

REDE DE NEURÓNIOS IMPULSIVOS APLICADA À MONITORIZAÇÃO DE DESGASTE DE FERRAMENTAS DE CORTE

R. Silva, V. Pereira, C. Oliveira e J. Ferreira
Universidade Lusíada de VN Famalicão
Largo Tinoco de Sousa
4760-108 Vila Nova de Famalicão, Portugal
rsilva@fam.ulusiada.pt

RESUMO

As redes neuronais do tipo sigmoidal e os neurónios do tipo McCulloch-Pitts têm sido objecto de investigação aplicada devido às suas principais características de abstracção e generalização a partir de informação sensorial com elevados índices de ruído. Recentes avanços na investigação de redes biológicas de neurónios, que comunicam através de impulsos, sugerem que o instante de disparo é também utilizado na codificação e descodificação de informação de uma forma mais eficaz. Neste artigo é apresentada uma versão simplificada, e realisticamente funcional, de uma arquitectura de rede neuronal não supervisionada que recorre a neurónios do tipo impulsivo e é demonstrado que a arquitectura computacional proposta possui uma maior capacidade para descodificar a informação proveniente do processo de corte, para classificação do nível de desgaste de ferramentas de corte, recorrendo a estruturas mais pequenas que as utilizadas normalmente em redes de neurónios do tipo sigmoidal.

Palavras-chave

Rede de Neurónios Impulsivos; Maquinação; Monitorização; Desgaste de Ferramentas

1. Introdução

A indústria tem vindo a fazer um esforço no sentido de reduzir custos e melhorar a produtividade, o que tem conduzido ao fabrico de equipamentos mais produtivos e autónomos. Desde o início da década de 1990 que se verifica uma mudança da velha prática de mudar ferramentas de corte automaticamente para a institucionalização de procedimentos de mudança baseados na monitorização do desgaste das ferramentas, através da implementação de mecanismos adaptativos de inspecção. No caso das máquinas ferramentas, os sistemas de inspecção são designados por “Sistemas de Supervisão de Ferramentas de Corte” (TCM – na literatura anglo-saxónica “Tool Condition Monitor”). O objectivo principal da aplicação dos TCMs é aumentar a produtividade e competitividade através da maximização do tempo de vida das ferramentas, da minimização de tempos de preparação, da redução de desperdícios e da prevenção de danos. Assim, uma apropriada e oportuna decisão para uma mudança de ferramenta é significativamente relevante em sistemas de maquinação. A tradicional habilidade do operador para determinar a condição da ferramenta, baseado na sua experiência e sentidos, isto é, visão e audição, é agora o papel atribuído ao sistema de monitorização. Uma estratégia importante para apoiar este sistema é baseada em sensores e no controlo em tempo real das características fundamentais das máquinas e dos produtos, ao longo do processo industrial.

Para justificar o investimento de capital, associado à instalação de equipamento de produção flexível, é necessário atingir o máximo de utilização possível desse equipamento. Esta necessidade, aparentemente simples de satisfazer, tem sido alvo de diversos obstáculos, na sua grande maioria decorrentes do facto do processo de corte possuir uma dinâmica muito complexa. Para ultrapassar estas dificuldades, neste artigo apresenta-se uma metodologia que implica a selecção de sensores e a implementação de uma estratégia de monitorização com base na selecção de indicadores da condição da ferramenta e a definição de um classificador, isto é, de uma avaliação da informação coligida e processada para determinar o nível de desgaste da ferramenta.

Este artigo está subdividido em quatro secções principais: uma secção introdutória sobre a monitorização de ferramentas de corte e o seu estado de evolução, uma introdução às redes neuronais impulsivas e sua adequabilidade à tarefa de monitorização de condições de desgaste de ferramentas de corte e uma secção dedicada ao trabalho experimental de validação e simulação de resultados.

2. Sistemas de Supervisão de Ferramentas de Corte

A necessidade de monitorização de um processo de maquinação é pertinente, não só sob o ponto de vista da monitorização do equipamento, como também das ferramentas de corte e da própria peça a maquinar, de forma a contribuir para o rendimento óptimo do sistema. Um sistema de monitorização de desgaste de ferramentas, TCM, pode, desta forma, ser visto como servindo os seguintes objectivos (Byrne et al. [1]):

- Detectar eficazmente falhas no processo de corte;
- Verificar e salvaguardar a estabilidade do processo de corte;
- Determinar a forma pela qual a tolerância na peça é mantida dentro de limites aceitáveis providenciando um mecanismo compensador de desvios de desgaste da ferramenta; e,
- Evitar danos nas ferramentas e máquina.

