



Faculdades Adamantinenses Integradas (FAI)

[www.fai.com.br](http://www.fai.com.br)

LIMA, Fernando Parra dos Anjos; SOUZA, Simone Silva Frutuoso; MINUSSI, Carlos Roberto; ROMERO Rubén. Compreensão de imagens digitais com o uso de redes neurais artificiais. *Omnia Exatas*, v.4, n.1, p.25-34, 2011.

# COMPRESSÃO DE IMAGENS DIGITAIS COM O USO DE REDES NEURAIIS ARTIFICIAIS

## DIGITAL IMAGES COMPRESSING USING ARTIFICIAL NEURAL NETWORKS

**Fernando Parra dos Anjos Lima**

**Simone Silva Frutuoso de Souza**

Mestrandos em Engenharia Elétrica – FEIS – UNESP – Ilha Solteira.

**Carlos Roberto Minussi**

**Rubén Romero**

Professores Titulares – DEE – FEIS – UNESP – Ilha Solteira.

### RESUMO

Este artigo tem como objetivo principal o desenvolvimento de uma aplicação com redes neurais artificiais (HAYKIN, 1994) para compressão de imagens digitais, em específico para este trabalho utiliza-se uma rede neural artificial do tipo *multilayer perceptron* com o algoritmo de treinamento de *backpropagation*. (WERBOS, 1974), (WINDROW, 1990). Para este trabalho utiliza-se o software MATLAB para realizar a implementação do sistema, e faz-se o teste com imagens digitais a fim de verificar o desempenho do sistema, e a qualidade da imagem após a descompressão. Este trabalho tem uma grande importância para a área de redes, no fato de transmissão de dados, ou até mesmo se pensando em armazenamento. A compressão de imagens nestes casos é essencial, pois as imagens comprimidas pelos softwares comuns de compressão não tem bons resultados devido ao fato de se ter em cada pixel uma informação extremamente importante para a qualidade da imagem, assim os softwares não conseguem comprimir esta informação, fazendo que o tamanho da imagem comprimida seja praticamente o mesmo. Este problema na teoria tem resultados claros e significativos, porém na pratica tem sérios riscos e incertezas, então este problema é digno e merecedor de mais atenção e estudo. (GOMEZ, 2005).

**Palavras-chaves:** Compressão, Redes Neurais artificiais, Imagens Digitais.

### ABSTRACT

This article has as its main objective the development of an application with artificial neural networks (HAYKIN, 1994) for compression of digital images, in particular for this work uses an artificial neural network type multilayer perceptron with the algorithm for training backpropagation. (WERBOS, 1974), (WINDROW, 1990). For this work is to use the MATLAB software to carry out the implementation of the system, and it is the test with digital images in order to verify the performance of the system, and the quality of the image after decompression. This work is of great importance to the area of networks, because data transmission, or even thinking about it in storage. Image compression is essential in these cases, because the images compressed by common compression software does not have good results due to the fact of having each pixel in an extremely important information for the image quality, so the software cannot compress this information, making the size of the compressed image is roughly the same. This problem results in the theory is clear and

significant, but in practice has serious risks and uncertainties, then this problem is worthy and deserving of more attention and study. (GOMEZ, 2005).

**Key-words:** Compression, Artificial Neural Networks, Digital Imaging.

## INTRODUÇÃO

O transporte de imagens através de caminhos de comunicação é um processo caro. A compressão de imagem oferece uma opção para reduzir o número de bits de transmissão e por fim reduzir o custo. Por sua vez, ajuda a aumentar o volume de dados transferidos em um espaço de tempo, assim tornou-se cada vez mais importante para a maioria das redes de computadores trabalham com uma tecnologia para compressão dos arquivos, pois o volume de tráfego de dados começou a exceder a sua capacidade de transmissão. As técnicas tradicionais de compressão de dados incluem codificação preditiva, e compressão de transformação. De forma breve, codificação preditiva refere-se à correlação de pixels vizinhos semelhantes dentro de uma imagem para remover a redundância. Depois da remoção de dados redundantes, uma imagem mais comprimida pode ser transmitida. Técnicas de compressão de transformação também têm sido comumente empregadas. Estas técnicas executam transformações nas imagens para produzir um conjunto de coeficientes, um subconjunto de coeficientes escolhido é aquele que permite a representação de dados de boa qualidade (mínimo de distorção), mantendo uma quantidade adequada de compressão para a transmissão. (GOMEZ, 2005), (OLIVEIRA, 2008).

