

Identificação de instrumentos musicais utilizando redes neurais artificiais

Anderson Jean de Farias¹

Jorge Fernando Linden¹

Marcio Alessandro Ternus¹

João Olegário O. de Souza²

Resumo

Este artigo apresenta um sistema capaz de identificar instrumentos musicais através do som, utilizando para isso uma rede neural artificial criada no MATLAB (MATWORK, 2008). O sistema apresentado permite a identificação de três instrumentos diferentes, utilizando como informação de entrada a Transformada de Fourier de diferentes notas musicais de cada um dos instrumentos. Escolheram-se aleatoriamente algumas notas como conjunto de treinamento da rede, associadas aos respectivos instrumentos, e, em seguida, as demais amostras foram submetidas à rede para reconhecimento. Outras notas de dois instrumentos não treinados também foram aplicadas ao sistema no intuito de verificar o comportamento diante de padrões não conhecidos. Ao final dos testes, confirmou-se a habilidade da rede neural artificial implementada de reconhecer e classificar aquelas amostras provenientes dos instrumentos treinados, apresentando indeterminação para as amostras daqueles para os quais não fora treinada.

Palavras-chave: Computação; Inteligência artificial; Redes neurais artificiais.

Abstract

This article presents a system able to identify musical instruments through sound, using an artificial neural network developed at MATLAB (MATWORK, 2008). The system allows the identification of three different instruments using as entry information the Fourier transform of different notes of each instrument. The article will present a brief introduction to artificial neural networks, musical instruments notes and signal analysis, following with the methodology used to solve the problem, the practical implementation of the neural network, tests and result analysis, ending with the conclusion that includes other suggestions of use to the methodology applied. Some notes were chosen randomly altogether as a training to the network, associated to each instrument, and afterwards the other samples were submitted to the network for recognition. Other notes of two instruments that were not trained also were applied to the system aiming to verify the behaviour when faced with unknown standards. In the end of the tests, it was confirmed the ability of the artificial neural network implemented to recognize and

¹ Técnico em Eletrônica, graduando em Engenharia Elétrica da Universidade do Vale do Rio dos Sinos – Unisinos. O presente artigo foi elaborado a partir de um trabalho desenvolvido na disciplina de Sistemas de Inteligência Artificial no Curso de Engenharia Elétrica. E-mail: <andersonjean@terra.com.br, jorgelinden@gmail.com, mternus@gmail.com>.

² Engenheiro Eletricista, Mestre em Computação Aplicada e professor do Curso de Engenharia Elétrica na Universidade do Vale do Rio dos Sinos – Unisinos. E-mail: <joaoolegario@yahoo.com.br>.

Recebido em 12/2008 e aceito em 03/2009.

classify the samples from the trained instruments and showing as undetermined the samples from the instruments that were not trained.

Keywords: *Computing; Artificial intelligence; Artificial neural networks.*

1 Introdução

As pesquisas em inteligência artificial tiveram um grande impulso nos últimos anos, e o principal motivo é a grande demanda por sistemas mais eficazes, capazes de interagir melhor com o meio onde estão e tomar decisões de forma autônoma. Estes sistemas podem ser de muitos tipos, como, por exemplo, sistemas especialistas que substituem profissionais de uma determinada área de conhecimento, ferramentas de busca em uma rede de computadores, sistemas de navegação automática de veículos, etc.

Dentro do ramo da inteligência artificial, uma das áreas existentes, e da qual trata este artigo, é a das redes neurais artificiais, cujo objetivo é obter um comportamento inteligente baseado no modelo de um neurônio biológico. Uma das principais vantagens das redes neurais é que elas podem produzir resultados válidos para problemas que são muito complicados ou até mesmo impossíveis de se resolver com algoritmos de computador convencionais, e isso é possível porque a rede possui a capacidade de generalização, isto é, captar as informações que são importantes para resolver o problema para o qual está sendo treinada e transformar isso em conhecimento para resolver problemas do mesmo tipo no futuro.

