

Previsão de Acordes em Músicas Tonais

Uraquitan Sidney G. C. Cunha e Geber Ramalho

Departamento de Informática -Universidade Federal de Pernambuco
Cx. Postal 7851, 50740-540 Recife, PE, Brazil
{usgcc, glr}@di.ufpe.br

Abstract

What is the real difficult in predict the next chord in one song? What kind of knowledge is necessary to realize this task? All of this questions have been not deeply studied yet, but they are relevant to the development of musical accompaniment systems. The problem of musical chords prediction belongs to a broad and well-known class of problems: *time series prediction*. In our work, we did a comparative analyses between the capacity of prediction of a Neural Network (MLP-Backpropagation) and one symbolic learning algorithm based in decisions trees, the ID3. The results show that a Neural Network has a better performance than the ID3 in all simulations.

1. Introdução

Prever um evento qualquer, normalmente e intuitivamente, requer algum conhecimento prévio do assunto e consequente percepção de padrões de comportamento. Um bom preditor tem que ser capaz de conseguir encontrar os vários padrões existentes dentro do conjunto de treinamento para então conseguir se antecipar e, de fato, prever o que virá. Qualquer aprendizado é bastante limitado a existência de alguma estrutura dentro dos dados. Encontrar esta estrutura é o objetivo do preditor.

Tornar uma máquina capaz de prever alguma coisa, entretanto, é uma tarefa difícil e que deve, sem dúvida alguma, ter boas motivações. Por que prever acordes musicais? Qual a contribuição que este estudo traria para as comunidades de música e da ciência da computação, em especial, da área de Inteligência Artificial? E comercialmente, o que poderíamos ter?

Dentro da comunidade musical, isto seria de uma utilidade surpreendente. Um sistema capaz de prever o próximo acorde de uma música que esteja sendo executada por alguns músicos é um sistema capaz de os acompanhar, ou seja, de tocar algum instrumento junto com estes músicos, o que poderia economizar tempo e dinheiro a muitos deles que dependem de outros músicos, sobretudo para ensaiar.

Como consequência, existe uma grande demanda da indústria de software e equipamentos musicais por algo capaz de realizar um bom acompanhamento automático. Hoje, este mercado está povoado de softwares e equipamentos que dão um suporte bastante precário em acompanhamento automático. Os existentes precisam, pelo menos, conhecer previamente a harmonia da música que será tocada (Band in a box). São bastante

previsíveis, estáticos e de pouca utilidade para os bons músicos, sobretudo os músicos que trabalham com improviso.

Dentro da comunidade de computação, resolver um problema deste nível é mais um desafio dentro da área da Inteligência Artificial. O problema de previsão de acordes musicais se encaixa na classe geral de problemas de *time series prediction* (previsão de séries temporais) (Weigend, 1993). O estudo deste problema contribuiria para que esta classe de problemas pudesse ser analisada e estudada detalhadamente através de um cuidadoso trabalho de comparação entre algoritmos de aprendizagem do paradigma conexionista, uma rede neural MLP-backpropagation, e do paradigma simbólico, o ID3.

O objetivo do nosso presente trabalho é a análise de qual ou quais algoritmos melhor se adequam à tarefa de previsão automática de acordes. Na seção 2 falaremos sobre as dificuldades computacionais do nosso problema e sua complexidade e a definição de um acorde musical para a máquina. Na seção 3 falaremos sobre o estado da arte. Na seção 4 será dada uma breve descrição sobre o modelo de rede neural usado e sobre o ID3. Na seção 5 será apresentada a definição que chegamos para um acorde e serão apresentados os resultados que obtivemos em nossos experimentos. A seção 6 concluirá o nosso trabalho, apontando algumas direções para futuros desenvolvimentos.