Além de algumas técnicas tradicionais de compressão de imagem, é possível discutir algumas das técnicas mais recentes que podem ser empregadas para compressão de dados.

As redes neurais artificiais (RNAs) são aplicadas constantemente a muitos problemas, e têm demonstrado uma superioridade sobre os métodos tradicionais ao lidar com dados ruidosos ou incompletos. (HAYKIN, 1994), (JAIN, 1996).

Assim uma destas aplicações é para a compressão de imagens, então neste artigo se apresenta uma proposta para realizar a compressão de imagens digitais, uma proposta utilizando redes neurais multicamadas fazendo uso do algoritmo *Backpropagation*, onde a importância do trabalho se baseia no gerenciamento ótimo da informação como são as tarefas de transmissão, organização e armazenamento de dados.

Atualmente existem grandes quantidades de softwares para realizar a compressão de arquivos de todo tipo, infelizmente estes apresentam melhores comportamentos para uma classe de arquivos em especial. Todos os diferentes tipos de arquivo de imagens digitais apresentam dificuldades em sua compressão porque são compostos por informações valiosas para a boa reprodução em qualquer tipo de máquina. Existem cenários onde não é preciso armazenar a informação exata da imagem, mas é primordial um armazenamento bem compacto.

Baseado no armazenamento de lembranças no cérebro humano, em especial as lembranças fotográficas, onde se explora todo o potencial da rede neural humana. Apresenta-se um modelo de compressão de imagens digitais através de redes neurais artificiais.

Neste trabalho implica que a compressão proposta no trabalho tem um alto grau de incerteza na qualidade, e é preciso um tamanho mínimo resultante e o processo de compressão é feito *off-line*. (GOMEZ, 2005), (OLIVEIRA, 2008).

## MATERIAL E MÉTODOS

Uma imagem digital na verdade é um mapa de bits ou um arranjo matricial de dimensões  $n \times m \times 3$ , onde  $n$  é o comprimento da imagem e  $m$  é a altura da imagem. Agora em relação à terceira dimensão de tamanho 3, tem-se informações correspondentes à cada uma das versões RGB (*Red*, *Green*, *Blue*) presentes em cada pixel da imagem. Na figura 1 pode-se visualizar a representação matricial de cada pixel com o valor correspondente em RGB. (GOMEZ, 2005), (OLIVEIRA, 2008).

