste-padrão e quantificados em termos de verdadeiro-positivos, falso-positivos, verdadeiro-negativos e falso-negativos. Com a contagem dos resultados é possível representar uma curva ROC. A área sob a curva, que pode variar entre 0 e 1, é então computada. Uma área igual a 1 significa que o teste escolhido leva a resultados consistentes com o teste-padrão, podendo ser utilizada para a tarefa de classificação.



**Figura 1** : Imagem de interesse: *slice* (fatia, divisão) da tíbia de um rato obtida por  $\mu$ TC a partir da luz Síncrotron: pixels em tons de cinza escuros representam fundo (*background*), tons de cinza intermediários correspondem a gordura (*marrow*) e tons claros correspondem a osso (*bone*).

## 3 Tecnologias de Implementação

Para implementação das RNAs e manipulação das imagens foi utilizado o *software* MATLAB. Para implementação das RNAs também estão sendo realizados testes em linguagem de programação JAVA, utilizando o *JOONE* (Java Object Oriented Neural Engine, <http://www.jooneworld.com/>), um *framework* de RNAs baseado em componentes, apresentando possibilidades para diferentes arquiteturas e treinamentos.

A linguagem de programação JAVA também têm sido sendo utilizada em testes para fazer a leitura dos

dados da imagem com o Ambiente de Desenvolvimento Integrado NetBeans 6.1 (<http://www.netbeans.org/>), juntamente com a instalação de uma Interface de Programação de Aplicação específica para trabalho com processamento de imagens, a *Java Advanced Imaging* (JAI). A JAI provê um conjunto de interfaces orientadas a objeto para um modelo de programação simples, porém de alto nível, que aceita fácil manipulação de imagens em aplicações JAVA.

## 4 Objetivo, Arquitetura e Treinamento da RNA

O objetivo da RNA aplicada era o de reconhecimento de padrões de sub-imagens de tecido ósseo, tendo como padrões de entrada as tonalidades de cinza referentes a tais sub-imagens. Para tanto, a arquitetura de rede utilizada foi a Perceptron Multi-Camadas (PCM) com algoritmo de Retro-Propagação de Erro (RPE) [8]. Utilizamos 9 neurônios na camada de entrada, 5 na camada escondida e 3 neurônios na camada de saída. Para treinamento, os dados de entrada foram as tonalidades de cinza obtidas da imagem da Figura 1 para 30 sub-imagens escolhidas visualmente pelo programador, 10 padrões para cada fase (osso, gordura e fundo). Assim, foram associados os vetores de saída no treinamento supervisionado da rede com (1 0 0) representando fundo, (0 1 0) representando osso e (0 0 1) representando gordura.

Após o treinamento, foram utilizados os próprios padrões de entrada para testes preliminares de aceitação. No entanto, como este conjunto é relativamente pequeno para conclusões globais a respeito da qualidade da classificação da rede, foram obtidas aleatoriamente 100 sub-imagens para cada um dos dois tipos de algoritmos de RPE para elaboração das curvas ROC: o gradiente descendente (GD) e o gradiente descendente com momentum (GDM). Para ambas as classificações feitas pelas redes treinadas com estes algoritmos foram traçadas as curvas ROC.

Após o resultado obtido para classificação de massa óssea com as curvas ROC, por apresentar melhor desempenho, a rede treinada com RPE com GDM foi aplicada à eliminação das fases que não eram de interesse na imagem (gordura e fundo). Aplicamos posteriormente uma rede treinada com o algoritmo de Gradiente Descendente

com taxa de aprendizado variável (GDTAV) também na eliminação de fases da imagem.

## 5 Resultados

### 5.1 Curvas ROC

As Figuras 2, 3 e 4 mostram os resultados da curva ROC para a tarefa de reconhecimento de padrões de osso, fundo e gordura para a RNA treinada com RPE-GD. Neste caso, a área sob a curva para o reconhecimento de osso foi 1,000, para fundo foi 0,993 e para gordura foi 0,795.

As Figuras 5, 6 e 7 mostram os resultados da curva ROC para a RNA treinada com RPE-GDM. Neste outro caso, a área sob a curva para o reconhecimento de osso também foi 1,000, mas para fundo foi 0,944 e para gordura foi 0,960.