Dificuldades Computacionais

Prever qualquer coisa, para qualquer ser humano comum, não é uma tarefa trivial. Requer, no mínimo, que se esteja inserido em algum contexto e que se tenha muito conhecimento prévio sobre o assunto. Inserir *contexto* e *conhecimento* dentro de um software é ainda mais difícil. Normalmente não é possível dar à máquina todas as informações possíveis e pertinentes ao assunto para que ela seja capaz de resolver qualquer situação de um determinado problema. Normalmente se define um sub-conjunto do espaço de soluções que melhor represente o espaço total. Este, então, se torna o responsável pela definição de como a solução será alcançada.

O problema de previsão de acordes musicais é bastante complexo sendo, em muitos casos, de difícil solução até para os melhores músicos. Existe uma enorme quantidade de estilos, além da grande variedade de formas de se tocar uma mesma música, o que vai ser muito influenciado pelo estilo de cada músico, pelo que ele esteja querendo expressar naquele momento e até pelo que os outros músicos estejam tocando no momento.

Resolver um problema deste tipo requer uma análise detalhada de uma série de variáveis presentes no contexto musical e que podem ser de função decisiva na implementação do preditor. Encontrá-las e analisá-las é uma tarefa que está intimamente relacionada com a definição do conceito de um acorde musical para a máquina. Como ele será representado para o computador. Basicamente, o acorde pode ser definido como uma *tupla* de algumas destas variáveis mais relevantes a sua caracterização. A definição hoje mais usada é a seguinte:

Acorde = [Tônica, Categoria]

Cada uma destas variáveis (Tônica: C - A - G / Categoria: Maj7 - Min) tem sua função e definição dentro do contexto musical. Sua relevância na formação de um conceito bem

definido de uma acorde musical em música tonal parece ser indiscutível. Com esta definição é possível, até certo ponto, realizar previsão porque existem sequências típicas dentro das músicas tonais, como por exemplo II - V, II - V - I, que facilitam a identificação de padrões dentro da música por parte do preditor. Entretanto, não é muito difícil perceber que esta é uma forma bastante simplificada de definir um acorde. Se analisarmos o problema em maior profundidade percebemos que existem outras variáveis dentro do contexto musical que exercem, às vezes, fundamental influência na definição de qual será o próximo acorde dentro de uma música. Qual então seria a melhor e mais eficaz forma de definir o que venha a ser para a máquina um acorde musical? Que variáveis vão representá-lo?

Dentro de uma sequência musical, além de muitas vezes estarmos a mercê da inspiração do próprio músico que pode mudar a forma de tocar uma música que ele já tocou de uma determinada maneira, existem fatores inerentes a estrutura musical que podem traduzir a forma como o músico prevê o próximo acorde dentro de uma sequência musical. É intuitivo saber que se for tocado um acorde do tipo *Dm7* seguido de um *G7*, ambos com a mesma duração, pode-se concluir com alguma certeza que o próximo acorde será um *C*. Entretanto, se por exemplo o *Dm7* demora o dobro do tempo do *G7*, pode-se achar que o próximo acorde seja um *Db7(#11)*, para que em seguida surja o *C*. Ainda poderíamos ter uma sequência com um *Em7(9)* seguido de *A7*, depois os mesmos *Dm7* e *G7*, todos com a mesma duração. O próximo acorde poderia ser um *Cm7* seguido de um *F7* em vez de um *C*. Que conclusão poderíamos tirar desta explanação? Mesmo nas sequências musicais com aparentemente o mesmo padrão de acordes (*Dm7 G7*), temos diferentes acordes seguindo-se a eles. Por estes simples exemplos, podemos perceber a quantidade de variáveis que podem existir dentro da estrutura de uma música e que podem e devem contribuir na definição do conceito de um acorde musical para a máquina. No primeiro caso vemos claramente a importância da variável 'duração'. Quanto um acorde dura naquele momento da música. No segundo caso percebemos a importância das informações de contexto de cada música, ou seja, a importância do histórico de acordes que foram tocados anteriormente dentro da música. Tudo isto contribui, em muitos casos, de forma decisiva para definição de qual será o próximo acorde a ser tocado.