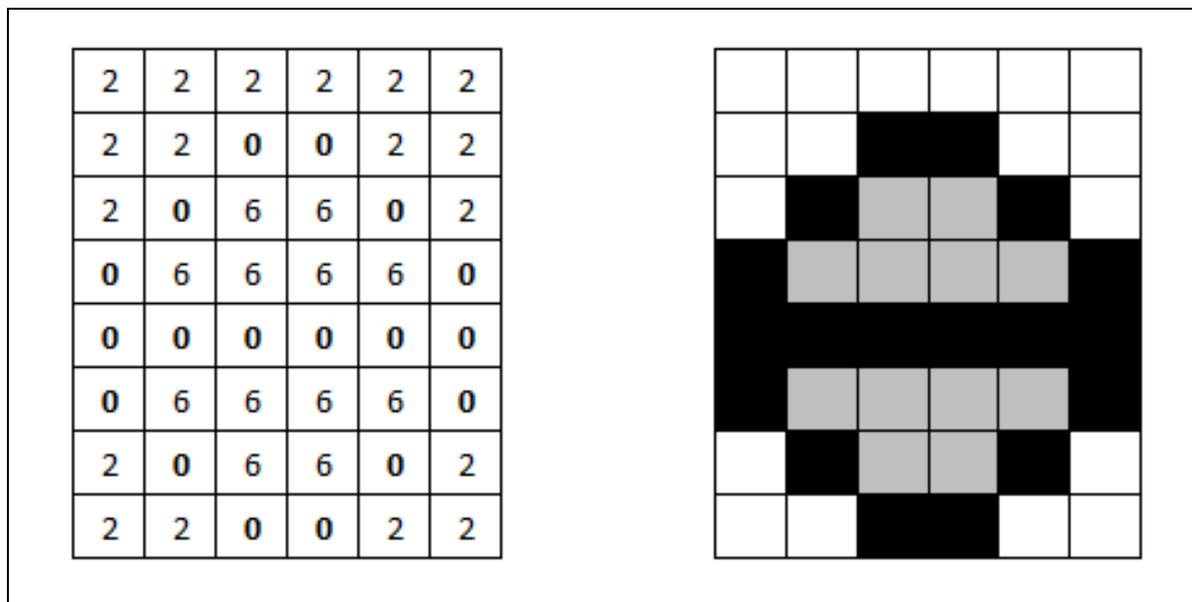


Figura 1. Representação matricial do armazenamento de uma imagem.

Isso significa que a imagem é armazenada pixel por pixel, onde cada cor de um pixel é uma combinação dada pelo padrão RGB (figura 2). No padrão RGB é reservado 256 opções para cada cor. O armazenamento é feito através de 24 bits ( $16'777.216$  cores diferentes).

Assim o sistema inteligente deverá armazenar o padrão de todas as cores com a menor quantidade de memória possível. Então para facilitar este trabalho convenhamos que esta imagem possa ser representada através de uma função em  $R^2$  ou  $R^3$  onde está armazenada a quantidade de cor em cada pixel, que na verdade é um neurônio na rede, isso faz com que o sistema precise somente de uma função como entrada de uma forma geral.

Então a seguir ilustra-se o procedimento para representar uma imagem através de uma função  $R^2$  ou  $R^3$ . (GOMEZ, 2005), (OLIVEIRA, 2008).

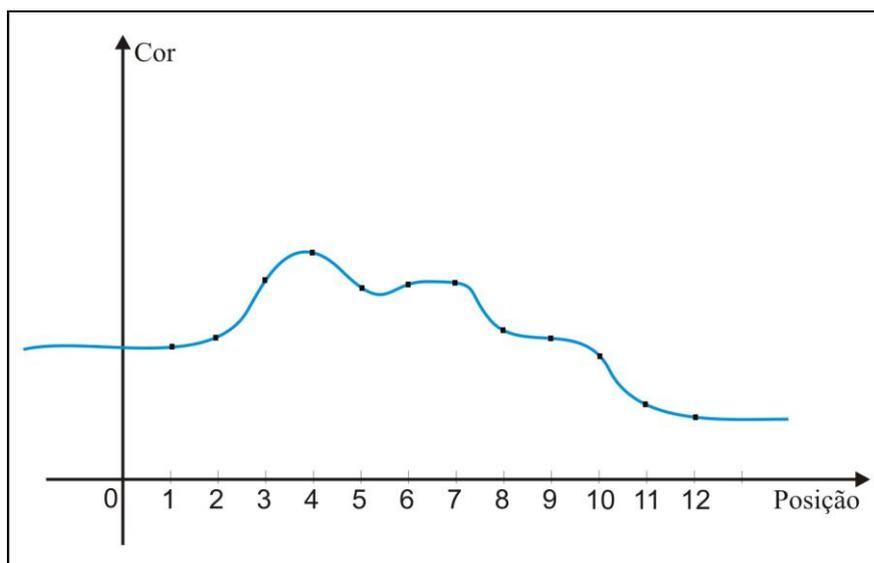


Figura 2. Função  $R^2$  de representação da imagem.