### 5.2 Teste Preliminar: Subtração das Fases de Gordura e Fundo de uma Sub-Imagem

Os resultados obtidos com a análise feita pelas curvas ROC permitiram inferir que a qualidade do reconhecimento está associada ao tipo de treinamento. Assim, para testes preliminares obtenção de imagens subtraindo o fundo e a gordura, a fim de obter melhor visualização de como as RNAs estão desempenhando a tarefa de classificação, foram utilizadas as RNAs treinadas com GDM e GDTAV em uma imagem obtidas a partir de uma amostra diferente da qual foi obtida a imagem de interesse (Figura 1). Tal imagem, sem tratamento, pode ser vista na Figura 8 e os resultados após o reconhecimento de padrões e subtração podem ser vistos nas Figuras 9 e 10, obtidas respectivamente pelas RNA com BP-GDM e BP-GDTAV.





Figura 4: Curva ROC para a rede treinada com RPE-GD: reconhecimento de gordura (área 0,795).

Figura 2: Curva ROC para a rede treinada com RPE-GD: reconheci-

mento de tecido ósseo (área 1,000).

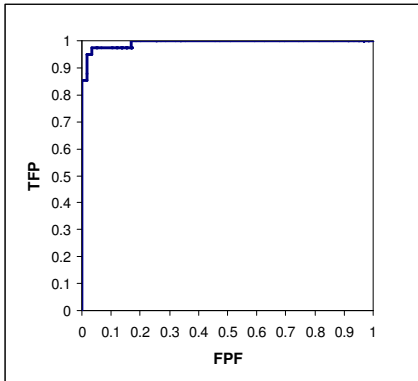


Figura 3: Curva ROC para a rede treinada com RPE-GD: reconheci-

mento de fundo (área 0,993).




Figura 5: Curva ROC para a rede treinada com RPE-GDM: reconhe-

cimento de tecido ósseo (área 1,000).

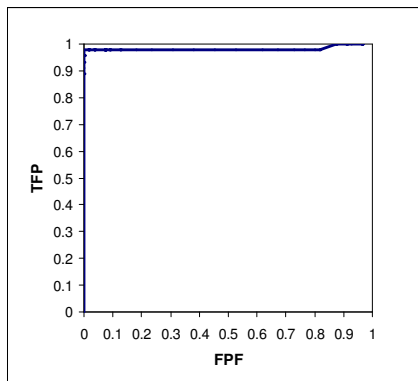


Figura 6: Curva ROC para a rede treinada com RPE-GDM: reconhecimento de fundo (área 0,944).




Figura 7: Curva ROC para a rede treinada com RPE-GD: reconhecimento de gordura (área 0,960).

## 5.2 Teste Preliminar: Subtração das Fases de Gordura e Fundo de uma Sub-Imagem

Os resultados obtidos com a análise feita pelas curvas ROC permitiram inferir que a qualidade do reconhecimento está associada ao tipo de treinamento. Assim, para testes preliminares obtenção de imagens subtraindo o fundo e a gordura, a fim de obter melhor visualização de como as RNAs estão desempenhando a tarefa de classificação, foram utilizadas as RNAs treinadas com GDM e GDTAV em uma imagem obtidas a partir de uma amostra diferente da qual foi obtida a imagem de interesse (Figura 1). Tal imagem, sem tratamento, pode ser vista na Figura 8 e os resultados após o reconhecimento de padrões e subtração podem ser vistos nas Figuras 9 e 10, obtidas respectivamente pelas RNA com BP-GDM e BP-GDTAV.




Figura 8: Imagem crua utilizada para os testes preliminares de reconhecimento de padrões de tecido ósseo e subtração dos padrões de gordura e fundo.




Figura 9: Subtração dos padrões de gordura e fundo a partir do reconhecimento de pixels com uma rede PMC com algoritmo BP-GDM.





Figura 10: Subtração dos padrões de gordura e fundo a partir do reconhecimento de pixels com uma rede PMC com algoritmo BP-GDTAV.

### 5.3 Subtração das Fases de Gordura e Fundo da Imagem de Interesse

A Figura 11 mostra o resultado final para a reconhecimento de padrões e subtração de pixels para a imagem de interesse da Figura 1, obtida com uma RNA PMC com algoritmo de treinamento BP-GDTAV.



**Figura 11:** Resultado final para a imagem de interesse da Figura 1: subtração de pixels de gordura e fundo, mostrando a viabilidade da aplicação de Redes Neurais Artificiais para o reconhecimento de padrões de massa óssea para análise histomorfométrica.

