

DETECÇÃO INTELIGENTE DE AVARIAS EM MOTORES - D I A M -

António José Ferreira da Silva

Departamento de Engenharia Mecânica, Instituto Superior de Engenharia do Porto
Rua de S. Tomé, 4200 Porto, Portugal.
Telefone: +351-2-8340500
Fax: +351-2-821159
Email: fsilva@dem.isep.ipp.pt

Fernando José Ferreira

Departamento de Engenharia Mecânica, Instituto Superior de Engenharia do Porto,
Rua de S. Tomé, 4200 Porto, Portugal.
Email: fjfer@dem.isep.ipp.pt

Resumo. *Nos últimos anos, os Algoritmos de Optimização, com base em processos de evolução natural das espécies, têm vindo a ser aplicados com sucesso em diferentes domínios. De entre estes, as Redes Neurais Artificiais (RNAs) e os Algoritmos Genéticos (AGs) assumiram-se como umas das mais populares e importantes ferramentas.*

O DIAM é um sistema de ajuda na detecção de avarias em motores. É na realidade um Sistema Pericial para obtenção de Diagnósticos de Avarias em Motores. O sistema foi desenvolvido de modo a atender não só às necessidades internas da escola (fim didáctico), como também constituir-se numa potente ferramenta informática de ajuda prática para oficinas de automóveis especializadas (componente industrial).

Dada a natureza combinatoria deste tipo de problemas, onde a procura de soluções exige esforços computacionais elevados, uma via para contornar este problema, ou seja, para a minimização do esforço computacional, centra-se no uso AGs para procurar os parâmetros óptimos da rede neuronal, no espaço vectorial que nos dá as soluções possíveis para o problema em equação. Através desta associação conjunta de AGs e RNAs, chamada GANN, procurou-se para o problema em estudo, maximizar as vantagens de cada método.

Palavras-chave: Algoritmos genéticos, Redes neurais artificiais, Previsão de séries temporais

1. MOTIVAÇÃO

O desenvolvimento tecnológico a que assistimos nas últimas décadas, trouxe consigo a necessidade de uma reflexão e revisão profunda dos métodos de ensino até aqui praticados. O

reflexo no ensino da engenharia (em particular da engenharia mecânica), não poderá passar despercebido aos agentes de ensino que somos nós os professores.

A oportunidade surgiu com a necessidade de criação de um novo curso de engenharia (Engenharia ElectroMecânica), no Instituto Superior de Engenharia do Porto. Este foi o pretexto para um debate mais alargado e profundo sobre o ensino de engenharia. Os autores como parte interessada neste processo, foram responsáveis pelo seu departamento, na formulação, discussão, elaboração e materialização da componente de Engenharia Mecânica que integra o curso. Só a inevitável necessidade de aproximação do ensino às novas fronteiras do conhecimento e às novas tecnologias, permitirá uma melhor adaptação às realidades emergentes.

É opinião consensual dos professores e educadores que nada pode substituir completamente o contacto com a realidade que nos cerca, o Mundo que é afinal o objecto das nossas ciências. Mas é notável que possamos hoje, com a ajuda de computadores, criar mundos alternativos onde experimentemos as sensações de movimento e acção. Dado o ritmo a que estão a ocorrer progressos no domínio das tecnologias da informação e o presumível impacto desses progressos na ciência e no ensino, sugere-se que a comunidade científico-pedagógica se envolva em projectos de investigação e/ou divulgação de tecnologias desse tipo. É responsabilidade dos professores e educadores actualizarem, sempre que possível, os seus meios e técnicas de ensino, por forma a assegurarem aos seus alunos, em cada momento, os processos de aprendizagem que julgarem mais adequados (Fiolhais et al).