Este artigo, desenvolvido a partir de um trabalho realizado na disciplina de Sistemas de Inteligência Artificial com o professor João Olegário O. de Souza, no curso de Engenharia Elétrica, na Universidade do Vale do Rio dos Sinos (UNISINOS), apresenta a implementação de uma rede neural artificial para reconhecimento de instrumentos musicais no MATLAB. Inicialmente é feita uma breve fundamentação teórica sobre redes neurais, princípios sobre timbre e características de instrumentos, a seguir é apresentada a metodologia utilizada

para implementação da rede e, por fim, uma análise dos resultados obtidos.

A ideia para este trabalho surgiu a partir do artigo Reconhecendo instrumentos musicais através de redes neurais artificiais (MENEZES JUNIOR; FARIA; YAMANAKA, 2007) e o objetivo foi validar o trabalho original, além de estender e aprofundar alguns conceitos e resultados.

2 Redes neurais artificiais

A capacidade do cérebro humano de processar informações de forma não-linear e paralela permite a resolução de tarefas complexas. Este poder de processamento é creditado aos neurônios e suas interconexões (BRAGA, 2007).

A área da Inteligência Artificial, conhecida como Conexionista, procura desenvolver e reproduzir comportamento inteligente, baseado na estrutura do cérebro biológico que tem como elemento básico o neurônio. Basicamente, o processamento de informações num cérebro biológico é distribuído através de conjuntos ou camadas de neurônios, sendo que todos os neurônios dentro destes conjuntos processam as suas entradas simultânea e independentemente (LUGER, 2004).

Um esquema simplificado de um neurônio biológico consiste de um corpo celular que possui várias ramificações chamadas de dendritos e de um ramo principal chamado axônio que, na sua outra extremidade, possui outro conjunto de dendritos. Os dendritos recebem sinais de outros neurônios interligados, e quando estes impulsos combinados excedem um determinado limiar, o neurônio dispara um impulso ao longo do axônio. Os ramos de terminações do axônio formam sinapses com os dendritos dos outros neurônios. Essas características capturam o essencial para os modelos

neurais de computação, que são formados basicamente por neurônios artificiais. (LUGER, 2004). Na figura 1, temos o esquema de um neurônio biológico.




Figura 1 - Neurônio biológico

Uma rede neural artificial é um processador paralelo e distribuído, constituído de unidades de processamento (neurônios) que processam funções matemáticas quaisquer a fim de armazenar conhecimento e utilizá-lo. A estrutura desses sistemas é disposta em camadas interligadas através de conexões. Associadas às conexões, geralmente, encontram-se os pesos, os quais são os responsáveis pelo conhecimento armazenado na rede e pelas forças das conexões (BRAGA, 2007). Na figura 2 vemos um neurônio utilizado nestas redes, onde as variáveis x são os valores de entrada que vêm do ambiente ou de outros neurônios, no nosso caso são valores reais, os w são os pesos sinápticos, Σ é a função que produz a soma ponderada dos sinais de entrada, θ é a função de ativação, e y a saída.




Figura 2 - Neurônio artificial

A função de ativação define, segundo o modelo exposto, o valor da saída em função dos valores locais. É ela que introduz o comportamento não-linear do neurônio e produz o estado ligado/desligado semelhante a um neurônio natural, sendo a função sigmoide a mais usada por ser diferenciável em todos os pontos. Na figura 3, vemos seu comportamento e, a seguir, a equação que a descreve.





Figura 3 - Função de ativação sigmoide



Equação da função sigmoide

A função sigmoide é a que será utilizada neste trabalho e, de acordo com a documentação do MATLAB: versão 6.5 (MATWORK, 2008), foi implementada de tal forma que o parâmetro α é igual a 1.

Os benefícios das redes neurais se evidenciam na sua habilidade para executar computação distribuída e na sua generalização. A generalização se refere à capacidade de apresentar saídas coerentes para entradas que não estavam presentes durante o treinamento (aprendizagem). Além disso, RNAs (Redes Neurais Artificiais) possuem outras potencialidades, tais como capacidade de trabalhar com problemas não-lineares, adaptabilidade (habilidade de se ajustar a novas informações) e tolerância a falhas (capacidade de oferecer boas respostas mesmo com falta de informação, confusão ou dados ruidosos) (HAYKIN, 2001).