Vários factores têm dificultado avanços no desenvolvimento de TCMS, nomeadamente a escolha inadequada de indicadores sensoriais e sua utilização. O comportamento casual ou aleatório pode ser atribuído à variação em larga escala da homogeneidade do material em corte. De uma forma geral, a maior parte dos processos de corte podem ser classificados como possuindo uma ou mais das seguintes características (Warneche et al. [2]):

- Comportamento complexo ou caótico, em virtude da não homogeneidade do material da peça;
- Grande sensibilidade dos parâmetros do processo relativamente às condições de corte; e,
- Relação de não linearidade entre os parâmetros do processo e o desgaste das ferramentas.

Um modelo mecanicista é teoricamente o modelo mais preciso que pode ser desenvolvido para qualquer sistema. No entanto, infelizmente os recursos necessários para desenvolver tal modelo, mesmo para os sistemas mais simples, tornam a sua adopção proibitiva. A complexidade do processo de corte é facilmente compreendida analisando um processo de torneamento, em que os mecanismos de desgaste de ferramentas ocorrem, geralmente, em combinação com o modo de desgaste predominante, dependendo das condições de corte, peça e material das ferramentas e da geometria da pastilha de corte. Para uma dada ferramenta de corte e material da peça, a forma do desgaste da ferramenta pode depender exclusivamente das condições de corte, principalmente da velocidade de corte, V , e da espessura da apra não deformada, t , e de uma combinação de diferentes mecanismos de desgaste. Por vezes, a vida útil da ferramenta pode ser consideravelmente reduzida se a área de corte, isto é, a área de contacto da ferramenta de corte, for aumentada de forma significativa (conseguido principalmente através do aumento da profundidade de corte). Para velocidades de corte reduzidas, o desgaste da ferramenta dá-se predominantemente por arredondamento da aresta, tornando-se esta, conseqüentemente, menos afiada. Por outro lado, a formação de cavidades depende em larga medida da temperatura de corte e não da velocidade. Conseqüentemente, a previsão de sistemas complexos, caracterizados por serem mal compreendidos, com ruído e não lineares, pode ser impraticável, quando baseada em algoritmos de predição de modelos tradicionais (Parlos et al. [3]).

Desta forma, os engenheiros dependem de técnicas de identificação de sistemas para estabelecerem modelos de processos. À semelhança de modelos lineares, as redes neuronais artificiais (na literatura anglo-saxónica, *artificial neural networks*, ANN) providenciam uma descrição da relação entre as variáveis de causa-efeito. Um dos benefícios das ANN relativamente a modelos lineares é terem a capacidade de modelar relacionamentos não lineares. Na realidade, diversos estudos já demonstraram que as ANN são capazes de modelar qualquer função não linear para uma dada precisão, como apresentado por Cybenko [4] e Hornik et al. [5]. Adicionalmente, as ANN têm tido crescente aceitação na investigação associada a sistemas de fabrico, devido à sua capacidade de adaptação e robustez em ambientes ruidosos (Balazinski et al. [6]).

No entanto, de acordo com uma comunicação de Lennox et al. [7], relativa a um extenso estudo sobre aplicações de redes neuronais artificiais na área da monitorização e controlo de processos, apesar de estas trabalharem em certas condições, a maior parte das aplicações sofre de algum tipo de limitação. Uma extensa investigação tem vindo a ser feita relativamente ao desenvolvimento de TCMs fiáveis. No entanto, nenhum modelo proposta foi até ao momento aceite universalmente (Dan and Mathew [8]; Dimla [9]). Vários factores contribuíram para o atraso no desenvolvimento de TCMs, incluindo a escolha inapropriada de descritores de sinais de sensores bem como a sua utilização. Uma das principais razões para a escassez de utilização de TCMs em aplicações industriais prende-se com o facto de que este tipo de sistemas ter vindo a ser desenvolvido, primordialmente, com base em modelos matemáticos, necessitando, conseqüentemente, de uma grande quantidade de informação empírica. Um outro obstáculo tem a ver com a natureza e características genéricas dos sinais de sensores utilizados que tendem a ser estocásticos e não-estacionários, dificultando, assim, a sua modelação (Silva et al. [10]).