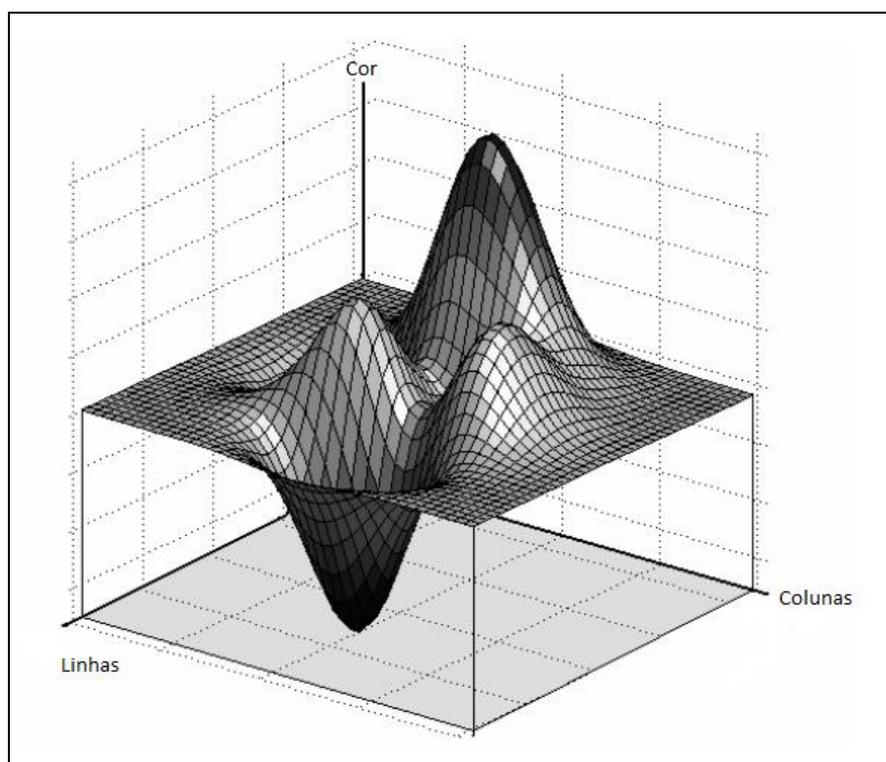


Figura 3. Função em  $R^3$  de representação da imagem.

Assim apresenta-se uma metodologia para resolver este problema com o uso de funções em  $R^2$  e  $R^3$  como entrada da rede neural.

### **Rede Neural Multicamada usando o algoritmo *Backpropagation***

Através da representação da imagem em uma função  $R^2$  ou  $R^3$  pode-se utilizar a seguinte arquitetura de rede neural:

Uma rede configurada para fazer a compressão da imagem e outra rede para fazer a descompressão, assim dada uma determinada função na entrada da rede de compressão, a mesma tem a finalidade de representar esta mesma função com um parâmetro de redução, ou melhor dizendo reduzir esta função.

Já com esta função reduzida apresentada para a rede de descompressão, tem-se o processo para recuperar toda informação inicial e montar novamente a função original de representação da imagem.

As figuras 5 e 6 a seguir ilustram a arquitetura da rede neural de compressão e da rede neural de descompressão.