Quanto ao processo de aprendizagem, mais conhecido como algoritmo de aprendizagem, os pesos sinápticos da rede são modificados de forma a alcançar um objetivo predefinido, que normalmente ocorre com um conjunto de exemplos que chamamos de conjunto




Figura 4 - Rede multicamada (BRAGA, 2007)

de treinamento, onde apresentamos os sinais de entrada, e analisamos se a rede gerou o resultado esperado (BRAGA, 2007). Quanto maior e mais heterogêneo o conjunto de treinamento, maior capacidade de generalização a rede terá. O algoritmo mais usado para treinamento é o *Backpropagation*. Na figura 4 vemos uma rede multicamada com 10 entradas e duas saídas.

No algoritmo *backpropagation*, a saída da rede é comparada com a saída desejada, o que gera um valor de erro. Este valor é utilizado para realimentação que resultará no ajuste

dos pesos sinápticos de cada camada num sentido oposto à propagação dos sinais de treinamento. Assim, o erro calculado de uma camada será usado para ajustar os pesos da camada anterior até que a primeira camada seja ajustada.

O processo é repetido um determinado número de vezes para cada padrão de dados durante o treinamento até que o erro total da saída tenha convergido a um valor mínimo predefinido. Na figura 5, vemos um diagrama simplificado do algoritmo *backpropagation*.

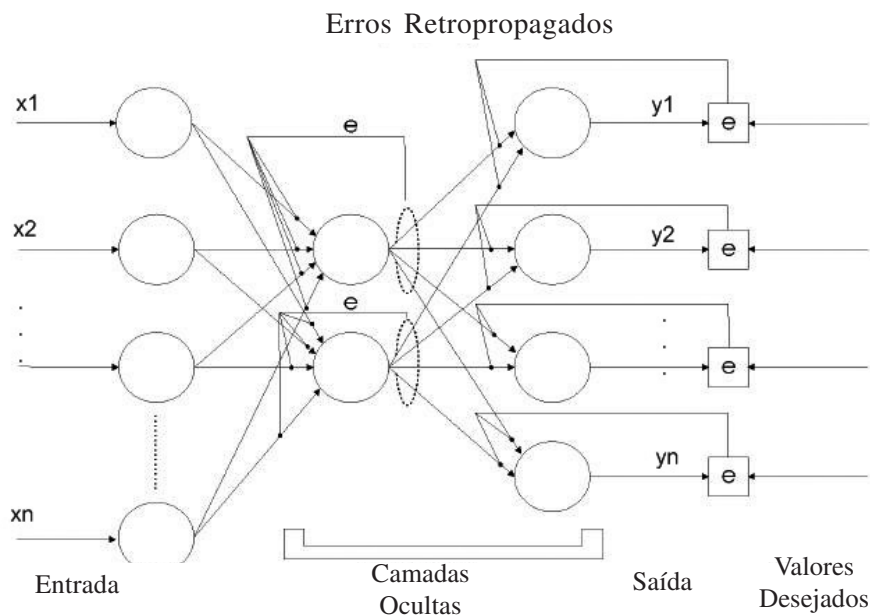


Figura 5 - Processo de treinamento com algoritmo *backpropagation* (DE PAULA, 2000)

3 Som, timbre e notas musicais

Os sons musicais podem ser produzidos por cordas (guitarra, piano, violino), membranas (tambores), colunas de ar (flauta, órgão), blocos de madeira ou barras de metal, (marimba, xilofone) ou arranjos de muitos outros corpos oscilantes. Num mesmo instrumento, mais de uma parte vibrante pode contribuir na geração do som (HALLIDAY; RESNICK; WALKER, 1996).

Aos sons musicais são atribuídas três características principais pelas quais os instrumentos e suas respectivas notas são discriminados e identificados (SEARS; ZEMANSKY; YOUNG, 1984):

- Intensidade: é a característica associada à intensidade das vibrações, muitas vezes conhecida como volume sonoro ou, erroneamente, como altura;

- Altura: determina quanto um som pode ser mais ou menos agudo ou grave, os sons graves tem frequências baixas e os agudos altas;

- Timbre: também chamado de qualidade, é o que distingue sons emitidos de mesma altura e frequência, de modo a diferenciar instrumentos distintos. Está ligado à complexidade das vibrações, com a presença de harmônicos sobrepostos.