De acordo com Dimla et al. [11], para se conseguir uma monitorização fiável do desgaste de ferramentas é necessário incorporar algum grau de inteligência no *software* e possivelmente utilizar múltiplos sensores. Numerosos estudos têm sido

descritos na literatura ([2, 9, 12]) que demonstram a eficácia desta abordagem, sendo alguns deles especificamente aplicados a processos rotativos ([8, 13]).

3. Rede de Neurónios Impulsivos

Os modelos computacionais com base em sistemas neuronais têm-se, na sua grande maioria, concentrado no processamento de estímulos estáticos. Apesar disto, numerosos sinais biológicos, à semelhança dos que provêm do processo de maquinação, possuem uma estrutura temporal rica que é ignorada na grande maioria das abordagens. Em muitas tarefas de processamento de sinal, como a audição, quase toda a informação se encontra embutida na estrutura temporal. No domínio da visão, o movimento representa uma das mais importantes características extraídas pelo sistema nervoso. Consequentemente, não é surpreendente que nos últimos anos tenha havido um interesse crescente sobre os aspectos dinâmicos do processamento neuronal. O processamento de estímulos reais e variantes no tempo é um problema complexo e representa um desafio para os modelos artificiais de funções neuronais, à luz da investigação realizada por Natschläger and Maass [14]. Simultaneamente, no domínio da ciência dos computadores, áreas como a visão por computador, robótica e aprendizagem com auxílio do computador estimulam a importância inerente aos aspectos relacionados com a componente temporal da informação.

Recentemente têm sido estudados modelos de redes neuronais artificiais que exploram uma outra vertente dos paradigmas de aprendizagem e que tomam por base a componente temporal [15], algo que até ao momento tinha sido deficientemente explorado. Estas novas redes têm por base modelos de neurónios que fazem a codificação temporal da informação e possuem maior poder computacional que as redes do tipo sigmoidal, com base nos princípios introduzidos por McCulloch–Pitts, e são capazes de modelar a habilidade dos neurónios biológicos codificando informação no exacto instante em que se dá a activação do neurónio [16], ou seja, recorrendo à estrutura temporal do sinal e reconhecendo o impacto desta mesma estrutura, não se limitando à utilização da frequência impulsiva de activação, Bugmann [17] e Maass e Ruf [18]. Uma das classes de modelos desenvolvidos até ao momento, modelos com base na condutância, tem origem no trabalho, já clássico, desenvolvido por Hodgkin and Huxley [19] que sumariaram os seus trabalhos experimentais sobre o axónio do polvo gigante em quatro equações diferenciais.

Até à data deste trabalho, a grande maioria dos sistemas de supervisão de ferramentas de corte baseadas em redes neuronais dependem dos conceitos tradicionais apresentados por McCulloch and Pitts [16]. No entanto, mais recentemente tem-se vindo a acumular evidência experimental que sugere que as redes neuronais biológicas, que comunicam através de impulsos, usam a temporização destes impulsos para codificarem e processarem a informação [20]. Na monitorização de condições de ferramentas, a informação capturada do processo de corte possui uma estrutura temporal rica [21], devendo o sistema supervisor ser capaz de fazer o processamento em tempo real. De acordo com o sugerido, estas novas arquitecturas computacionais de redes neuronais baseadas em neurónios impulsivos, também designados por neurónios integradores (na literatura anglo-saxónica *integrate-and-fire*), revelam um poder computacional superior ao do das redes do tipo sigmoidal, ou neurónios de tipo McCulloch-Pitts [22].

