

AUMENTO DE CONFIABILIDADE DE SISTEMAS EMBUTIDOS USANDO REDUNDÂNCIA E ALGORITMOS DE DECISÕES BASEADOS EM RECONHECIMENTO DE PADRÕES

EMERSON. M. A. ALVES

*Departamento de Engenharia e Computação, Instituto Federal de Minas Gerais CAMPUS Bambuí,
Caixa Postal 05 - CEP: 38900- 000, Bambuí – MG*
E-MAIL: emerson.alves@ifmg.edu.br

FRANK. S. TORRES

*Departamento de Engenharia Eletrônica, Universidade Federal de Minas Gerais
Av. Antônio Carlos 6627
CEP: 31270-901, Belo Horizonte - MG, Brazil*
E-MAIL: franksill@ufmg.br

Abstract— Embedded systems are widely applied for data acquisition and data processing in harsh environments. Therefore, system robustness is of utmost importance. Hence, in case of faulty measured data, it is mandatory to possess solutions that prevent that these faults lead to system errors or even generate disasters. This paper presents an approach that improves the reliability of embedded systems for data acquisition. The proposed technique applies a mixture of redundancy techniques and detection of abnormalities based on Pattern Recognition. Experimental results indicate the feasibility of the proposed approach with notable increase of the system reliability.

Keywords— Embedded Systems, Reliability, Redundancy, Pattern Recognition, Data Acquisition.

Resumo— Com o avanço tecnológico, cada vez mais os sistemas embutidos estão presentes em nosso dia a dia. A confiabilidade é um tópico importante, pois os sistemas críticos são controlados pelos sistemas embutidos cada vez mais. Esses sistemas interagem com o mundo que nos rodeia, por meio de informações oriundas da aquisição de dados através de sensores. A correta tomada de decisão desses sistemas depende de uma aquisição de dados confiável. Falhas podem ocorrer em qualquer sistema, entretanto é possível criar mecanismos que impeçam que essas falhas possam trazer danos ou até gerar catástrofes. Este trabalho aborda a melhoria da confiabilidade dos sistemas embutidos através não só de técnicas de redundância, mas também com técnicas de detecção de anormalidades utilizando reconhecimento de padrões. A proposta é unir duas metodologias distintas - redundância e inteligência computacional - que se conectam para contribuir no desenvolvimento de sistemas embutidos mais confiáveis.

Palavras-chave— Sistemas Embutidos, Confiabilidade, Redundância, Reconhecimento de Padrões, Aquisição de Dados.

1. Introdução

A aquisição de dados utilizando sistemas embutidos (Barr & Massa, 2006), (Malinowski, 2011), (Emilio, 2014) tem sido uma ferramenta fundamental para o desenvolvimento tecnológico. Na indústria, tem aumentado muito o interesse nos sistemas de aquisição de dados (Rajpal, 2012), (Medina, 2011), (Gaitan, 2010), uma vez que o controle dos processos produtivos depende da leitura de grandezas físicas, que devem ser amostradas e quantizadas em sinais discretos, ou seja, sinais digitais. Até mesmo sistemas bem projetados estão sujeitos às falhas (Marwedel, 2011) em condições de sobrecarga proporcionada por ambientes agressivos (Alves & al., Congresso Brasileiro de Automática 2012).

A motivação deste trabalho é contribuir para o aumento da confiabilidade (Ranous, 2007), (Gunawardane, 2004), de forma geral, em qualquer processo em que seja possível a entrada redundante de três sinais representados por números reais discretos não aleatórios. Levando-se em conta essas especificações, podem-se considerar os sinais oriundos de sistemas de aquisição de dados analógicos (Smith, 1997), (Nishijima, et al., 2014). Utilizou-se a aquisição de dados para mostrar a aplicação e o funcionamento das metodologias abordadas.

O presente trabalho tem como objetivo um aumento de confiabilidade no sistema de aquisição de dados analógicos para sistemas embutidos. A proposta é que essa melhoria seja alcançada com duas técnicas distintas, que estão diretamente conectadas. A primeira técnica utiliza a redundância (Gosheblagh & Mohammadi, 2014), especificamente Redundância Modular Tripla (TMR) (Microsemi Corporation, 2013), para os sensores do sistema de aquisição de dados, através de um sistema de votação, para ser robusta a falha de um sensor. A segunda técnica utiliza reconhecimento de padrões (Duda, et al., November 9, 2000) para analisar os sinais de todos os sensores e detectar uma mudança no comportamento que poderia indicar uma anormalidade no sinal. A descoberta novos eventos que aparecem no ambiente é denominada detecção de novidades (Modenesi & Braga, 2009), (L, et al., 2014). O objetivo da segunda técnica é completar a primeira, que poderia falhar quando mais de um sinal redundante apresentar falha semelhante.