As ondas sonoras, de modo a serem utilizadas na música, são geradas com frequências regulares e bem definidas. Cada nota musical tem uma frequência específica, padronizada internacionalmente, e nessas frequências e suas relações foi estruturada toda a teoria musical.

Como a característica que permite distinguir entre um instrumento e outro é o timbre, cada nota emitida por um instrumento é composta pela sua frequência básica de oscilação mais um conjunto de frequências múltiplas da mesma, chamadas de harmônicos. O conjunto de harmônicos que acompanha uma nota fundamental forma a Série Harmônica, e se dá fisicamente devido à formação de ondas estacionárias. Seja a corda de um violino ou a coluna de ar num tubo de órgão, quando postos a oscilar, produzem o modo fundamental e vários harmônicos de ordem

superior. A sobreposição desses componentes vai gerar o timbre característico do instrumento.

Cada nota tocada gera uma série harmônica identicamente proporcional. Ao tocar a nota dó de uma guitarra, por exemplo, a corda vibrará inteira e vibrará também, de forma a dividir a corda pela metade, logo depois, vibrará em três partes iguais, quatro partes iguais e assim por diante, tudo simultaneamente.

Na figura 6, vemos um diagrama de harmônicos de uma corda vibrando. Para cada instrumento, esses harmônicos são gerados em intensidades diferentes, o que explica como uma mesma nota tocada em instrumentos diferentes pode parecer tão diferente (HALLIDAY; RESNICK; WALKER, 1996).




Figura 6 – Harmônicos de uma corda

Analisando a distribuição das frequências e suas amplitudes, podemos verificar a distribuição da Série Harmônica, independente da nota que está sendo tocada. A amplitude dos harmônicos mais próximos da nota fundamental é maior do que a dos mais afastados, logo, quanto mais longe da fundamental, menos audível fica o harmônico. Esta relação de intervalos entre os harmônicos é a mesma para qualquer nota fundamental. É a série

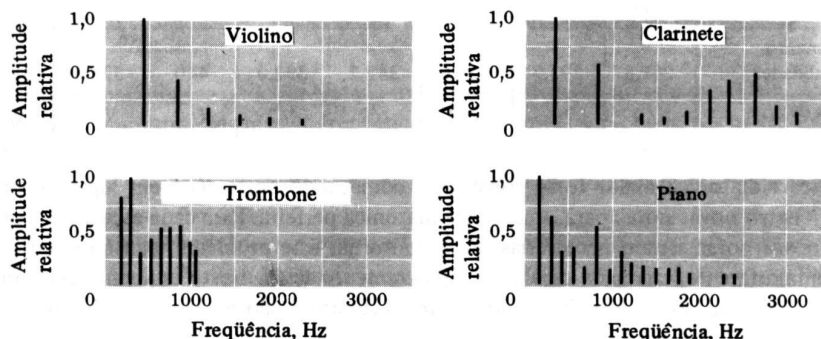


Figura 7 – Distribuição harmônica de diferentes instrumentos.

harmônica que define a nota que está sendo executada por um determinado instrumento. São as diferentes intensidades dos harmônicos que permitem o reconhecimento dos diversos timbres. Cada instrumento musical tem um gráfico de intensidade de harmônicos característico. Na figura 7, vemos alguns exemplos (SEARS; ZEMANSKY; YOUNG, 1984).

Para compreender melhor o conceito de timbre, podemos ver na figura 8 (HALLIDAY; RESNICK; WALKER, 1996) a forma de onda emitida por três instrumentos diferentes tocando a mesma nota. Observa-se que as formas de onda apresentam um padrão bem definido, e é este comportamento que permite distinguir cada instrumento quando os ouvimos.




Figura 8 – “Assinatura” dos instrumentos musicais definida pelo timbre.

