

Análise de parâmetros de operação de máquinas marítimas

Ribeiro Parreira¹, Valter Vairinhos, ¹Victor Lobo^{1,2}

¹Escola Naval

valter.vairinhos@marinha.pt

ribeiro.parreira@marinha.pt

²ISEGI / UNL

vlobo@isegi.unl.pt

Sumário: Neste artigo propõe-se uma metodologia para determinação dos limites de valores aceitáveis de parâmetros de operação de máquinas marítimas. O método proposto baseia-se na determinação de agrupamentos a partir de dados históricos, usando mapas auto-organizados (SOM), e k-médias.

Palavras chave: clustering, mapas auto-organizados, manutenção, CBM

1- Introdução

A Escola Naval está a desenvolver um projecto de investigação, denominado MECPAB (Monitorização do Estado de Condição e Previsão de Avarias de Bordo), que visa desenvolver técnicas para monitorizar o funcionamento de vários equipamentos de navios, de modo a que seja possível prever e prevenir a ocorrência de avarias. Este tipo de ferramentas permitirá passar de uma política de manutenção essencialmente preventiva para uma política de manutenção baseada na condição, ou CBM – Condition Based Maintenance (Jardine, Lin *et al.* 2006). Neste artigo descrevemos um dos conjuntos de dados sobre os quais estamos a trabalhar, e uma técnica de monitorização que estamos a desenvolver, baseada em técnicas de agrupamento (clustering). Para fazer esse clustering usamos mapas auto-organizados (Self-Organizing Maps - SOM)(Kohonen 2001), e k-médias (MacQueen 1967).

2- Os dados

A maior parte dos navios de guerra moderna dispõem de *sistemas de gestão de plataforma* (SGP) que são essencialmente computadores ou redes de computadores que interligam sensores e sistemas de comando e controlo. Estes sistemas substituíram os antigos sistemas de comando das máquinas, e hoje em dia é através deles que as diversas máquinas do navio são controladas. As fragatas da classe Vasco da Gama, da Marinha Portuguesa, dispõem de um sistema de gestão de plataforma fabricado pela Siemens denominado NAUTOS (Naval Automation System). Este sistema controla não só os motores e turbinas de propulsão, mas também as máquinas auxiliares (como por exemplo geradores e compressores) e equipamento de limitação de avarias (como por exemplo sensores de incêndio ou de alagamento). Ao todo há mais de 2000 sensores ligados ao sistema, havendo várias dezenas em cada um dos dois motores diesel principais. Neste artigo vamos usar dados de um destes motores, referentes a pressões e temperaturas de diversos fluidos do motor (ar de admissão, ar de escape, óleos de lubrificação, *etc.*). Estes dados correspondem à utilização continuada dos motores em diversos regimes de operação. Ao todo, dispomos de 221 observações de 38 parâmetros. Os valores medidos foram normalizados de modo a que todos os parâmetros tenham o mesmo peso.

O sistema NAUTOS foi adquirido na década de 80, e é constituído por um computador central, baseado num microprocessador da família INTEL 80286 com uma arquitectura

própria. Originalmente não estava prevista a possibilidade de exportação dos dados gerados pelos sensores para outro computador. Existe no entanto na consola central do sistema uma *drive* que permite gravar dados em disquetes, embora estes estejam formatados como um relatório (em texto) cuja importação automática não é trivial. No entanto, havia duas impressoras ligadas ao sistema, para onde era possível enviar relatórios definidos pelo operador, onde ficavam registados os alarmes e outros acontecimentos importantes. Na década de 90 a impressora foi substituída por um computador portátil que recebe os ditos relatório. Infelizmente, optou-se por manter o software original do NAUTOS, pelo que neste projecto foi necessário desenvolver um programa para processar os relatórios e produzir uma base de dados que pudesse ser utilizada pelos programas de análise. Esse programa, desenvolvido em *Delphi*, permite fazer uma análise preliminar dos dados, obtendo médias, desvios padrão, percentagens de valores em falta, entre outros.

3 – Análise dos parâmetros em agrupamentos

O próprio sistema NAUTOS permite definir parâmetros “normais” e “de alarme” para cada um dos sensores. Esses parâmetros foram definidos originalmente pelos diversos fabricantes, mas consideram cada sensor individualmente, sem ter em conta o estado de funcionamento do resto do motor. Este tipo de abordagem não permite detectar alguns valores que são claramente indicativos de avarias. A título de exemplo, consideremos a temperatura dos gases de evacuação de um dos cilindros. O fabricante indica valores típicos e máximos para esse parâmetro, e há alarmes que são actuados quando o valor máximo é atingido. No entanto, para cada estado do motor, há valores que são normais, e valores que, não excedendo os valores máximos, são indicadores de potenciais avarias. Quando o motor está a arrancar, por exemplo, uma subida súbita da temperatura de um dos cilindros em relação aos demais, ainda que não excedendo o valor máximo, é claramente indicador de uma avaria. Inversamente, uma temperatura baixa quando o motor está em pleno funcionamento é indicador de outro tipo de avaria. Este tipo de situações exige que a identificação de anomalias seja feita dentro de determinados contextos, ou estados, e não em termos absolutos.