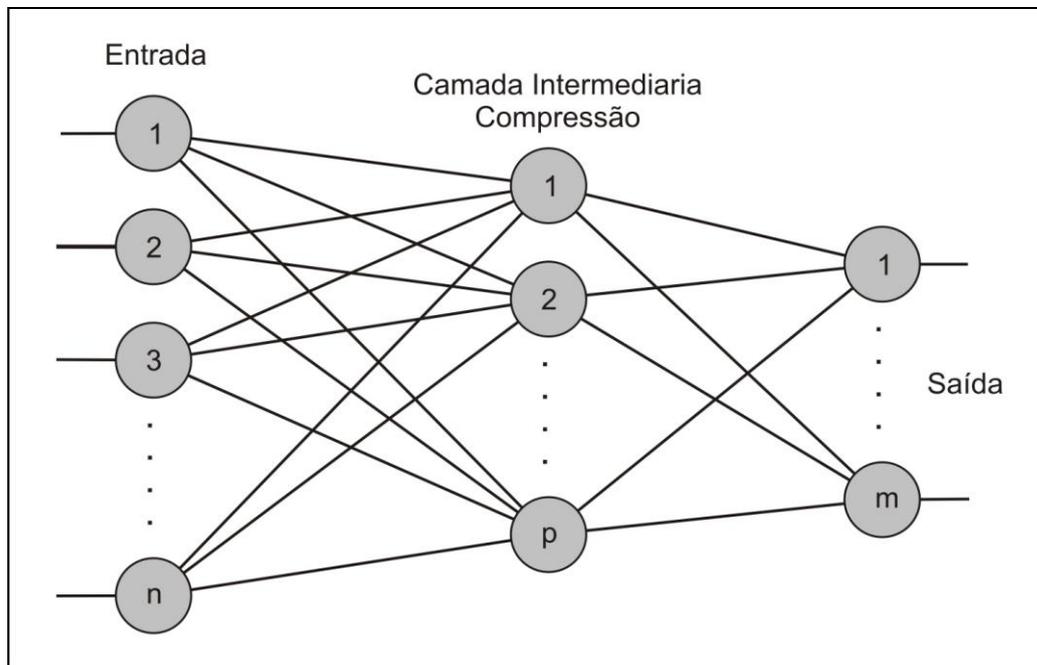


Figura 5. Arquitetura para compressão.

Como podem observar nas figuras 5 e 6, têm-se uma arquitetura para realizar a compressão e outra para realizar a descompressão da imagem.

A arquitetura para compressão de imagem trabalha com 3 camadas, na camada inicial  $n$  é o número de neurônios, ou melhor o número de posições presentes na função  $R^2$  (pixel por pixel) e  $R^3$  (representação de uma coordenada Linha x Coluna), assim dependendo do tamanho da imagem a ser trabalhada a dimensão da rede neural pode ser maior ou menor. Na segunda camada têm-se a camada de compressão onde os dados da camada inicial são estrangulados até um número de neurônios  $p$  para que exista a compressão e por fim a camada de saída que tem um número de neurônios  $m$  que deve ser menor que o número de neurônios da camada de compressão, então no final da rede neural tem-se uma função  $R^2$  ou  $R^3$  reduzida que representa a imagem original comprimida.

A arquitetura da rede de descompressão da imagem tem uma arquitetura semelhante à arquitetura de compressão, porém trabalha com o inverso. Na camada inicial é apresentada a função de representação da imagem em  $R^2$  ou  $R^3$  reduzida, com o mesmo número  $m$  de neurônios da rede neural de compressão. Na camada de descompressão trabalha-se com a expansão da função, por isto o número de neurônios aumenta, sendo determinado pelo parâmetro  $p$ , e finalmente a camada de saída tem um número  $n$  de neurônios, e tem a função de representar a função original, ou o mais próximo disto.