Definir qual será a representação ideal para um acorde, entretanto, não é o único problema que enfrentamos. Partindo desta análise começamos a constatar uma série de dificuldades e problemas que guiaram as nossas decisões sobre a maneira de como tratar o nosso problema. Por exemplo, a tarefa de definir um conjunto de regras que fossem capazes de exprimir e definir qual seria o próximo acorde em uma sequência musical é de extrema dificuldade, pois não existem regras universais dentro da música. O que acontece durante a execução de uma música, quais acordes serão tocados, depende muito do músico, daquilo que ele pode estar sentindo naquele momento e do que os outros músicos estão tocando. Além disto, cada música tem suas próprias peculiaridades, suas próprias características que podem definir esta ou aquela sequência em particular. Os próprios músicos muitas vezes não sabem como responder porque tocaram aquele acorde particular naquele momento, o que traz, logicamente, uma série de dificuldades a respeito de como definir o problema e conseqüentemente, de como definir regras que pudessem resolver o problema. Daí porque a

melhor solução para este tipo de problema parece ser uma que seja baseada na observação de exemplos, ou seja, baseada em *aprendizado supervisionado*, que é aquele em que os algoritmos recebem padrões de exemplos como entrada e adaptam sua estrutura interna para que a sua saída corresponda a saída desejada (Russel & Norvig, 1996). Por exemplo, poderíamos fornecer como entrada os três últimos acordes de uma música e dizer qual deveria ser o próximo acorde. O algoritmo, com os três acordes fornecidos como entrada, produziria uma saída e a compararia com a que deveria ser, de fato, a saída, que também fora fornecida. Cada vez que a comparação não fosse correta ele readaptaria a sua estrutura interna no sentido de diminuir o erro cometido. O processo de aprendizagem seria composto, então, pela apresentação de um conjunto pré-definido de padrões de exemplos e seria concluído quando a taxa de erros atingisse o seu valor mínimo.

Uma outra dificuldade presente no nosso problema é a questão da dimensionalidade. Em outros casos exemplo de problemas de previsão de séries temporais (Masters, 1996), como o de previsão de cargas elétricas, de vazão de água em barragens ou de queda ou alta de ações em bolsas de valores, percebemos intuitivamente que é necessário a definição de uma série de variáveis capazes de compor o problema e o aprendizado. Entretanto, em todos estes casos, apenas uma variável será predita. Seja ela a quantidade de cargas, a vazão de águas ou a queda ou alta de ações. Em nosso caso, estamos prevendo qual será o próximo acorde dentro de uma música. Porém, este acorde é formado por uma tupla de não menos que três variáveis (tônica, categoria, duração), o que aumenta a dimensão e a dificuldade do nosso problema, pois o preditor terá que prever não menos que três variáveis.

Um outro problema relacionado com a dimensão é o do tamanho da entrada. Como definir quantos acordes são necessários para que se possa prever o próximo? É importante definir o quanto do passado é importante para que se possa chegar a esta dimensão da entrada.

Estas dificuldades definem o nível do nosso problema e não têm resolução direta, dependendo de um trabalho experimental detalhado. Em nossa abordagem fizemos vários testes com redes neurais e com um algoritmo de aprendizagem baseado em árvores de decisão, mais especificamente ID3.

3. Estado da Arte

Hoje, o único trabalho de que se tem notícia nesta área foi o realizado por Bellinda Thom e equipe da universidade de Carnegie Mellon, (Thom, 1995). Foi desenvolvido um estudo sobre a previsão de acordes em músicas de jazz através da comparação de técnicas de predição e aprendizagem.

A primeira destas técnicas foi chamada de *off line*, e tentava extrair similaridades harmônicas de dentro das músicas de jazz e conseguir com isto capacidade de generalização. Para tanto foi realizado um processo de aprendizado sobre um conjunto estático de canções armazenadas em uma base de dados.

A segunda técnica foi chamada de *on line*, e foi baseada em uma aprendizagem em tempo real, onde cada canção era o seu próprio conjunto de teste e onde o preditor

começava sem qualquer tipo de conhecimento armazenado e a medida que a música ia sendo tocada uma base ia sendo incrementalmente construída. Esta técnica foi testada devida a constatação de que muitas informações eram bastante dependentes de cada música e que, conseqüentemente, modelos adaptativos seriam bastante necessários.