4. Trabalho Experimental

Com base nas considerações acima apresentadas foi realizado trabalho experimental aprofundado sobre o processo de desgaste de ferramentas de corte num torno, para coligir informação com origem no processo. Neste trabalho, foi obtido um conjunto de dados através da maquinação de uma barra de secção circular de aço macio em condições reais de produção, isto é, a uma velocidade de corte de 350 m/min., um avanço de 0.25 mm/rot. e uma profundidade de corte de 1 mm. O conjunto de sensores utilizado incluiu: um acelerómetro para medir vibrações; um microfone para registar a emissão de som; extensómetros colocados no suporte da ferramenta para medir forças; um sensor para medir a corrente consumida pela máquina CNC. O trabalho experimental foi realizado num torno CNC, Moog MT 50, e a aquisição de sinal foi obtida a uma frequência de 20 kHz por canal, tendo os dados dos sensores sido adquiridos com intervalos de 2 minutos. O tempo de vida típico de cada pastilha foi de 15 min. Foram registados dados de amostragem para 6 pastilhas. A dimensão de cada amostragem foi de 512 pontos adquiridos na parte central da barra. Cada conjunto de pontos registados foi processado para gerar as características/indicadores usados na fase de classificação. Um total de 12 características foi extraído dos dados de som e vibração: média, primeiro, segundo e terceiro momento estatístico (desvio padrão, *kurtosis* e *skewness*) e a energia nas bandas de frequência (2.2-2.4 e 4.4-4.6 kHz) obtidas dos espectros. Duas características adicionais, forças de corte tangencial e na direcção de corte, foram também extraídas. Os resultados mostram que a classificação do desgaste de ferramentas é difícil na presença de ruído e torna-se assim necessário que essa classificação seja feita por um método que possa resolver a complexa correlação entre diferentes características para produzir uma classificação consistente com o desgaste.

5. Modelo Computacional – Rede de Neurónios Impulsivos (SNN)

Apesar da popularidade atribuída aos modelos computacionais de redes neuronais supervisionadas, a necessidade subjacente ao processo de aprendizagem obriga a que exista uma classificação do desgaste da ferramenta de corte para cada amostra. Esta abordagem diminui as possibilidades de sucesso de determinado sistema de monitorização com perspectivas de utilização em ambientes reais de produção e, conseqüentemente, restringe a capacidade de generalização de uma rede neuronal. A monitorização do desgaste da ferramenta para cada amostra implica a paragem da máquina e conseqüente aumento de tempos de preparação, tornando o método impraticável, pois existe um número elevado de condições de corte que requerem aprendizagem e conseqüente monitorização e aprendizagem. É desejável que um sistema para monitorização em tempo real possua redes neuronais cuja aprendizagem possa ser efectuada com recurso a um número reduzido de amostras e, conseqüentemente, a um número reduzido de paragens, sendo desta forma aconselhado o uso de redes não supervisionadas. Por outro lado, a aprendizagem com base em redes neuronais não supervisionadas permite que seja feita a validação de cada indicador, uma vez que não estão condicionados por objectivos que podem não ser representativos da verdadeira essência da característica/indicador utilizado. A rede faz a modelação em função das características/indicadores e não de uma forma forçada a partir da indicação de desgaste. Pelas razões indicadas anteriormente, e tendo por base as vantagens introduzidas com as redes de neurónios impulsivos, é possível concluir que um modelo de rede neuronal não supervisionada, com base em neurónios impulsivos, reúne características que potenciam o sucesso deste esquema de sistema de monitorização de desgaste de ferramentas de corte.

Como demonstrado por Maass [16], os neurónios do tipo integrador (*integrate-and-fire*) possuem a capacidade de processar somas pesadas incorporando a dimensão temporal, onde o tempo de disparo de determinado neurónio codifica um valor que, de acordo com a sua magnitude, determina o instante em que este realizou um disparo. Cada neurónio de saída, numa arquitectura básica de redes de neurónios impulsivos, recebe uma soma pesada de contribuições de cada neurónio da camada anterior, que poderá ser a camada de entrada. Cada neurónio de saída dispara assim que determinado limite é atingido. O instante em que o disparo ocorre permite determinar a classe ou tipo de padrão em uso. A aprendizagem é centrada no primeiro neurónio a disparar, para que esse neurónio de saída se torne cada vez mais representativo da classe ou padrão apresentado à rede. O esquema de aprendizagem não supervisionado recorre a um conjunto de vectores representativos de determinado universo que é apresentado de forma aleatória à rede de neurónios.

Com base nos argumentos anteriores, e recorrendo aos princípios de funcionamento e aprendizagem de redes neuronais tradicionais, é apresentado de seguida o modelo computacional desenvolvido com base em neurónios impulsivos.