O uso de sistemas de simulação de última geração (sistemas que são altamente interactivos e contêm uma considerável quantidade de “inteligência” embutida), apresentam-se hoje como uma poderosa ferramenta para ensino e aprendizagem (não só em ambientes académicos, mas também industriais). Estes sistemas, permitem a transmissão do conhecimento de uma forma mais rica e interactiva, quando comparados com os métodos expositivos tradicionais. O sistema que aqui será descrito (DIAM – Detecção Inteligente de Avarias em Motores), foi por nós desenvolvido no Instituto Superior de Engenharia do Porto (ISEP), em cooperação com a empresa Salvador Caetano (Toyota), e é um sistema simulador de avarias em motores, estando actualmente a servir de apoio a aulas do curso de Engenharia Mecânica. A diversidade, normalmente também associada à complexidade de problemas passíveis de ocorrer neste domínio, envolve a necessidade de um conhecimento pericial que permita lidar com diferentes tipos de informação de maneira sistematizada.

Dada a natureza combinatória deste tipo de problemas, onde a procura de soluções exige esforços computacionais elevados, uma via para contornar este problema, ou seja, para a minimização do esforço computacional, centra-se no uso de AGs para procurar os parâmetros óptimos da rede neuronal, no espaço vectorial que nos dá as soluções possíveis para o problema em equação. Através desta associação conjunta de AGs e RNAs, chamada GANN, procurou-se para o problema em estudo, maximizar as vantagens de cada método.

O sistema actualmente existente, resulta de uma evolução do sistema SIDAM (Ferreira et al 1997), ao qual foi acrescentado um módulo de prevenção de avarias. Esta nova componente cumpre os objectivos que se julgaram essenciais para uma futura e mais rápida inserção no meio industrial, mas também permitir uma maior sensibilização para a importância desta componente, no meio académico.

O sistema encontra-se neste momento numa fase de validação e teste na escola, prevendo-se já a curto prazo a sua progressiva inserção na indústria. Está previsto a curto prazo, uma actualização do sistema com vista à introdução de melhorias/actualizações que o tornem mais útil e adaptável à realidade quer académica quer industrial.

2. OBJECTIVOS PROPOSTOS PARA O SISTEMA

O projecto DIAM, tem um cariz fundamentalmente pedagógico, não descurando contudo a componente industrial. O sistema poderá e deverá ser utilizado indistintamente que no meio académico quer num ambiente industrial.

Procurámos que na vertente pedagógica os seguintes objectivos fossem atingidos:

- despertar os alunos para o uso das novas tecnologias;
- apoiar o ensino da engenharia (mecânica), numa disciplina de detecção de avarias;
- permitir a detecção de avarias simuladas;
- criar metodologias de trabalho na detecção de avarias;
- permitir a previsão fundamentada de avarias;
- ilustrar os procedimentos.

De um ponto de vista industrial procurou-se:

- motivar o meio industrial para o uso das novas tecnologias;
- criar um sistema inteligente para detecção de avarias;
- criar um sistema inteligente que seja capaz de “aprender” com a experiência adquirida no meio industrial (experiências reais);
- utilizar a experiência adquirida para possibilitar a previsão de avarias;
- criar um sistema inteligente que permita a análise estatística de dados reais existentes sobre veículos (ex: identificação de avarias características de determinado modelo).

3. A IMPORTÂNCIA DA PREVISÃO

É natural assumir que as organizações estão interessadas em obter previsões fundamentadas de certos tipos de indicadores, especialmente acerca daqueles que possam influenciar a tomada de decisões (Cortez et al. 1998).