O restante do trabalho é organizado como seguinte. O capítulo 2 descreve a metodologia proposta da confiabilidade de sistemas embutidos de aquisição de dados. O Capítulo 3 detalha os experimentos realizados não só para aquisição de dados, mas também para aplicações das técnicas estudadas. O Capítulo 4 analisa os resultados dos experimentos. As conclusões

sões e sugestões para trabalhos futuros são apresentadas no Capítulo 5.

2. Metodologia

Este estudo propõe uma nova metodologia, para o aumento da confiabilidade de sistemas embutidos de aquisição de dados, baseado no uso de dois métodos distintos e que estão diretamente conectados. Com essa metodologia propõe-se uma nova técnica para o sistema de votação do TMR.

Um método aborda a utilização da redundância tripla de sensores ou módulos de medição. Nesse método, os três sinais de leitura são avaliados por um sistema de decisão on-line denominado Voter (Neumann, 1956), que define o sinal de saída. O outro método avalia o comportamento das curvas dos sinais após um procedimento completo, como, por exemplo, o procedimento de aquecimento de um forno. O objetivo da avaliação das curvas é detectar mudança no comportamento baseada em curvas históricas consideradas sem falhas. Em resumo, um método define o sinal de saída em relação aos três sinais de entrada, e o outro visa preencher a lacuna deixada pelo método da redundância - essa lacuna está relacionada à ocorrência de falha em mais de um sinal redundante.

Os métodos descritos no parágrafo anterior podem ser visualizados no diagrama da Figura 1. Na parte superior da figura, destacado na cor laranja, é mostrado o grupo do método que utiliza a redundância, denominado TMR Analógico. Esse grupo possui o núcleo de tomada de decisão denominado Voter, que define o sinal de saída após análise de três sinais redundantes de entrada. Os sinais de entrada no Voter são sinais analógicos que foram convertidos em números reais, portanto, sendo sinais analógicos digitalizados a saída do Voter. O critério de escolha para o sinal de saída considera a diferença entre os valores dos três sinais. Existem várias técnicas para o sistema de votação para sinais de valores expressos em números reais, como as técnicas de sistema de votação de escolha do valor do meio, nos quais os valores máximo e mínimo são descartados, e o valor mediano é selecionado.

A técnica aplicada neste *trabalho* baseou nos dois princípios mais utilizados na literatura: votação da maioria e média, conforme citado anteriormente. O Voter é composto pelo bloco de votação de sinais e bloco de média dos sinais votados. Os demais grupos, indicados pela cor azul, fazem parte do método que avalia o comportamento.

O grupo Armazenamento é composto pelos blocos de Banco de Dados e de Extração de Curvas. Este grupo é fundamental, pois toda avaliação de comportamento é baseada em dados históricos. O grupo Treinamento utiliza as curvas históricas, classificadas como “sem falhas”, como referência para a detecção de comportamento alterado de outras curvas. O grupo Detecção de Novidades utiliza os parâmetros de referência para classificar as curvas em: sem falhas

ou com falhas. Como podem ocorrer falhas desconhecidas, utiliza-se o termo detecção de novidades.

A conexão entre os dois métodos é realizada no sinal de saída, do grupo TMR Analógico, interligado com a classificação determinada pelo bloco Detecção de Novidades. A interligação é mostrada pela seta tracejada na cor vermelha na Figura 1. A validação do sinal de saída é objetivada com a conexão entre os dois métodos. Nessa abordagem, os sinais que apresentarem comportamento anormal não serão tratados, entretanto o comportamento vai sinalizar a necessidade de uma intervenção nos módulos de geração desses sinais. A detecção dessa falha será utilizada para evitar a utilização, em bateladas futuras, de sinais com problemas ou para indicar que sensores possuem defeitos intermitentes.