A escala musical temperada pode ser definida matematicamente como uma progressão geométrica, cujo primeiro termo é a frequência da nota escolhida e cuja razão é o valor numérico 1.0594631 em decorrência da divisão de uma oitava em 12 intervalos. Assim, se tomarmos a nota dó como 16,352 Hz e formos multiplicando sucessivamente pelo número 1.0594631 vamos obter todas as frequências das notas musicais da escala musical temperada, culminando com a primeira nota da oitava seguinte que é o dobro do valor inicial, portanto igual a 32,704 Hz. Percorrendo a escala, segundo esses valores obtidos vamos caminhar de meio em meio tom. Na figura 9, podemos ver a distribuição das notas num teclado de piano (NETTO, 2006).




Figura 9 – Notas musicais no teclado de um piano

4 Análise de Fourier e fft

Assim como os sons dos instrumentos musicais são gerados pela sobreposição de inúmeras frequências, também é possível

decompor o sinal final em seus componentes harmônicos originais, utilizando-se o recurso da análise de Fourier. O matemático francês Jean Baptiste Fourier (1786-1830) foi o responsável por demonstrar que, com o princípio da superposição, é possível analisar formas de onda não senoidais, representando o sinal original através da soma de um grande número de ondas senoidais de frequências e amplitudes apropriadas. As figuras 10 e 11 mostram um exemplo dessa representação de um sinal complexo por seus componentes harmônicos.




Figura 10 – Onda dente de serra aproximada pelos seis primeiros harmônicos




Figura 11 – Seis primeiros harmônicos da onda dente de serra

A Transformada de Fourier é uma manipulação matemática que traduz uma função periódica qualquer do domínio do tempo para o domínio da frequência, sendo possível obter as informações de frequência e amplitude dos componentes harmônicos da forma de onda original (ALEXANDER; SADIKU, 2003). Para aqueles sinais que passaram por uma digitalização para processamento, armazenamento ou reprodução digital, como em computadores, por exemplo, existe a Transformada Discreta de Fourier, que é uma versão discretizada para sinais digitais.

Utilizando recursos computacionais, como o MATLAB, é possível fazer a análise de Fourier de um sinal digital aplicando-se o método da Transformada Rápida de Fourier, ou FFT (*Fast Fourier Transform*), que consiste em um algoritmo computacional que realiza a manipulação dos dados de modo a se obter as informações dos harmônicos presentes no sinal original e suas amplitudes.

5 Metodologia

Para implementação da RNA com o MATLAB, primeiramente capturamos diferentes notas musicais de instrumentos diversos em um teclado com capacidade de sintetizar as notas de diferentes instrumentos com ótima qualidade. O teclado utilizado foi um Korg – M1.

As notas gravadas em um arquivo WAV foram recortadas em um *software* de edição de arquivos de áudio para termos cada nota em um arquivo independente. Um exemplo de uma das notas geradas é visto na figura 12, visualizada através do MATLAB.




Figura 12 – Nota da Tuba visualizada no MATLAB.

Para que a RNA possa identificar cada instrumento através das notas tocadas, traçamos com o MATLAB o comportamento espectral destas, capturando o valor de magnitude das harmônicas de cada nota para um vetor, estes valores foram obtidos através da Transformada Rápida de Fourier de cada nota. Para que a RNA possa identificar com precisão cada instrumento, escolhemos capturar a amplitude das 25 primeiras harmônicas de cada nota tocada, assim, repetimos este processo para cada nota que será utilizada tanto para treinar, como para testar a RNA. Nas figuras 13,

14 e 15 podemos ver as formas de onda de uma mesma nota tocada nos três instrumentos escolhidos para serem identificados pela rede, que foram o acordeon, a guitarra e a tuba, respectivamente.

A decisão de utilizar as 25 primeiras harmônicas foi realizada bem no início do projeto, baseado nos resultados do artigo Reconhecendo instrumentos musicais através de redes neurais artificiais (MENEZES JUNIOR; FARIA; YAMANAKA, 2007), que utilizou apenas 16 harmônicas e desejava-se observar diferenças com a utilização de um número maior.




Figura 13 – Forma de uma nota tocada no acordeon




Figura 14 – Forma de onda de uma nota tocada na guitarra




Figura 15 – Forma de onda de uma nota tocada na tuba

Como mencionado, o comportamento espectral de cada instrumento permite identificá-los, assim utilizamos este artifício para

que a RNA faça a identificação. Nas figuras 16, 17 e 18, vemos o espectro harmônico das notas apresentadas nas figuras 13, 14 e 15 e podemos observar que cada instrumento tem um comportamento espectral distinto.