- I. Iniciar os pesos entre o neurónio i e todos os neurónios da camada seguinte j ;
- II. Apresentar um vector de entrada s_i^l , aleatoriamente seleccionado a partir do conjunto de vectores característicos de todos os estados de desgaste onde se inclui a componente tempo;
- III. Determinar a soma pesada entre o vector de entrada S_i e cada um dos neurónios de saída v_j , com intervalos de tempo δ (resolução temporal da aquisição), utilizando a seguinte equação,

$$Pot_j = \sum_i w_{ij} s_i^l$$

- IV. Seleccionar o neurónio que ultrapassa determinado limite θ e actualizar todos os pesos recorrendo à seguinte equação,

$$\Delta w_{ij} = \eta (1 - t_j) (s_i^l - w_{ij}),$$

Onde t é o tempo de disparo do neurónio j e η o ritmo de aprendizagem que é reduzido linearmente com o tempo de aprendizagem.

- V. Repetir para cada intervalo de tempo, indo para o passo III;
- VI. Repetir, indo para o passo II.

A implementação consistiu no desenvolvimento de três componentes: normalização do vector de entrada; aprendizagem; classificação.

6. Simulação e Resultados

A simulação teve lugar utilizando um algoritmo, similar ao descrito acima, baseado nos resultados de trabalho experimental prévio onde foram usadas 4 pastilhas com vários patamares de desgaste., Foram utilizados 16 indicadores no vector de entrada, um por cada característica obtida a partir de dados experimentais, e um numero variável de neurónios de saída.

Foram feitos testes para classificação dos níveis de desgaste desconhecidos utilizando duas pastilhas. O gráfico apresentado na Figura 1 é representativo dos tempos de disparo de um neurónio de saída em função do nível de desgaste, medido experimentalmente, para cada um dos vectores de entrada apresentados.

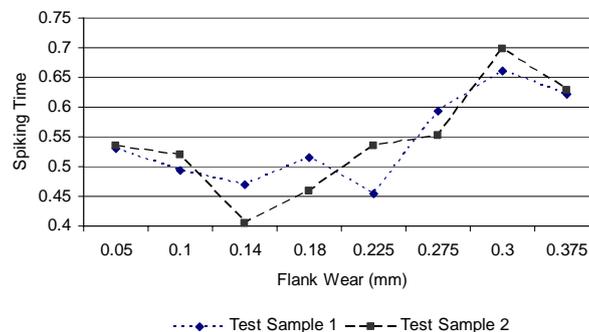


Figura 1 – Resposta característica para classificação de ferramentas desconhecidas

Os resultados demonstram e validam a possibilidade de recorrer a este tipo de arquitectura na classificação de ferramentas de corte quanto ao seu desgaste. Os testes realizados demonstraram que todos os neurónios de saída reagem de forma similar, isto é, inicialmente há uma resposta rápida a cada entrada. No entanto, e à medida que o tempo de aprendizagem vai passando, os neurónios topologicamente próximos reagem de uma forma semelhante a determinado padrão de vector de entrada, ou seja, a níveis de desgaste semelhantes. Em resposta a esta observação foram feitas simulações que implicavam a redução do número de neurónios de saída até se ficar, no limite, com apenas um neurónio de saída. Foi observado que a aprendizagem continuava a acontecer e residia no tempo de resposta, ou tempo de disparo, do neurónio.

Podemos observar que, para os estágios iniciais de desgaste, a classificação não é clara. No entanto, e dado o número reduzido de amostras testadas, podemos concluir que os resultados são encorajadores e potenciam a utilização de redes de neurónios impulsivos nas mais diversas áreas que se caracterizam pela sua estrutura temporal inerente.

7. Conclusão

Este artigo descreve a implementação de um sistema de apoio à decisão para monitorizar o desgaste de ferramentas de corte, tendo por base uma rede de neurónios impulsivos. Foi evidenciado que o sistema desenvolvido possui a capacidade de distinguir entre diferentes níveis de desgaste de pastilhas de corte num ambiente industrial caracterizado por elevados níveis de ruído.

A redução em número de neurónios demonstrada anteriormente potencia a sua utilização em condições reais de funcionamento e mostra que a codificação temporal tem um enorme impacto na estrutura da rede e na consequente tarefa de classificação. Os resultados sugerem que desta adaptação pode advir um grande avanço se comparado com anteriores abordagens que utilizam redes neuronais tradicionais.