Este desejo de compreender o passado e prever o futuro impulsiona a procura de leis que expliquem o comportamento de dados fenómenos ou acontecimentos. Se são conhecidas equações determinísticas que os explicam, então é possível efectuar previsões, desde que conhecida a sua génese. No entanto, na ausência de regras que definam o comportamento de um sistema, procura-se determinar o seu comportamento futuro a partir de observações do passado (Weigend et al. 1994)

No sector automóvel, a previsão de avarias é, quando possível, fundamental. Permite uma maior fiabilidade do veículo com custos menores. Ao nível do sistema construído, a previsão de avarias, permite que as revisões periódicas aos veículos que são recomendadas, sejam actualizadas, de forma a contemplar este aspecto (ver exemplos de funcionamento do sistema). Para a previsão de avarias em motores, a técnica que utilizamos, socorre-se da chamada Previsão de Séries Temporais (PST), que se baseia em observações da variável, ou variáveis, em estudo. O objectivo, é prever o comportamento de sistemas e não o seu funcionamento. Na situação em questão, tratou-se fundamentalmente de prever o aparecimento de avarias com base nas informações existentes numa base de dados, contendo informações nomeadamente sobre manutenção de veículos, casos anterior de avarias, etc.

4. REDES NEURONAIS ARTIFICIAIS

As Redes Neurais Artificiais (RNAs) são modelos conexionistas com a capacidade de aprender a partir do conhecimento de situações passadas, dando resposta a novas situações,

especialmente em problemas com uma forte componente de ruído e/ou informação incompleta. Esta é a razão principal das vantagens comparativas que alcançaram em áreas tão distintas como os sistemas periciais, a filtragem de dados, a visão por computador ou o planeamento.

Porém, as RNAs não podem ser vistas como a solução universal para todos os tipos de problemas (Russel et al 1995). De facto, uma das dificuldades que resulta do uso de RNAs para a resolução de problemas reside no tempo despendido com a procura do melhor tipo de rede ou topologia. Uma outra dificuldade tem a ver com a melhor forma de alimentar os dados a uma rede, num processo que se designa por pré-processamento.

Quando se usam RNAs algumas escolhas têm que ser feitas à partida. Estas escolhas são normalmente feitas, olhando à especificidade do problema. Por outro lado, atendendo a que a maior parte dos trabalhos em curso nesta área utiliza RNAs feedforward, esta situação é aqui entendida como um bom motivo para se adoptar este tipo de redes neste trabalho.

Tendo como objectivo reduzir o espaço de soluções, foi decidido usar redes completamente interligadas com bias¹, com apenas uma camada intermédia e sem ligações de atalho. O uso de redes completamente interligadas permite que não haja preocupações com a existência ou não existência de ligações entre nodos, o que simplifica todo o processo. O peso do bias aumenta o potencial da RNA para assimilar informação sem acrescentar complexidade, dado que este valor é definido, de forma automática, pelo algoritmo de treino. Por outro lado, a maior parte das aplicações apenas força à utilização de uma camada intermédia. Por este motivo, achou-se ser esta a topologia a seguir, dado que o uso de camadas extra iria aumentar a complexidade da rede de forma desnecessária.

5. ALGORITMOS GENÉTICOS

Os Algoritmos Genéticos (AGs) são exemplos de máquinas de aprendizagem, que se baseiam em processos de selecção natural. Os AGs assumem-se como procedimentos de optimização, passíveis de serem aplicados à panóplia de parâmetros que fazem a solução de um problema, gerando variantes que através de competição, podem convergir para uma melhor solução. Assim, embora os AGs usem processos estocásticos, os resultados obtidos são claramente superiores aos conseguidos por procura aleatória.

Os AGs são normalmente utilizados em problemas de natureza combinatória, onde a procura de soluções exige esforços computacionais demasiado elevados.

6. COMBINANDO ALGORITMOS GENÉTICOS COM REDES NEURONAIS

As RNAs (do tipo feedforward) são ferramentas poderosas para a resolução de problemas, em particular os de classificação e de aproximação. No entanto, o esforço colocado na procura da melhor das redes, ou seja, sua estrutura e parâmetros do algoritmo de treino, é normalmente proibitivo (Russel et al 1995).