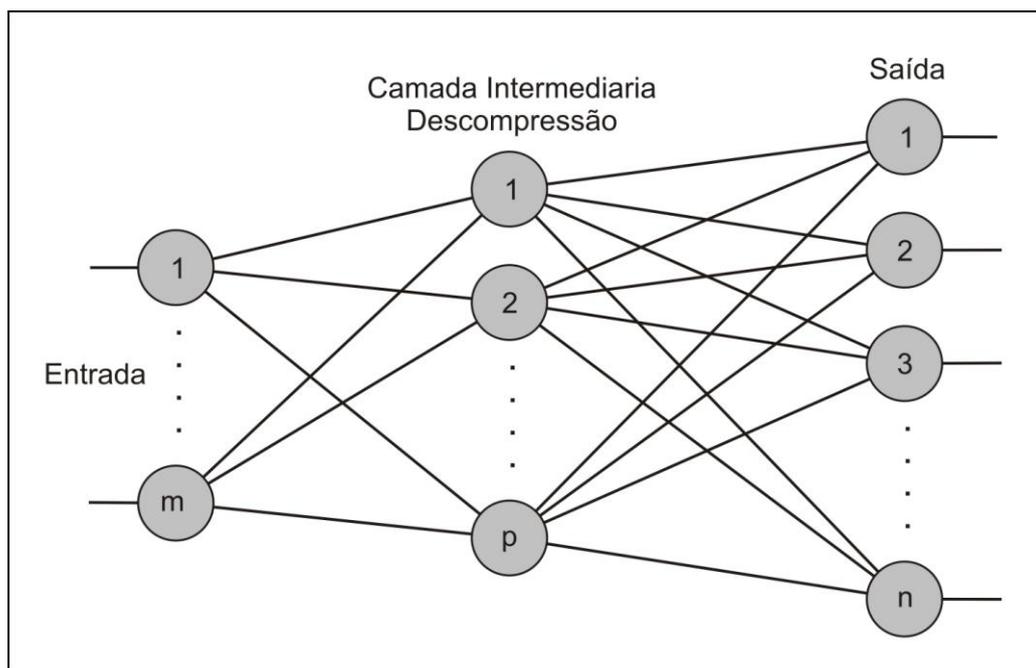


Figura 6. Arquitetura para descompressão.

Estas redes neurais são treinadas com o algoritmo *backpropagation*, e tem um treinamento supervisionado.

## RESULTADOS E DISCUSSÃO

Para testar esta rede neural para compressão de imagens digitais foram propostos 3 testes diferentes.

No primeiro teste utiliza-se uma imagem de 512x512 Pixels em escala de cinza, utilizando uma função do tipo  $R^3$  para representar a imagem, assim o número de neurônios na camada de entrada  $n = 512$ , então se adota uma compressão razoável fazendo com que o número de neurônios na segunda camada  $p = 350$ , e por fim a última camada tem um número de neurônios  $m = 256$ . Assim fica claro que o objetivo é reduzir pelo menos pela metade o tamanho da função que representa a imagem.

No segundo teste utiliza-se uma imagem de 512x512 Pixels em escala de cinza, utilizando uma função do tipo  $R^3$  para representar a imagem, assim o número de neurônios na camada de entrada  $n = 512$ , então se adota uma compressão razoável fazendo com que o número de neurônios na segunda camada  $p = 250$ , e por fim a última camada tem um número de neurônios  $m = 128$ . Assim fica claro que o objetivo é reduzir muito o tamanho desta função que representa a imagem.

No terceiro teste utiliza-se uma imagem de 512x512 Pixels em escala de cinza, utilizando uma função do tipo  $R^3$  para representar a imagem, assim o número de neurônios na camada de entrada  $n = 512$ , então se adota uma compressão razoável fazendo com que o número de neurônios na segunda camada  $p = 150$ , e por fim a última camada tem um número de neurônios  $m = 64$ . Assim fica claro que o objetivo é reduzir intensamente o tamanho da função que representa a imagem.

Após realizar os três testes foram obtidos os resultados a seguir:

### Teste 1:

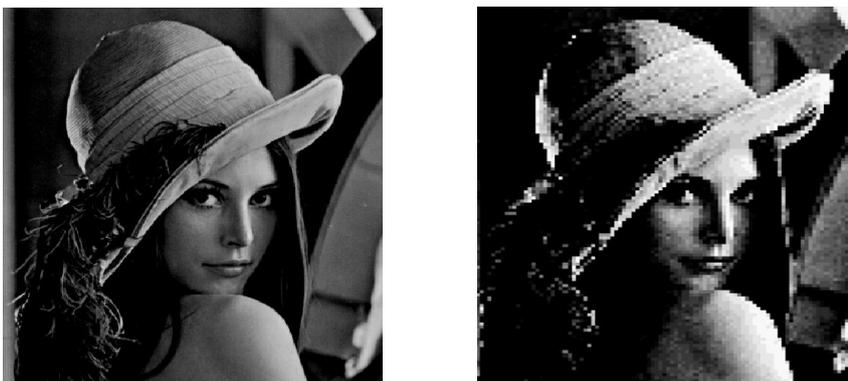


Figura 7: Imagem original e imagem na Saída da rede neural para o teste 1.