Figura 16 – Distribuição harmônica de uma nota tocada no acordeon




Figura 17 – Distribuição harmônica de uma nota tocada na guitarra




Figura 18 – Distribuição harmônica de uma nota tocada na tuba

Nas figuras 19, 20 e 21, temos o comportamento espectral de três notas diferentes de um mesmo instrumento, a tuba. Podemos ver que existe um padrão harmônico que se espera que a rede consiga identificar após ter sido treinada. Na realidade, o comportamento da RNA, tanto no aprendizado como no processo de identificação é semelhante ao do cérebro humano, pois este aprende a identificar diferentes instrumentos através de amostras que ouvimos com a devida associação de cada comportamento harmônico (timbre) de cada instrumento. Assim, espera-se que a rede possa identificar e, neste caso, diferenciar estes três

instrumentos, mesmo “ouvindo” (no caso recebendo um padrão harmônico) notas que não foram usadas no processo de treinamento.




Figura 19 – Distribuição harmônica da primeira nota da tuba




Figura 20 – Distribuição harmônica da segunda nota da tuba




Figura 21 – Distribuição harmônica da terceira nota da tuba

6 Implementação da rna

As notas de cada instrumento, depois de normalizadas, foram divididas em dois grupos: o conjunto de treinamento e o conjunto de teste. O conjunto de treinamento foi utilizado para treinar a rede, depois de alguns testes ficou definido como tendo cinco amostras de cada instrumento, e o conjunto de teste é formado por todas as amostras que ficaram de fora do conjunto de treinamento.

Exemplo de uma amostra de um instrumento:

```
Entrada = [0.541, 0.695, 1.000, 0.110,
0.071, 0.093, 0.012, 0.064, 0.044, 0.086,
0.019, 0.047, 0.074, 0.046, 0.071, 0.051,
0.036, 0.086, 0.020, 0.026, 0.019, 0.012,
0.003, 0.024, 0.005]
```

Esta é a primeira nota de treinamento do acordeon, e a saída desejada para esse instrumento foi definida como

$$\text{Saída} = [1, 0, 0]$$

Onde a primeira saída está ativada, já que foi essa a escolhida para o acordeon, e as duas seguintes foram definidas como sendo as saídas para a guitarra e a tuba, respectivamente.

A rede neural criada no MATLAB é do tipo *feed-forward* treinada com um algoritmo de *back-propagation*. A rede possui entradas, uma para cada harmônica adquirida da Transformada de Fourier do sinal de entrada. A camada oculta possui 50 neurônios, esse número foi definido a partir de vários testes com quantidades diferentes de neurônios na camada oculta, e esse valor apresentou uma boa relação entre capacidade de aprendizagem e tempo de treinamento, pois o MATLAB leva mais tempo e utiliza mais memória para executar o treinamento quando o número de neurônios aumenta. Na camada de saída, foram colocados três neurônios, um para cada instrumento treinado, tanto a camada de saída quanto a oculta possuem função de ativação do tipo *logsig* (sigmoide).

A seguir, está o programa escrito no MATLAB para criar, treinar e testar a rede neural.

```
clear;
P = load ('treinamento.txt');
T = load ('target.txt');
V = load ('teste.txt');
X = load ('teste2.txt');

MM = [0 1; 0 1; 0 1; 0 1; 0 1; 0 1; 0 1; 0 1; 0 1; 0 1;
1; 0 1; 0 1; 0 1; 0 1;
0 1; 0 1; 0 1; 0 1; 0 1; 0 1; 0 1; 0 1; 0 1;
1; 0 1; 0 1;];

net = newff(MM, [50 3], {'logsig' 'logsig'});
net.trainParam.goal = 0.001;
net.trainParam.epochs = 200;
net2 = train(net, P, T);
net3 = sim(net2, V)
net4 = sim(net2, X)
```

O vetor P contém o conjunto de treinamento da rede neural, formado por cinco amostras de cada instrumento, começando pelo acordeon, seguido pela guitarra e por fim a tuba.