Por outro lado, e embora tanto os AGs como as RNAs se assumam como estratégias de procura universal, há estudos que mostram que o seu comportamento é função do domínio de aplicação (Kitano 1990). Os AGs realizam uma procura globalmente superior à das RNAs. Por backpropagation leva-se mais tempo a atingir a vizinhança de uma boa solução, mas esta é atingida de forma mais precisa. Por outro lado, os AGs ao varrerem todo o espaço de

¹ Neste tipo de redes, existe uma célula especial, cuja saída é sempre 1, e que está ligada a todas as células; o peso desta ligação é chamado bias.

soluções, posicionam-se mais rapidamente sobre a região com a melhor destas. Todavia não convergem necessariamente para essa, uma vez que a optimização da procura depende quase exclusivamente da operação de mutação.

Assim, combinar ambas as estratégias de procura, nos chamados sistemas GANN (Genetic Algorithms and Neural Networks), aproveitando as vantagens de cada uma das partes, pareceu-nos ser um caminho promissor a seguir. Esta via, com raízes nos anos oitenta, tem sido desde então objecto de atenção; há estudos empíricos que mostram que os sistemas GANN podem ultrapassar, em eficiência, quer os AGs quer as RNAs, na resolução de problemas.

7. OS SISTEMAS GANN

Os sistemas GANN melhoram o desempenho das RNAs de duas formas: por evolução da topologia da rede através dos AGs e por aprendizagem via backpropagation, processo este que socorre-se em particular das aprendizagens Lamarckian² e Baldwin³.

Pela primeira, os pesos, associados às ligações da RNA, são codificados em cromossomas, evoluindo pelo AG. Pela segunda, que segue um modelo caro a Darwin, a aprendizagem da RNA guia a procura evolucionária. Se uma rede está próxima do óptimo, então por backpropagation se chegará a esse óptimo, o que se traduzirá num bom valor para a aptidão da rede. Soluções (cromossomas), perto do óptimo, por partilharem muitos padrões, fazem com que o AG seja capaz de as explorar por amostragem no hiperplano.

Uma vez que o AG desempenha o papel de uma função de optimização de segunda ordem, a escolha dos parâmetros deste não é muito crítica. Baseado em alguma intuição, experiência e tendo em conta o binómio eficiência computacional – eficácia da solução, foi decidido usar uma população de 30 (trinta) indivíduos, selecção baseada na ordem, cruzamento de um ponto e taxa de mutação de 0,02 “Fig.1”.

Ou seja, inicialmente um conjunto de indivíduos são gerados aleatoriamente, sendo depois cada rede concebida de acordo com a informação do (seu) genoma. A aptidão é função do treino da rede. Após avaliação, todos os indivíduos são ordenados segundo a sua aptidão. Os operadores de cruzamento e mutação irão criar uma nova população, e os seus constituintes serão avaliados. Finalmente, a selecção baseada na ordem irá escolher as melhores redes para ambas as populações, dando origem a uma nova geração. Este processo continua até que algum critério de paragem seja atingido. De referir que o sistema guarda em memória a melhor rede que entretanto for gerada, devolvendo-a no fim do processo.

8. DESCRIÇÃO DO SISTEMA

O sistema DIAM resulta de uma evolução dum sistema pré-existente o sistema SIDAM (Ferreira et al 1997), ao qual foi acrescentado um módulo de prevenção de avarias. O sistema é fundamentalmente um Sistema Computacional Integrado, que inclui um Sistema Pericial para o diagnóstico e prevenção de avarias “Fig. 2”. O sistema é complementado na sua componente académica com uma bancada de simulação de avarias em motores.

² Jean Baptiste Lamarck (1744-1829). Naturalista francês, autor da *Teoria do Transformismo*, que postula que características adquiridas por uma espécie, durante o seu tempo de vida, podem ser herdadas por gerações futuras.

³ James Mark Baldwin (1861-1934). Psicólogo norte-americano. Foi o primeiro a afirmar que a aprendizagem assim como outros ajustes durante o tempo de vida das espécies podem afectar o curso da evolução.