Figura 1 - Diagrama estrutural com a proposta deste trabalho

O treinamento consiste em criar o modelo Gaussiano multivariado (Verges & Sanfeliu, 2005) com a matriz de curvas sem novidade. Em seguida, realiza o cálculo da distância de cada amostra em relação ao centroide do modelo. A distância vai orientar sobre limiar para detectar novidade. Para cálculo da distância, utiliza-se a distância de Mahalanobis (Marsland, 2003).

O primeiro passo é a criação de uma validação cruzada entre todas as curvas que compõem o modelo Gaussiano multivariado. O segundo passo é calcular o modelo Gaussiano multivariado, considerando todas as curvas sem novidades, e tem como saída a média e a matriz de covariância. A terceira etapa consiste em determinar um valor de limiar para um determinado intervalo de confiança, utilizando as distâncias calculadas na primeira etapa. Para a determinação do limiar, é encontrado o quantil para o intervalo de confiança desejado; neste estudo, de 95%. O procedimento para detecção de novidades é através da distância de cada curva em relação à média e à matriz de covariância do modelo, ambas anteriormente calculadas.

3. Experimentos

Neste capítulo são demonstrados os experimentos realizados na planta-piloto com a aplicação das técnicas e métodos apresentados.

A planta-piloto é composta por um forno elétrico, três sensores de temperatura de tipo PT100 (Hyde, 1997), um circuito de aquisição de dados e software de controle do sistema. O software comanda o acionamento do forno, sendo ligado e desligado dentro dos limites inferior e superior de temperatura pré-estabelecidos.

A Figura 2 mostra o gráfico com um grupo de curvas de três PT100, no intervalo de 3500 segundos, que corresponde ao tempo de um ciclo completo de aquecimento e resfriamento do forno.




Figura 2 - Grupo de curvas sem novidades de três sensores PT100 em intervalo com 3500 segundos.

Um grupo de curvas com e sem novidades foi criado, denominado grupo com curvas mistas. O grupo foi gerado com a utilização dos sinais com menor nível de tratamento de dados pelos microcontroladores das placas de aquisição de dados.

É possível observar na Figura 3 a alternância do sinal com ruído, que inicia com o sinal de temp2, ciclo 1 (A); no próximo ciclo não há ruído (B); no terceiro ciclo (C), o sinal de temp1 apresenta um ruído maior e, assim, de forma alternada, exceto para o sinal de temp3 em vermelho.




Figura 3- Grupo de curvas mistas dos sensores PT100, (A) ruído em temp 2 na cor azul, (B) sem ruído e (C) ruído em temp 1 na cor preta, temp 2 na cor azul.

3.1. Experimentos com redundância

Os experimentos foram realizados com a aplicação das técnicas de redundância com TMR.

A técnica foi aplicada nos dados das curvas sem novidade. Na Figura 4, as curvas em cinza-claro são

os sinais dos sensores de temperatura PT100, e a curva preta indica a curva resultante da aplicação do TMR.




Figura 4- Gráfico com curvas dos três PT100 em cinza e a curva de saída do TMR, sinais sem novidades.

Em outro experimento, o TMR foi aplicado em dados em que havia curvas com sinais ruidosos. O comportamento dos sinais e a curva resultante, em preto, são mostrados na Figura 5. É possível observar que a curva resultante atenua os picos dos sinais ruidosos de entrada.




Figura 5- Gráfico com as curvas dos 3 PT100 em cinza, a curva da média em preto.

3.2. Experimentos com reconhecimento de padrões

A aplicação das técnicas de reconhecimento de padrões foi realizada utilizando-se os dados históricos do banco de dados.

O treinamento é realizado com grupo de curvas que não possuem novidades. A Figura 6 mostra o resultado da extração das curvas para treinamento.




Figura 6- Gráfico com as curvas crescentes da operação de aquecimento

Outro grupo é criado com curvas sem novidades, formadas por sinais com menor nível de filtragem de

r  idos no microcontrolador e que recebem tratamento. Esse grupo   denominado grupo de curvas mistas. A Figura 7 mostra o resultado da extra     das curvas para treinamento do grupo de curvas mistas.




Figura 7 – Grupo de curvas mistas dos sinais sem filtro no microcontrolador e ap s a m dia m vel no software supervisor io.

Na Figura 8 est  o as curvas do grupo de sinais sem tratamento. As curvas pertencentes a esse grupo s  o classificadas como curvas com novidades. Esse grupo ser   utilizado para verifica     da capacidade do sistema em detectar novidades.