Por fim, uma última técnica foi testada e chamada de *híbrida*. Ela tentava somar as características fortes do aprendizado usado na técnicas *on line* e *off line* em um único modelo e assim obter melhores resultados.

Seu estudo começa com algumas considerações sobre porque não usar este ou aquele algoritmo de aprendizagem para realizar a previsão de acordes. Devido ao que ela considera uma "falta de uma contínua medida de similaridade" entre cada par de acordes, ela descarta o uso de algoritmos de aprendizagem como as redes neurais, os que usam técnicas de aproximação de funções, técnicas de vizinho mais próximo e algoritmos de aprendizagem discreta que só respondem sim ou não.

Para realizar a aprendizagem, ela usou um algoritmo baseado nos *modelos n-gram* usado pela comunidade de linguagem natural (Bell *et al.*, 1990) e que é capaz de realizar aprendizado incremental e é baseado na probabilidade de acontecer um acorde tendo acontecido já uma determinada sequência anterior de acordes. Em particular, a predição é dada por:

$$\Pr(i | f_{t+n}, \dots, f_t) = \Pr(i, f_{t+n}, \dots, f_t) / \Pr(f_{t+n}, \dots, f_t)$$

onde f_t é o acorde mais recente e f_{t+n} é o acorde mais antigo no intervalo de acordes que foram definidos como necessários para que se pudesse prever qual seria o próximo.

Foi definido que um acorde seria representado por sua tônica e sua categoria.

Os testes por ela realizados resultaram em taxas de acerto girando em torno de 42% a 53% entre os modelo *off-line*, *on-line* e *híbrido*, sendo o modelo híbrido o que teve a melhor performance.

Levando em conta os resultados apenas regulares apresentados pelo presente trabalho, fizemos algumas observações e levantamos algumas críticas e idéias que poderiam vir a melhorar os resultados obtidos se tivessem sido melhor exploradas e que terão um enfoque maior em nosso trabalho:

1. Nenhuma informação sobre a melodia da música no processo de aprendizagem ou teste foi adicionada. Esta informação, sem dúvida, enriqueceria estes processos podendo trazer melhores resultados
2. O corpus de músicas utilizado para o aprendizado e teste foi totalmente transposto para uma única tonalidade, o que diminui o realismo dos testes.
3. A codificação dos acordes é muito pobre. Apenas a tônica e a categoria do acorde foram usadas para definir um acorde musical e já constatamos a importância que uma outra série de variáveis poderia ter na definição de um acorde musical e de como isto poderia influenciar o aprendizado e predição.

4. Nossa Abordagem

O nosso objetivo é basicamente ser capaz de prever um acorde corretamente dentro de uma sequência musical. Para tanto, nos propusemos a realizar uma série de testes com alguns algoritmos de aprendizagem de diferentes paradigmas com o intuito de, primeiro definir qual deles parece ser o que dá os melhores resultados, para em seguida definirmos como trabalhar para dele extrair os melhores resultados.

A idéia foi a de realizar alguns testes com um algoritmo de aprendizagem conexionista, uma rede neural, mais especificamente o modelo Multilayer Perceptron usando o algoritmo de aprendizagem backpropagation (Rumelhart & McClelland, 1986), e um algoritmo de aprendizagem simbólica, o ID3 (Quinlan, 1986), que é baseado em árvores de decisão.

Para o nosso caso de estudo o processo de aprendizado foi realizado a partir de sequências de acordes de uma base de canções que receberam codificações adequadas para serem passadas para a rede neural e para o ID3. A idéia de como realizar o aprendizado partiu do princípio de como o músico percebe e prevê qual será o próximo acorde de uma música que ele não conhece. Normalmente, ele houve dois, três e, às vezes, até quatro acordes para poder ter condições de perceber qual será o próximo. Partindo desta idéia, todo o processo de aprendizado foi guiado através da apresentação de um conjunto de acordes de entrada (dois, três ou quatro) e do fornecimento, para rede neural ou para o ID3, de qual seria o próximo acorde após este conjunto de acordes de entrada (aprendizado supervisionado). Assim, para cada canção que teve as suas sequências de acordes codificadas foram tomados, em princípio, por exemplo, os três primeiros acordes como conjunto de entrada e o quarto acorde como o acorde que deveria ser aprendido. Em seguida, tomou-se os três próximos acordes como entrada e aquele que se seguia a eles como saída, e assim sucessivamente como mostra a figura 1.