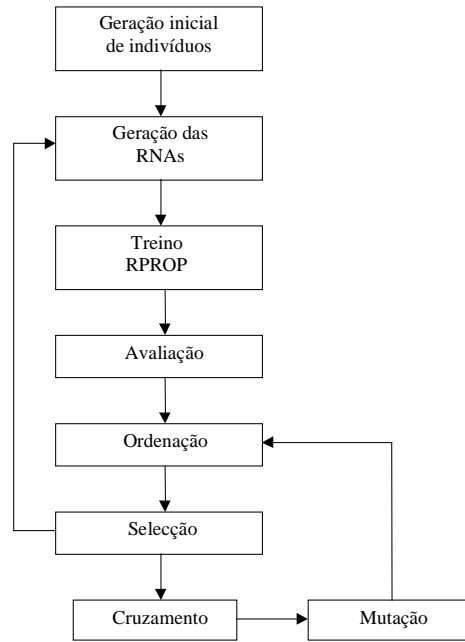


Figura 1 – Estrutura do sistema GANN

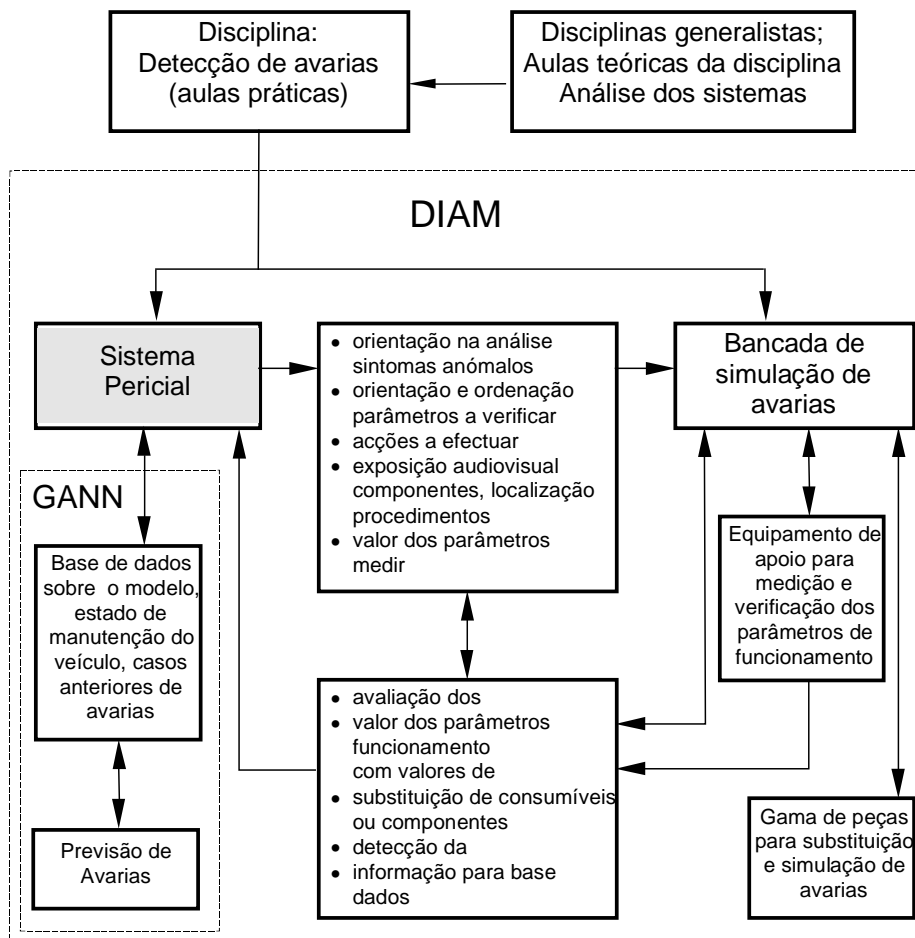


Figura 2 – Diagrama funcional do DIAM

O modelo que foi construído para o processo de detecção de avarias, pode ser visto na “Fig.3”. A tarefa inicial do modelo consiste na identificação de sintomas de mau funcionamento do motor, após simulada uma avaria na bancada. Essa identificação é feita com recurso a um questionário que terá que ser preenchido (ver Menu 1). A identificação das causas prováveis, é feita com recurso a regras de produção. As premissas da regra representam as pré-condições que se devem verificar para que o conjunto de causas prováveis referido na conclusão da regra seja identificado “Fig.4”.