O vetor T contém as saídas desejadas durante o processo de treinamento, para o acordeon a saída desejada será [1, 0, 0], para a guitarra será [0, 1, 0] e para a tuba a saída desejada é [0, 0, 1].

O vetor V contém as amostras que ficaram de fora do treinamento e serão utilizadas para testar a rede.

O vetor X contém duas amostras do banjo e do piano para o teste de instrumentos não treinados.

O vetor MM contém os limites numéricos aceitos em cada entrada da rede neural, como os valores foram normalizados, as entradas foram limitadas entre 0 e 1.

7 Análise de resultados

Uma vez que o programa foi executado e a rede está treinada, foram realizadas duas simulações, a primeira com amostras não treinadas dos instrumentos usados durante o treinamento e, por fim, duas simulações utilizando duas amostras de dois instrumentos desconhecidos para a rede.

Saídas após treinamento:

Exemplo de saída de uma amostra de Acordeon:

Saída = [0.9845, 0.0043, 0.0012]

Exemplo de saída de uma amostra de Guitarra:

Saída = [0.0009, 0.9893, 0.0028]

Exemplo de saída de uma amostra de Tuba:

Saída = [0.0006, 0.0018, 0.9897]

Como pode ser observado nos exemplos acima, a rede tem a capacidade clara de distinguir o instrumento ativando a saída correspondente.

Foi observada uma pequena variação nos valores de saída da simulação (em geral na segunda casa decimal) com instrumentos

conhecidos, esta variação depende dos valores finais dos pesos das entradas dos neurônios, e esses valores variam cada vez que a rede é treinada, pois ela sempre começa com pesos aleatórios, entretanto acima temos exemplos típicos de resposta observados na saída da rede. Apesar dessas pequenas variações, a rede conseguiu determinar com certeza a qual instrumento pertence uma dada amostra.

Por fim, foi feito um teste, colocando na entrada da rede uma amostra de dois instrumentos para os quais a rede não fora treinada, um banjo e um piano. O objetivo do teste foi determinar a resposta para estes dois instrumentos desconhecidos pela rede.

Dois hipóteses foram criadas para este teste, a primeira é a de que a rede iria convergir para o instrumento conhecido com o comportamento espectral mais parecido; na segunda hipótese, a rede não convergiria para um instrumento em particular, não ativaria qualquer uma das saídas ou ativaria mais de uma com um valor qualquer, não sendo possível determinar um instrumento específico.

A FFT desses dois instrumentos pode ser vista nas figuras 22 e 23.




Figura 22 – Espectro de frequências do banjo




Figura 23 – Espectro de frequências do piano

Exemplo de saída para o Banjo

Saída = [0.0003, 0.4827, 0.9093]

Exemplo de saída para o Piano

Saída = [0.0018, 0.5034, 0.1173]

Um detalhe importante foi observado neste caso, a rede varia muito a resposta para estes dois instrumentos a cada vez que é treinada. Ao contrário das amostras de instrumentos conhecidos, que têm pequenas variações, para estes dois instrumentos, a resposta variou significativamente a cada vez que a rede era submetida a um novo treinamento com os padrões originais.

No exemplo mostrado com o banjo, a rede deu uma resposta alta para a tuba, mas a saída da guitarra também exibiu uma resposta significativa.

Para o piano, a rede novamente apresentou um valor significativo na saída da guitarra, mesmo assim, pode-se perceber que a rede não conseguiu definir um instrumento específico.

Como conclusão deste teste, a segunda hipótese se mostrou verdadeira, a rede não consegue convergir para um único instrumento quando, na entrada, é apresentado um instrumento para o qual a mesma não foi treinada.

8 Conclusão

A capacidade de generalização de uma rede neural permite que se desenvolvam diversas aplicações na área de classificação de dados. Em problemas de classificação, como o realizado neste trabalho, o objetivo da rede é enquadrar um padrão de entrada a um grupo de entradas conhecidas. Outras aplicações possíveis envolvem predição de dados, aproximações e otimização.