Agradecimento

A investigação para este artigo foi parcialmente comparticipada pela FCT – Fundação para a Ciência e a Tecnologia, Portugal. Project Referência POCTI/EME/59491/2004.

Bibliografia

- [1] G. Byrne, D. Dornfeld, I. Inasaki, G. Ketteler, W. König & R. Teti, Tool condition monitoring (TCM) - the status of research and industrial application, *Annals of CIRP*, 44, 1995, 541–567.
- [2] A. Warnecke, A. Jenewein & A. Reinfelder, Tool monitoring based on process identification, monitoring and control for manufacturing processes, *Winter Annual Meeting of the ASME*, Dallas, TX, USA, 1990, 43–55.

- [3] A. Parlos, O. Rais & A. Atiya, Multi-Step-Ahead Prediction Using Recurrent Neural Networks, *Neural Networks*, 13, 2000, 765-786.
- [4] G. Cybenko, Approximation by superposition of a sigmoidal function, *Mathematics of Control, Signals and Systems*, 2, 1989, 303-314.
- [5] K. Hornik, M. Stinchcombe & H. White, Multilayer feedforward networks are universal approximators, *Neural Networks*, 2, 1989, 359-366.
- [6] M. Balazinski, E. Czogala, K. Jemielniak & J. Leski, Tool condition monitoring using artificial intelligence methods, *Engineering Applications of Artificial Intelligence*, 15, 2002, 73-80.
- [7] B. Lennox, G. Montague, A. Frith, C. Gent & V. Bevan, Industrial application of neural networks – an investigation, *Journal of Process Control*, 11, 2001, 497-507.
- [8] L. Dan & J. Mathew, Tool wear and failure monitoring techniques for turning - a review, *International Journal of Machine Tools and Manufacture*, 30, 1990, 579-598.
- [9] D. Dimla, Sensor signals for tool-wear monitoring in metal cutting operations - a review of methods, *International Journal of Machine Tools and Manufacture*, 40, 2000, 1073-1098.
- [10] R. Silva, R. Reuben, K. Baker & S. Wilcox, The Adaptability of a Tool Wear Monitoring System Under Changing Cutting Conditions, *Mechanical Systems and Signal Processing*, 14, 2000, 287-98.
- [11] D. Dimla, P. Lister & N. Leighton, Neural network solutions to the tool condition monitoring problem in metal cutting – a critical review of methods, *International Journal of Machine Tools and Manufacture*, 37, 1997, 1219-1241.
- [12] E. Jantunen, A summary of methods applied to tool condition monitoring in drilling, *International Journal of Machine Tools and Manufacture*, 42, 2002, 997-1010.
- [13] S. Choudhury, V. Jain & C. Rao, On-line monitoring of tool wear in turning using a neural network, *International Journal of Machine Tools and Manufacture*, 39, 1990, 489-504.
- [14] T. Natschläger & W. Maass, Spiking neurons and the induction of finite state machines, *Theoretical Computer Science*, 287, 2002, 251-265.
- [15] W. Gerstner, Spiking neurons, in: *Pulsed Neural Networks* (W. Maass, C. Bishop, MIT Press, Cambridge. 1999).
- [16] W. Maass, Networks of spiking neurons: the third generation of neural network models, *Neural Networks*, 10, 1997, 1656-1671.
- [17] G. Bugmann, Biologically plausible neural computation, *Biosystems*, 40, 1997, 11-19.
- [18] W. Maass & B. Ruf, On computation with pulses, *Inform. Comput.* 148, 1999, 202-218.
- [19] A. Hodgkin & A. Huxley, A quantitative description of membrane current and its application to conduction and excitation in a nerve, *Journal of Physiology*, 117, 1952, 500-544.
- [20] W. Maass, Computation with spiking neurons, in: *Pulsed Neural Networks* (W. Maass, C. Bishop, MIT Press, Cambridge. 1999).
- [21] R. Silva, R. Reuben, K. Baker & S. Wilcox, Tool Wear Monitoring of Turning Operations by Neural Network and Expert System Classification of a Feature Set Generated from Multiple Sensors, *Mechanical Systems and Signal Processing*, 12, 1998, 319-32.
- [22] B. Ruf & M. Schmitt, Learning temporally encoded patterns in networks of spiking neurons, *Neural Processing Letters*, 5, 1997, 9-18.