Figura 3 – Modelo do sistema DIAM

A fase que se segue vai definir o escalonamento das causas que foram previamente detectadas. Este escalonamento deverá garantir que as avarias mais prováveis e com uma maior acessibilidade em termos de reparação devam ser postas em primeiro lugar.

Se
sintoma
então
lista de causas prováveis

Figura 4 – Protótipo de uma Regra de Produção

Esta fase do modelo utiliza árvores de decisão “Fig.5”. A cada ramo da árvore corresponde uma causa possível, estando-lhe associada uma probabilidade de ocorrência. A cada folha da árvore corresponde o grau de acessibilidade. O produto destes dois factores dá-nos o mérito de cada hipótese. Havendo (como geralmente acontece) um elevado número de hipóteses, este método permite a optimização do processo (não eliminando causas que sendo pouco prováveis possam todavia ocorrer).

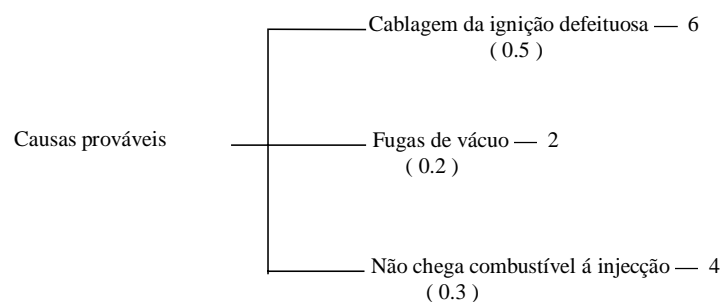


Figura 5 – Árvore de decisão representando três causas possíveis de avarias no motor

Para cada causa possível de avaria, o sistema possui um conjunto variado de informação escrita e audiovisual que permite quer a um utilizador experiente, ou não, seguir de uma maneira simples e objectiva os passos a efectuar para a verificação (dos parâmetros de funcionamento) ou reparação da avaria.

Como pode ser visto na “Fig.3”, em paralelo á identificação dos sintomas, e de uma forma perfeitamente autónoma o sistema permite a previsão de avarias (sistema GANN). O seu diagrama funcional pode ser visto na “Fig.6”.

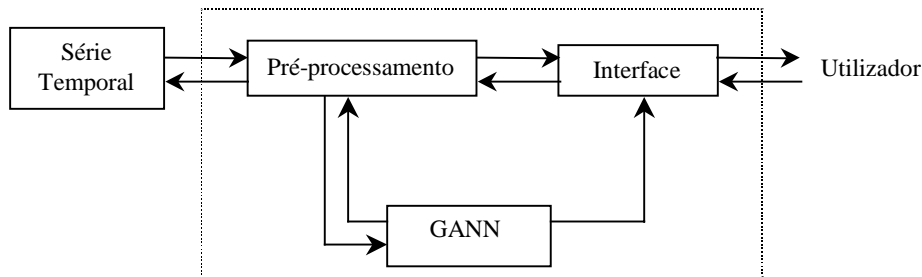


Figura 6 – Diagrama funcional do sistema de previsão de avarias

Todo o sistema foi desenvolvido em Windows 98, sendo usadas as linguagens de programação C⁴ e Prolog⁵. Enquanto que por uma questão de eficiência computacional, a linguagem C é usada na implementação dos AGs e dos procedimentos de treino das RNAs, a linguagem de programação em lógica Prolog é usada para construir todo o resto do sistema.