Como se pode ver, a rede não teve problemas em reconhecer os instrumentos aos quais ela foi treinada. O experimento com instrumentos diferentes exemplifica o que pode acontecer na saída de uma rede neural quando recebe uma informação para a qual não foi treinada, também mostra um detalhe importante das redes neurais: elas não são determinísticas. Uma rede nunca irá dar como resposta exata para uma determinada entrada, ou produzir uma mensagem de erro caso a entrada não seja válida, uma rede neural pode errar, uma vez que o conhecimento em

geral é impreciso e incompleto, mas é possível, com um bom projeto, manter a taxa de erros dentro de um limite aceitável.

Em relação ao número de harmônicas na entrada, observaram-se que as últimas harmônicas possuem valores muito pequenos, portanto não são muito significativos para o processo de aprendizado e identificação, sendo assim um número menor poderia ter sido utilizado, como 20, por exemplo.

Uma das aplicações em que o método aqui descrito pode ser utilizado é em um sistema de manutenção de motores elétricos, onde podemos medir o comportamento vibratório do eixo e, através da sua análise espectral e de uma RNA devidamente treinada, identificar diferentes tipos de defeitos no motor, como, por exemplo, o desgaste de rolamentos, falta de fase etc. De uma forma mais genérica, é possível dizer que qualquer fenômeno que possua natureza oscilatória pode ser abordado com o método apresentado neste artigo.

Referências

- ALEXANDER, Charles K.; SADIKU, Matthew N. O. **Fundamentos de circuitos elétricos**. Porto Alegre: Bookman, 2003.
- BRAGA, Antônio de Pádua; CARVALHO, André Ponce de Leon F de; LURDEMIR, Teresa Bernarda. **Redes neurais artificiais: teoria e aplicações**. 2. ed. Rio de Janeiro: LTC, 2007.
- BRAGA, Petrônio de Luna. **Reconhecimento de voz dependente de locutor utilizando redes neurais artificiais**. 2006. Trabalho de Conclusão de Curso - Engenharia da Computação, Universidade de Pernambuco, Recife, 2006.
- DE PAULA, Maurício Braga. **Reconhecimento de palavras utilizando redes neurais artificiais**. 2000. Trabalho de Conclusão de Curso - Sistemas de Computação, Universidade Federal de Pelotas, Pelotas, 2000.
- GONÇALVES, Dalton. **Física**. Rio de Janeiro: Ao Livro Técnico SA, 1972.

HALLIDAY, David; RESNICK, Robert; WALKER, Jearl. **Fundamentos de Física 2: gravitação, ondas e termodinâmica**. 4. ed. Rio de Janeiro: LTC Editora. 1996.

HAYKIN, Simon. **Redes neurais: princípios e práticas**. 2. ed. Porto Alegre: Bookman, 2001.

LUGER, George F. **Inteligência artificial: estruturas e estratégias para solução de problemas complexos**. 4. ed. Porto Alegre: Bookman, 2004.

MATWORKS. **Matlab**. Disponível em: <<http://www.matworks.com/index.html>>. Acesso em: 28 de dez. de 2008.

MENEZES JUNIOR, Carlos R.F.; FARIA, Eustáquio José; YAMANAKA, Keiji. Reconhecendo instrumentos musicais através de redes neurais artificiais. **Hifen**, Porto Alegre, v. 31, N. 59, 2007.

Disponível em: <<http://revistaseletronicas.pucrs.br/ojs/index.php/hifen>>. Acesso em: 16 de dez. de 2008.

NETTO, Luiz. **A matemática na música**. 2006. Disponível em: <http://members.tripod.com/caraipora/esc_temp_freq_.htm> Acesso em 16 de dez. de 2008.

SEARS, Francis; ZEMANSKY, Mark W.; YOUNG, Hugh D. **Física 2: mecânica dos fluídos, calor, movimento ondulatório**. 2. ed. Rio de Janeiro: LTC, 1984.

VIEIRA, Renato Corrêa; ROISENBERG, Mauro. **Redes neurais artificiais: um breve tutorial**. 2006. Florianópolis: Universidade Federal de Santa Catarina, 2006. Disponível em: <http://www.das.ufsc.br/~gb/CIPEEL>. Acesso em: 16 de dez. de 2008.