4.1 O Multilayer Perceptron - Backpropagation

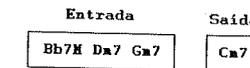
O modelo de rede neural escolhido para realizar os primeiros testes no presente problema foi o do *Multilayer Perceptron* usando o algoritmo de backpropagation.

Com forte base matemática o MLP-backpropagation associa unidades básicas de processamento, os neurônios, em camadas que são estimulados por uma determinada entrada, produzindo uma saída cujo valor dependerá dos valores de pesos que estão associados a ligações existentes em cada unidade de processamento. Os valores destes pesos são definidos durante o processo de aprendizagem através do algoritmo backpropagation que os altera de forma que seus valores guardem as informações necessárias ao aprendizado.

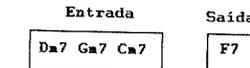
Música

Bb7M Da7 Gm7 Cm7 F7 Bb7

Inicialmente, toma-se os três primeiros acordes como entrada e quarto como aquele que deve ser aprendido



Em seguida, toma-se os três próximos acordes como entrada e o que se segue a eles como o que deve ser aprendido:



Daí o processo se segue até o final da música!

Figura 1 - Como ocorreu o aprendizado

Todo este processo de aprendizado é, normalmente, bastante demorado sendo realizado, às vezes, várias vezes a partir da alteração de parâmetros de configuração da rede que podem definir um novo rumo para o aprendizado e uma melhor ou pior taxa de acertos para a rede. Na figura 2 damos uma idéia de como o processo de aprendizado ocorreu com a rede neural. Neste exemplo, a rede está recebendo como entrada os acordes *Dm7*, *Gm7* e *Cm7* e como saída *F7*.

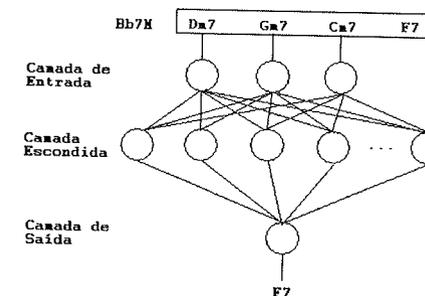


Figura 2 - O Funcionamento da Rede Neural

4.2 ID3

ID3, que significa "Induction of Decision Trees", é um sistema de aprendizado supervisionado que constrói regras de classificação na forma de árvores de decisão. Ele toma um conjunto de objetos, o conjunto de treinamento, como entrada e constrói a árvore de decisão a partir do particionamento deste conjunto. São escolhidos atributos que dividem o conjunto de treinamento e a árvore é construída sobre cada destes sub-conjuntos até que todos os membros de cada um deles pertençam a mesma classe.

Uma função heurística é usada para escolher o melhor atributo capaz de separar o conjunto de treinamento. Uma má escolha deste atributo pode afetar o resultado final. A versão original de ID3 tratava apenas valores discretos, sofrendo depois algumas

modificações para tratar também atributos contínuos. Em fase de teste, apenas os atributos de fato relevantes são usados para separar o conjunto. Se estão faltando atributos durante a classificação, todos os possíveis ramos são explorados e a mais provável classificação é escolhida.

ID3 foi desenvolvido por Quinlan e é talvez o mais usado algoritmo ML na comunidade científica e em sistemas comerciais. É um algoritmo que tem uma alta capacidade de classificação mesmo em conjuntos de dados com muito ruído e tem uma rápida fase de aprendizado com baixa complexidade.