9. EXEMPLO DE FUNCIONAMENTO DO SISTEMA DIAM

O que a seguir se ilustra, contempla um exemplo de utilização do sistema. Após simulada uma avaria na bancada, o utilizador deverá identificar os sintomas anómalos, preenchendo o menu 1. Validando essa entrada, aparecer-lhe-á o menu seguinte, que é uma lista (ordenada) de causas prováveis, resultado de todo o processo atrás referido (menu 2).

DIAM - Diagnóstico Inteligente de Avarias em Motores	
<i>Atenção declare todas os sintomas que considere relevantes. Tenha em atenção as perguntas que lhe estão a ser feitas</i>	
DETECÇÃO DE AVARIAS	
Quais os sintomas anómalos ?	
Temperatura do motor <input type="checkbox"/> Sobre aquecimento do	Ignição retardada ou pré-ignição <input type="checkbox"/> Explosões no sistema de escape durante a aceleração <input type="checkbox"/> Explosões no sistema de escape <input type="checkbox"/> Ignição adiantada
Arranque difícil <input type="checkbox"/> O motor não roda ou roda <input checked="" type="checkbox"/> O motor não arranca ou tem arranque	<input type="checkbox"/> Consumo de óleo excessivo <input type="checkbox"/> Consumo de combustível excessivo
Marcha lenta irregular <input type="checkbox"/> Marcha lenta instável ou "vai abaixo" ou tem falhas de	<input type="checkbox"/> Vibrações no motor
<input type="checkbox"/> O motor demora a arrancar / Fraca aceleração	
Auto detonação do motor <input type="checkbox"/> O motor continua a funcionar depois de desligar a	

Menu 1

DIAM - Diagnóstico Inteligente de Avarias em Motores
CAUSAS PROVÁVEIS
<ul style="list-style-type: none"> • Cablagem de ignição defeituosa • Cabos de tensão defeituosos ou desligados • Falta de compressão • Folga de válvulas incorrecta • Fugas de vácuo • Não chega combustível a injeção • Ponto de ignição incorrecto • Problemas no sistema de injeção electrónico - EFI • Válvula de EGR defeituosa

Menu 2

O conjunto de explicações (audiovisuais) que o sistema possui, associado a cada uma das causas prováveis pode ser visto num conjunto subsequente de menus. Nesses menus, o utilizador encontra toda a informação necessária para realização do procedimento de verificação e/ou reparação.

Na versão industrial este conjunto de causas prováveis é reordenado com recurso á base de dados. Com base nos dados de entrada (modelo, número de quilómetros, idade), será

⁴ Turbo C da Borland versão 2.0

⁵ LPA Win Prolog versão 3.6

também proposta a manutenção preventiva sobre pontos que o sistema considerou necessários.

O sistema encontra-se neste momento numa fase de teste e validação na escola, sendo já no próximo ano lectivo passível de utilizar pelos alunos (ainda em fase de experimentação). Numa fase posterior passará a ser de utilização corrente nas aulas do curso de engenharia mecânica. A fase seguinte de vida do sistema, passará pelo seu teste e validação num ambiente industrial (oficinas da Toyota).

10. DATA MINING – UMA PERSPECTIVA PARA O FUTURO

Data mining (DM) significa “ajustar modelos a”, ou “determinar relações a partir de” dados observados. Na prática, os principais objectivos de alto nível do DM são prognosticar e descrever. Prognosticar envolve usar algumas variáveis ou campos da base de dados e prever valores desconhecidos ou valores futuros de outras variáveis de interesse. A descrição baseia-se na procura de relações, humanamente compreensíveis, que descrevam os dados.

Em muitas situações como é o caso da industria automóvel, a capacidade de armazenar informações (neste caso dados dos concessionários sobre vendas de veículos, avarias detectadas, reparações mais frequentes, etc..), supera a possibilidade de realmente utilizá-la.