Figura 8- Curvas com grande variabilidade extra  das do grupo de curvas mistas, consideradas curvas com novidades.

3.3. Detec     de novidades

Fazendo a compara     entre as dist  ncias das curvas do grupo para verifica    , em rela      s curvas sem novidade de treinamento, foi poss  vel detectar novidades. A Figura 9 apresenta a distribui     das dist  ncias das curvas. Os c  rculos representam as dist  ncias das curvas sem novidades, e os tri  ngulos, as dist  ncias das curvas com novidades.




Figura 9- Demonstr     gr fica da aplica     das dist  ncias de Mahalanobis como m trica para detec     de novidades.

4. Discuss    

4.1. Redund  ncia com TMR

N  o foi utilizado um sensor calibrado para a gera     da temperatura de refer  ncia e compara     com os sensores de temperatura PT100. Apesar da desvantagem de n  o possuir uma temperatura de refer  ncia, para as compara    s de efici  ncia dos m  todos aplicados ao Voter, houve a vantagem do desenvolvimento de uma an  lise diferencial entre os sinais. Com essa abordagem, n  o   poss  vel mensurar a diferen  a com o valor correto; entretanto,   poss  vel detectar as diferen  as relativas entre os valores medidos pelos tr  s sensores. Esse m  todo tem se tornado vi  vel dentro do contexto deste estudo, pois o sistema de detec     de novidades vai sinalizar a ocorr  ncia de falhas simult  neas em dois ou nos tr  s sinais de entrada, n  o validando, portanto, o sinal de sa  da.

4.2. Quantidade de curvas para treinamento

Foram geradas, no per  odo do experimento, 183 curvas que foram consideradas sem anomalias e que podiam ser utilizadas para o treinamento do sistema de detec     de novidades.

Como ferramenta para determinar a quantidade m  nima de curvas para treinamento, fez-se uso da matriz de confus     (Simon & Simon, 2010), que   muito aplicada para avalia     de modelos com classes desbalanceadas, o que se aplica ao modelo deste estudo. Dessa forma, foram 31 replica    es, cada uma avaliando 6 curvas, perfazendo um total de 186, ou seja, n igual a 186. Para cada experimento, gerou-se uma matriz de confus     e foi calculado o erro total T_{et} . A matriz de confus     dos experimentos com 30 curvas   mostrada na Tabelas 1.

Tabela 1- Matriz de confus     para o treinamento com 30 curvas.

Classe	Com Novidades	Sem Novidades
Com Novidades	93	0
Sem Novidades	8	85

Observou-se que a varia     da taxa de erro total T_{et} , acima de 30 est  o abaixo de 5%.

4.3. Verifica     do m  todo

Foi realizado um experimento para verifica     do sistema de detec     de novidades, por meio da valida     cruzada. Para a valida     cruzada, foram usadas 60 curvas para treinamento e 60 para teste (valida    ), o que atende ao levantamento m  nimo de curvas realizado com as matrizes de confus    .

O experimento procurou verificar se a capacidade em detectar novidades foi comprometida ap  s a uni  o das curvas de todos os sinais. Seleccionadas as 183 curvas (A), a estrat  gia adotada consistiu em utilizar

60 curvas para o treinamento (B) e realizar uma validação cruzada com outras 60 (C). Essas curvas foram escolhidas de forma aleatória. Após o treinamento e a validação, foi apresentado um grupo com cinco curvas para detecção de novidades (D), como na Figura 10. Fez-se uso de somente cinco curvas, para facilitar a compreensão da detecção de novidades.




Figura 10- Experimento 1 de detecção de novidades com base de curvas para treinamento (A), curvas para treinamento (B), curvas para validação cruzada (C) e curvas para avaliação (D).

O limiar foi calculado para 95% de aproveitamento das curvas de treinamento, com base nas distâncias dessas curvas representadas pelos círculos verdes. Nas curvas de teste da validação cruzada, indicadas pelos pontos triangulares, detectou-se uma curva com distância maior que a do limiar (A). Para curvas com novidades, representadas pelos pontos circulares na cor azul, quatro pontos ficaram acima do limiar. No entanto, um ponto ficou abaixo do limiar (A), como mostrado na Figura 11. O triângulo vermelho indica uma curva de teste da validação com novidades, conforme a Figura 11 (B), que possui uma curva correspondente em (C) indicada pela seta na Figura 10. O círculo azul, que aponta uma curva sem novidade no grupo de curvas com novidades, também possui uma curva correspondente na Figura 10, em (D), indicada pela seta. Isso indica que o sistema foi robusto na detecção de novidades.