5. Trabalho realizado

O trabalho proposto por Bellinda Thom levanta algumas dúvidas não deixando claro porque exatamente não usar técnicas como as baseadas em redes neurais, ou as baseadas em algoritmos simbólicos, para testar suas capacidades na previsão de acordes. Partindo destas dúvidas e da intuição de que estas técnicas poderiam trazer bons resultados para o nosso trabalho, uma série de testes foram realizados usando a rede neural MLP-backpropagation e o algoritmo de aprendizagem simbólica ID3.

Após uma análise sobre as possíveis informações que poderiam contribuir para a formação e definição de um acorde musical, chegamos às seguintes variáveis que formaram a tupla que definiu o acorde musical usado em nossos experimentos:

[Tônica, Categoria, Intervalo, Posição no Compasso, Posição na Música, Duração]

Cada uma destas variáveis representa características bem definidas de cada acorde. A seguir definimos cada uma delas:

- **Tônica:** É o que define qual acorde será tocado. Ex: C, D, E, etc;
- **Categoria:** É o tipo do acorde que será tocado: Ex.: min, maj7, etc;
- **Intervalo:** é o intervalo que separa o presente acorde do anterior a ele. Ex.: min, maj, etc
- **Posição no compasso:** Variável que indica a posição do acorde dentro do compasso em que ele se encontra na música;
- **Posição na música:** Variável que define a posição do acorde dentro da música. Ex.: Begin, End, Turnround, etc;
- **Duração:** Variável que representa a duração do acorde. Ex: 1,2 3,4, etc.

Usando um corpus formado por 58 canções de jazz e usando a definição acima para representar cada acorde, realizamos uma série de testes e obtivemos os seguintes resultados:

5.1. Resultados obtidos com a Rede Neural:

Foram realizados testes com treinamento usando dois, três e quatro acordes de entrada para a rede tentar prever qual seria o próximo. Definiu-se que, aproximadamente 75% da base de acordes criada constituiria o conjunto de treinamento da rede e que, aproximadamente, 25% da base de canções seria usada para formar o conjunto de testes. O

software utilizado para realizar os treinamentos e testes foi o Qnet97 que possui um mecanismo interno que possibilitou a realização de validação cruzada automaticamente.

Nos primeiros testes, expostos na Tabela 1, a rede foi treinada objetivando a previsão de todas as variáveis que compunham a tupla de um acorde. Eis alguns dos melhores resultados obtidos:

Número de Acordes de Entrada	Número de Unidades na camada escondida da rede	Número de interações de treinamento	Erro médio no conjunto de teste	Erro médio no conjunto de treinamento
2	10	2600	19.4%	19.0%
3	10	12000	16.8%	14.2%
4	10	2000	19.5%	19.0%

Tabela 1: Previsão de todas as variáveis de formação do acorde

Em seguida, foram realizados uma série de testes com dois e três acordes de entrada para a rede, com o aprendizado objetivando a previsão de um acorde formado apenas pela tônica e pela sua categoria, pois estas duas informações resolveriam grande parte dos nossos problemas. Os melhores resultados estão expostos na Tabela 2.

Número de Acordes de Entrada	Número de Unidades na camada escondida da rede	Número de interações de treinamento	Erro médio no conjunto de teste	Erro médio no conjunto de treinamento
2	10	10000	16.3%	11.2%
3	10	10000	15.4%	11.5%

Tabela 2: Previsão de Tônica e Categoria

5.2 Resultados obtidos com ID3:

Foram realizados testes na mesma base de canções, objetivando a previsão, em princípio, apenas da categoria do acorde (Tabela 3), depois da tônica e categoria do acorde (Tabela 4).