Entretanto, sabe-se que muitas vezes as bases de dados contêm muito conhecimento útil, que infelizmente se encontra de uma forma implícita.

A realidade deste sector em Portugal diz-nos que não só na maior parte das vezes a informação não está disponível (na maioria dos casos é mesmo inexistente), ou quando o está, não contempla um número de casos suficientemente significativo para ser potencialmente interessante de tratar.

Estando o sistema DIAM agora numa fase de validação e teste, temos nesse sentido sensibilizado a componente industrial (Salvador Caetano) para a necessidade de criação e disponibilização de bases de dados com informação relativa aos diversos concessionários espalhados pelo país. Isto irá permitir o tratamento desta informação a dois níveis: ou poderá ser vista num nível mais restrito, onde estará disponível informação relativa a um só concessionário, ou ter uma visão mais alargada (ao nível por exemplo de uma região ou do país todo) de modo a inferir conhecimento a um nível mais global e potencialmente mais interessante.

A procura de informação em dados dispersos leva muitas das vezes à descoberta de tipos de conhecimento que podem tornar-se extremamente úteis para quem os possui, sem acréscimos significativos nos custos.

É por exemplo possível utilizando DM na base de dados sobre clientes tendo como objectivo a definição do perfil do cliente. Desta forma será possível encontrar um padrão de comportamento de clientes na relação pai/filho. Será possível definir descobrir uma regra do tipo: se o pai compra o modelo X então o filho tenderá a comprar também mas optará pelo modelo Y. Desta forma será por exemplo possível adoptar uma melhor estratégia de marketing para estes dois tipos de clientes.

Será possível descobrir avarias relacionadas com quilometragem, actuando assim preventivamente com diminuição de custos para o cliente.

REFERÊNCIAS

Cortez, P. and Neves J. Algoritmos Genéticos e Redes Neurais na Previsão de Redes Neurais. Universidade do Minho, Braga, 1998

Ferreira, S. and Fernando, F. SIDAM – Um Sistema Inteligente para Diagnóstico de Avarias em Motores. In XIV Congresso Brasileiro de Engenharia Mecânica. Bauru, 1997

Fiolhais, C. and Jorge A. Trindade, A Realidade Virtual no Ensino e na Aprendizagem da Física e da Química. http://www.fis.uc.pt/Read_c/RV/Ensino/artigo.htm

Kitano, H. Empirical Studies on the Speed of Convergence of Neural Network Training using Genetic Algorithms. In Proceedings of the Internacional Joint Conference on Neural Networks, vol. II, pp. 397-404, IEE, 1990

Russell, S. and Norvig, P. Artificial Intelligence: A Modern Approach. Prentice-Hall, New Jersey, USA, 1995

Weigend, A. and Gershenfeld, N. Time Series Prediction: Forecasting the Future and Understanding the Past. Addison-Wesley, USA, 1994

INTELLIGENT DIAGNOSIS OF MALFUNCTION ENGINES - DIAM -

Abstract: In recent years the new technology of Genetic Algorithms (GA) and Artificial Neural Networks (NN) have been successfully applied to complex problems of optimisation.

In this paper we present an Expert System called DIAM to automatically diagnose possible causes for motor malfunctioning. The system was developed with the concern of being a useful tool in the specialised automobile workshops. The system was designed and developed in Instituto Superior de Engenharia do Porto (ISEP) in cooperation with the enterprise Salvador Caetano (Toyota).

Expert knowledge is necessary in this domain due to the complexity and diversity of possible problems occurring in automobile engines.

The goal of the GAs is to tune the NN used in the Expert System. The joint use of GAs and NNs, called GANN, enables to profit from advantages of both GAs and NNs.

The combination of GAs and NNs is used, with advantage, in the detection and diagnosing of automobile motor faults.

The system is currently in the testing phase (in ISEP) and we estimate that it will soon be tested in a real automobile workshop.

Keywords: *Genetic algorithms, Artificial neural networks, Time series forecasting*