### Teste 2:



Figura7: Imagem original e imagem na saída da rede neural para o teste 2.

### Teste 3:

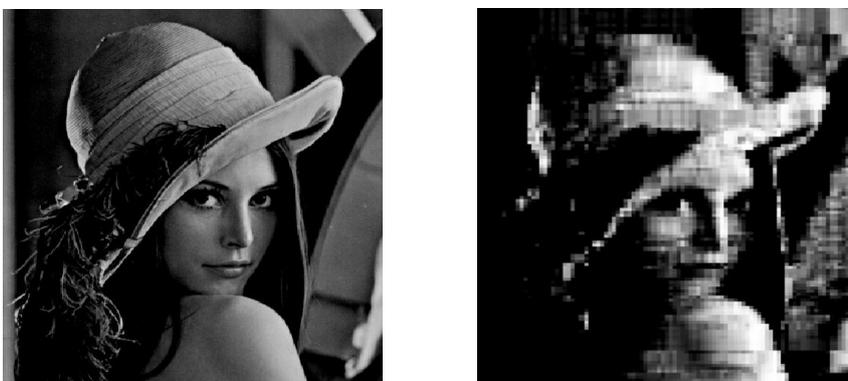


Figura 9: Imagem original e a imagem na saída da rede neural para o teste 3.

Estes resultados foram obtidos com um treinamento em *backpropagation* (WERBOS, 1974), (WIDROW, 1990) com aproximadamente 2000 épocas. A seguir apresentam-se os gráficos de erro na rede neural durante o treinamento.

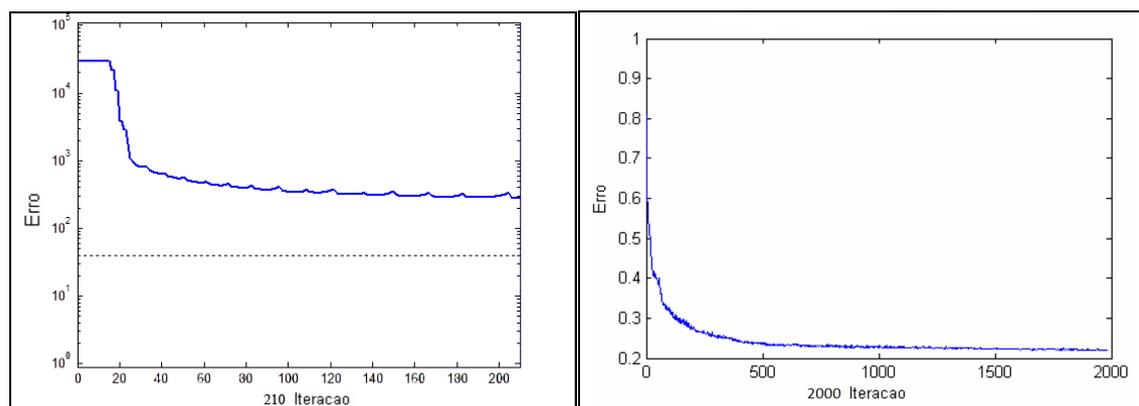


Figura 10: Erros no treinamento para 210 iterações e ao final com 2000 iterações.

Pode-se observar na figura 10 que o treinamento começa com um erro muito grande e à medida que se passa iterações este erro é diminuído, até aproximar-se de zero. Quando esse erro está próximo de zero temos a imagem comprimida para a rede de compressão, e a imagem descomprimida para a rede de descompressão.