Com validação cruzada	Usando 25% do conjunto de pares de entrada e saída para testes	Erro médio
Não	Não	13.4%
Sim	Não	23.2%
Não	Sim	24.8%
Sim	Sim	25.7%

Tabela 3: Previsão de Tônica

Com validação cruzada	Usando 25% do conjunto de pares de entrada e saída para testes	Erro médio
Não	Não	23.7%
Sim	Não	44.8%
Não	Sim	49.8%
Sim	Sim	48.0%

Tabela 4: Previsão de Tônica e Categoria

6. Conclusão

Objetivamos o desenvolvimento de algo pioneiro dentro da área da computação aplicada à música, haja visto que ninguém publicamente tratou este problema tão detalhadamente. Diante dos nossos primeiros resultados já concluímos que o sistema de fato é factível e que, partindo da idéia de que usamos praticamente o estilo musical de maior complexidade harmônica, que é o jazz, em todos os nossos testes, supõe-se que obteremos resultados bem melhores em estilos mais simples e populares.

Apesar de não termos usado o mesmo corpus que o utilizado por Thom em seu trabalho, estes primeiros testes que realizamos mostram resultados bem superiores aos resultados obtidos em seu trabalho.

Apesar destes bons resultados, principalmente com as redes neurais que parecem ser o melhor caminho para a resolução deste problema, uma série de outros testes ainda serão realizados, principalmente para busca da melhor forma de representar o acorde. Existem outros aspectos e variáveis que em muitos casos são fundamentais na decisão de qual acorde tocar. Variáveis como a tonalidade local de uma música e a própria melodia são intuitivamente de grande importância e serão objeto do nosso próximo passo de análises e estudos.

7. Referências

- Bell T. C., Cleary J. G. & Witten I. H. (1990). *Text Compression*. Prentice Hall Advanced References Series, Prentice Hall, New Jersey.
- Masters T. (1996). *Neural, Novel and Hybrid Algorithms for Time Series Prediction*. Wiley.
- Quinlan, J. R. (1986). *Induction of Decision Trees*. *Machine Learning*, 1:81-106.
- Rumelhart D.E. & McClelland J.L. (1986). *Parallel Distributed Processing*, volume 1. MIT Press.
- Russel S. & Norvig P. (1996). *Artificial Intelligence: A Modern Approach*. Prentice Hall, Englewood Cliffs New Jersey 07632
- Thom B. (1995). *Predicting Chordal Transitions in Jazz: The Good, the Bad, and the Ugly*. 14th International Joint Conference on Artificial Intelligence (IJCAI-95) Montréal, Canada
- Weigend, A. S. (1993). *Time Series Prediction; Forecasting The Future And Understanding The Past*. Addison Wesley Pub Co. Volume 0015.

Controle Paramétrico MIDI Usando Interface Gestual Ultrassônica

FURIO DAMIANI^{1,2}, JÔNATAS MANZOLLI² E GILBERTO MENDES¹

UNICAMP - Universidade Estadual de Campinas / 13081-970 Campinas, SP Brasil

furio@fee.unicamp.br, jonatas@nics.unicamp.br

¹Faculdade de Engenharia Elétrica e de Computação

²Núcleo Interdisciplinar de Comunicação Sonora

Abstract

An application of an ultrasonic interface (IGu), developed in the Gestual Interfaces Laboratory at NICS is presented. A short description of the IGu is given. The parametric MIDI control developed is described as well as its functionality. The IGu has a small ultrasonic transmitter, worn by the user in one finger, sending signals to a sensor array. The finger position is sampled 80 times per second, generating a stream of coordinates (x,y,z) that are fed to the parametric MIDI control program. A set of MIDI parameters controlled by the coordinates values was established, in order to give interesting sound output capabilities. The control program uses a graphic interface to ease the system's utilization.

INTRODUÇÃO

O trabalho interdisciplinar aqui apresentado faz parte dos objetivos do Laboratório de Interfaces Gestuais, na linha de estudo de sistemas para o sensoramento gestual e de software para utilização em performances de produção musical interativa.

Tem havido um interesse crescente em Interfaces Gestuais para uso em situações de performance. Nos mais recentes SBC&M foram apresentados trabalhos sobre composição interativa usando interfaces de diversos tipos [Iazetta 1994; Kuntzenback & Hulteen 1993; Lima & Wanderley 1996; Mulder 1994; Manzolli 1995]. Estes dispositivos permitem efetivar propostas de interação onde o movimento do *performer* é um dos vetores geradores da composição musical.