Os diversos estados de referência para os quais são definidos parâmetros “normais” e “anormais” podem ser definidos *a priori* pelo fabricante usando um conjunto de regras. No entanto, isso não foi feito para o sistema NAUTOS, e mesmo noutros SGP essa identificação está longe de ser exaustiva.

Em alternativa, propomos gerar os estados de referência a partir dos dados de operação disponíveis e considerados “normais”. Qualquer desvio destes estados poderá ser considerada suspeita, sendo alvo de intervenção humana. Assim sendo, em vez de haver um conjunto de valores de alarme definido pelo fabricante para cada sensor em todas as situações, passará a haver um número n de valores de alarme definido automaticamente para cada sensor consoante o estado em que o motor se encontra.

A definição dos estados de operação a partir dos dados implica que as observações individuais sejam agrupadas em conjuntos homogêneos, que constituirão os estados de referência. Este é um problema típico de agrupamento onde temos que encontrar quer o número adequado de agrupamentos quer o conjunto de valores que define cada um destes. Propomos resolver este problema usando por um lado k -médias, por outro SOM emergentes (Ultsch 2005).

A resolução deste problema usando SOM é de algum modo semelhante à solução encontrada para resolver problemas de controlo não-linear à custa de múltiplos modelos lineares definidos a partir de SOM (Cho, Principe *et al.* 2006).

4 – Análise dos dados usando SOM

Os SOM, em problemas de agrupamento, podem ser usados de duas maneiras muito distintas (Bação, Lobo *et al.* 2005; Ultsch 2005). Por um lado podemos usar SOM de pequenas dimensões, que têm um desempenho semelhante ao algoritmo k-médias, produzindo um número pré-determinado de clusters. Por outro lado, podemos usar SOM de grandes dimensões, chamados SOM emergentes, que permitem identificar o número de clusters “naturais” nos dados. Se treinarmos um SOM emergente, com 20x30 unidades, e visualizarmos a sua UMAT (Ultsch, Guimarães *et al.* 1993), obtemos os resultados da Figura 1. Nessa figura aparecem claramente 4 clusters bem definidos, representados a azul escuro.




Figura 1 - UMAT obtida a partir do SOM treinado com os dados experimentais. Observam-se claramente 4 clusters bem distintos, representados a azul escuro.

Os resultados obtidos neste pondo podem ser usados de duas maneiras muito distintas. Por um lado podemos usar cada uma das unidades como um estado de referência, sendo as tolerâncias para cada um desses estados definidos pelos valores máximos e mínimos nos seus vizinhos. Neste caso ficaríamos com 600 estados de referência. Por outro lado podemos usar a informação obtida com o SOM sobre a existência de 4 clusters, e usar um método como o k-médias para obter os centroides desses clusters. Neste caso, os valores máximos e mínimos podem ser obtidos a partir da variância dos parâmetros dentro de cada cluster.

5 – Análise com k-médias

Ao aplicar o algoritmo k-médias aos dados, variando o número k de clusters (fazendo 10 inicializações para cada valor de k e utilizando o valor mínimo para cada k), obtém-se o resultado apresentado na Figura 2.

Como previsto, há reduções muito significativas quando o número de clusters pedido cresce de 2 até 4, havendo a partir desse ponto reduções bastante menores. Analisando os centróides desses clusters é possível identificar claramente os estados de operação a que estes correspondem. A título de exemplo, primeiro cluster, correspondente ao canto superior esquerdo no SOM, refere-se ao arranque do motor, enquanto o segundo, correspondente à parte inferior do SOM, refere-se ao motor a funcionar no regime máximo (mas normal) de rotações.




Figura 2 - Variação do erro total com o número de clusters.

6 – Conclusões

A utilização do SOM neste problema permitiu identificar os quatro principais estados de operação do motor. Essa informação pode ser usada para, usando k-médias, obter os valores típicos e erros esperados para cada um dos grupos. Em alternativa, é possível usar directamente os 600 estados correspondentes às unidades do SOM como referências.

A metodologia proposta e testada permite detectar situações de avaria que passas despercebidas usando as técnicas actualmente em vigor.

7 – Bibliografia

- Baao, F., V. Lobo, et al. (2005). Self-organizing Maps as Substitutes for K-Means Clustering. Lecture Notes in Computer Science, V. S. Sunderam, G. v. Albada, P. Soot and J. J. Dongarra. Berlin Heidelberg, Springer-Verlag. **3516**: 476-483.
- Cho, J., J. C. Principe, et al. (2006). "Modeling and inverse controller design for an unmanned aerial vehicle based on the self-organizing map." IEEE Transactions on Neural Networks **17**(2): 445 - 460.
- Jardine, K. S. A., D. Lin, et al. (2006). "A review on Machinery diagnostics and prognostics implementing condition-based maintenance." Mechanical Systems and Signal Processing **20**: 1483-1510.
- Kohonen, T. (2001). Self-Organizing Maps. Berlin-Heidelberg, Springer.
- MacQueen, J. (1967). Some methods for classification and analysis of multivariate observation. 5th Berkeley Symposium on Mathematical Statistics and Probability, University of California Press.
- Ultsch, A. (2005). Clustering with SOM: U*C. WSOM 2005, Paris.
- Ultsch, A., G. Guimarães, et al. (1993). Knowledge Extraction from Artificial Neural Networks and Applications. Transputer-Anwender-Treffen, Aachen, Springer Verlag.