## 6 Discussão

### 6.1 Curvas ROC

Os resultados com as Curvas ROC (Figuras 2-7) nos permitem inferir que a qualidade do reconhecimento das três fases está correlacionado ao tipo de treinamento das redes, embora o conjunto de pixels de massa óssea tenha sido perfeitamente reconhecido pelas RNAs treinadas com os algoritmos BP-GD e BP-GDM. Esta característica de considerável desempenho no reconhecimento de padrões de massa óssea foi aplicada na subtração de pixels que não fossem relativos à massa óssea.

### 6.2 Teste Preliminar: Subtração das Fases de Gordura e Fundo de uma Sub-Imagem

Os testes preliminares do desempenho do reconhecimento de tecido ósseo para imagens com redes MCP com algoritmos de treinamento BP-GDM e BP-GDTAV demonstraram a possibilidade de aplicação para as imagens

cruas, como mostram as Figuras 8-10.

### 6.3 Subtração das Fases de Gordura e Fundo da Imagem de Interesse

O uso da RNA com algoritmo de aprendizagem BP-GDTAV no reconhecimento de padrões de tecido ósseo na imagem de interesse (Figura 1) mostrou um importante resultado, de acordo com a Figura 11. Apesar de uma pequena quantidade de pixels de gordura terem sido reconhecidos como tecido ósseo e portanto não subtraídos, podemos inferir que outras arquiteturas e treinamentos podem ser investigados para melhorar os resultados, já que foram testados tipos básicos de arquitetura e treinamento.

## 7 Conclusões e Trabalhos Futuros

As RNAs PMC com treinamento de RPE com GD e GDM demonstraram ótima capacidade de reconhecimento de padrões de tecido ósseo na imagem obtida por Microtomografia Computadorizada com Raios X, com sua qualidade dos resultados verificada a partir das curvas ROC. As RNAs com RPE-GDM e RPE-GDTAV foram aplicada diretamente à subtração das fases não-desejadas de gordura e fundo em testes preliminares, a fim de ilustrar como a rede realiza a tarefa de reconhecimento de padrões para todos os pixels da imagem. Foi aplicada então, a RNA com RPE-GDTAV à imagem de interesse.

Desta forma, com os resultados obtidos, podemos considerar a viabilidade do uso de RNAs para reconhecimento de padrões de tecido ósseo para imagens obtidas por Microtomografia Computadorizada a partir da luz síncrotron. Como trabalhos futuros, estaremos realizando a histomorfometria do tecido ósseo a partir das informações de classificação fornecidas pelas RNAs. Também estaremos treinando e testando outras arquiteturas e treinamento de redes para comparação com estes resultados.

## Agradecimentos

Os autores agradecem à FUNEMAC (Fundação Educacional de Macaé) e à FAPERJ (Fundação Carlos Chagas Filho de Amparo à Pesquisa do Estado do Rio de Janeiro) pelo apoio à pesquisa.

## Referências

- [1] G. N. Hounsfield. "Computerized transverse axial scanning (tomography)". *Br. J. Radiol.* 46,



pp. 1016-1022, 1973.

- [2] M. Stampanoni, P. Wyss, R. Abela, G. Borchert, D. Vermeulen, U. Sennhausen, P. Rüeggsegger. "Computer Microtomography". SLSAR, 2000.
- [3] C. J. G. Pinheiro, R. C. Barroso, D. Braz, G. Tromba, D. Dreossi. "3D Histomorphometric Quantification of Cortical Bone Architecture Using MicroCT with Synchrotron Radiation". Technical Report. The Abdus Salam International Centre for Theoretical Physics, 2008.
- [4] L. D. Carbonare, M. T. Vallenti, F. Bertoldo, M. Zanatta, S. Zenari, G. Realdi, V. L. Cascio, S. Giannini. "Bone microarchitecture evaluated by histomorphometry". *Micron* 36, pp. 609-616, 2005.
- [5] Haykin, S. *Neural Networks: a Comprehensive Foundation*. India: Pearson Education, 2005.
- [6] M. Egmont-Petersen, D. de Ridder, H. Handels. "Recognition of radiopaque markers in X-ray images using a neural network as a nonlinear filter". *Pattern Recognition Letters* 20 , pp. 521-533, 1999.
- [7] M. Egmont-Petersen, D. de Ridder, H. Handels. "Image processing with neural networks - a review". *Pattern Recognition* 35, pp. 2279-2301, 2002.
- [8] D. E. Rumelhart, G.E. Hinton, R. J. Williams. "Learning representations by back-propagating errors," *Nature* 323, 1986.