O treinamento desta rede levou aproximadamente 65 minutos, assim pode-se dizer que a rede tem um bom desempenho, porém um alto custo em relação ao tempo.

Ao observar o desempenho desta metodologia proposta para compressão das imagens, é possível analisar esta rede em comparação com outros softwares de compressão de dados.

A tabela a seguir apresenta os dados da análise.

Tabela 1: Análise comparativa.

Método para compressão	Tamanho	Tempo para compressão
Imagem Original	2,07 MB (2196,8 KB)	
Winzip®	473 KB	0,3 segundos
Winrar®	442 KB	0,3 segundos
Rede Neural artificial	36 KB	65 minutos

Em relação a qualquer software de compressão já existente a rede neural se comporta com superioridade, porém tem um custo de tempo muito grande.

Esta técnica é importante e deve ser aprofundada para se ter resultados muito melhores, mais de qualquer forma esta técnica é recomendada para aplicações em ambientes que necessitem de trabalhar com compressão de imagens, e este processo possa ser realizado em modo *off-line*.

## CONCLUSÕES

Através deste trabalho foi possível analisar e concluir que a utilização das redes neurais multicamadas usando o algoritmo *Backpropagation* para a compressão de imagens digitais apresentam excelentes resultados, porém pagando um alto custo de tempo computacional, isso faz com que tal técnica seja principalmente viável para tarefas onde a compressão é feita *off-line*.

Os três testes propostos para esta arquitetura de rede neural obtiveram bons resultados, porém o teste número 1 teve um desempenho melhor, onde foi possível recuperar a imagem com mais nitidez. Os demais testes tiveram bons resultados, porém os parâmetros adotados para a camada de compressão

afetaram as imagens de resultado, pois a camada intermediária acaba estrangulando muito a informação e os dados não conseguem ser bem recuperados.

Uma observação a ser feita é em relação ao treinamento da rede neural, as imagens foram obtidas com aproximadamente 2000 iterações, para termos uma melhoria na imagem de resultado pode-se aumentar o número de iterações de treinamento.

Assim neste trabalho conclui-se que é possível comprimir imagens com redes neurais, e aconselha-se que este procedimento seja realizado em modo *off-line*.

## AGRADECIMENTOS

Agradecemos primeiramente a Deus, as nossas famílias, e por fim um especial agradecimento a CAPES pelo apoio (concessão de bolsa de Mestrado).

## REFERÊNCIAS

GOMEZ, J. D. **Compresión de imágenes digitais utilizando redes nueronales: Multicamada (Backpropagation) y RBR's**. Scientia et Technica – Uversidad Tecnológica de Pereira. ISSN 0122-1701, Vol. 29, pp. 101 – 106, Diciembre de 2005.

HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. Prentice-Hall - Upper Saddle River - New Jersey – USA – 1994.

JAIN, A. K.; MOHIUDDIN, K. M. **Artificial Neural Networks: A Tutorial**, IEEE Computer – Vol. 29 – Nº. 3 – pp. 31-44 – March 1996.

NASCIMENTO J. C. L. **Inteligência Artificial em controle e automação**, Edgard Blucher – 1º Edição – São Paulo – Brasil – 2004.

OLIVEIRA, A. B. V.; NASCIMENTO, C. L.; WALTER, F. **Implementação de um sistema de compressão de imagens usando redes neurais**. Divisão de engenharia eletrônica – instituto tecnológico de aeronáutica – ITA – 2008.

WERBOS, P. J. **Beyond Regression: New Tools for Prediction and Analysis in The Behavioral Sciences**, PhD. Thesis – Harvard University – 1974.

WIDROW, B.; LEHR, M. **30 Years of Adaptive Neural Networks: Perceptron, Madaline and Backpropagation**. *Proceedings of IEEE Neural Networks Congress* – Vol. 78 – Nº. 9 – pp. 1415-1442 - March 1990.