Figura 11- Gráfico com as distâncias do treinamento, validação e detecção do sistema de detecção de novidades.

Outro experimento considerou curvas sem falhas de um processo de aquecimento em que foram geradas curvas sem o tratamento dos sinais pelo microcontrolador. Nesse experimento, foram empregadas 40 curvas como base de treinamento, 30 para treinamento. A Figura 12 mostra um grupo com curvas para validação (A) e o grupo com curvas para detecção em (B), com ruído elevado.




Figura 12- Gráfico com o grupo de curvas de validação (A) formadas pelo grupo de curvas sem novidades e o grupo de curvas de sinais ruidosos (B).

Nesse experimento, as curvas de sinais ruidosos foram classificadas como curvas com novidades, conforme Figura 13. O que novamente demonstra que o método é robusto na detecção de alteração do comportamento das curvas dos sinais.




Figura 13-Gráfico com as distâncias do grupo de curvas ruidosas em relação ao grupo de treinamento, ambas oriundas de sinais sem tratamento pelo microcontrolador.

5. Conclusão

A proposta para o aumento da confiabilidade de sistemas embutidos de aquisição de dados, fundamentada no uso das duas técnicas distintas e diretamente conectadas, proporciona um aumento da confiabilidade. Avaliando os resultados dos experimentos, foi possível perceber que a técnica de resposta imediata, baseada na redundância dos sinais analógicos dos sensores do sistema de aquisição de dados on-line, foi eficiente na seleção do sinal de saída. Pôde-se concluir que a conexão da técnica de redundância com a técnica de reconhecimento de padrões preenche a lacuna encontrada no TMR, quando dois ou três sinais possuem anomalias semelhantes, já que a alteração do comportamento pode ser percebida pela detecção de novidades, e isso valida o sinal de saída do Voter. Apesar da existência do atraso entre as duas técnicas de redundância e reconhecimento de padrões, a conexão entre elas possibilita a sinalização de problemas intermitentes no sinal e também pode prevenir uma sequência de bateladas futuras com anomalias, até que a falha leve o sistema ao colapso, gerando prejuízos.

A sugestão para futuros trabalhos é a proposta de detecção de novidades on-line, ou seja, enquanto o sistema está em operação. Assim, seria possível indicar um sinal com novidades para o sistema de votação do TMR.

Agradecimentos

Os autores agradecem ao PPGEE – Programa de Pós Graduação em Engenharia Elétrica da UFMG, ao IFMG Instituto Federal de Minas Gerais Campus Bambuí e especialmente à CAPES e ao CNPq pelo apoio financeiro à elaboração e apresentação desse trabalho.

Referências Bibliográficas

- Alves, E. M. d. A. & al., e., *Congresso Brasileiro de Automática 2012. Vantagens do Desenvolvimento Interno de Sistemas de Automação e Controle: O caso da Liasa, Campina Grande – PB.*
- Barr, M. & Massa, A., 2006. *Programming embedded systems: with C and GNU development tools*, "O'Reilly.
- Duda, R. O., Hart, P. E. & Stork, D. G., November 9, 2000. *Pattern Classification, Hardcover.*
- Emilio, M., 2014. *EMBEDDED SYSTEM SYSTEM DESIGN*, *Electronics world* [1365-4675] vol:120.
- Gaitan, N. C., 2010. *Real-time Acquisition of the Distributed Data by using an Intelligent System*, *Elektronika ir elektrotechnika* [1392-1215].
- Gosheblagh, R. O. & Mohammadi, K., 2014. *Hybrid time and hardware redundancy to mitigate SEU effects on SRAM-FPGAs: Case study over the MicroLAN protocol*, Hyde, . D., 1997. *Evaluating Thin Film RTD Stability*, s.l.*Microelectronics Journal* 45.
- Gunawardane, G., 2004. *Measuring reliability of service systems using failure rates: variations and extensions*, *The International Journal of Quality & Reliability Management* [0265-671X]. vol:21.
- Malinowski, A., 2011. *Comparison of embedded system design for industrial applications*, *IEEE Transactions on Industrial Informatics* [1551-3203] vol:7.
- Marsland, S., 2003. *Novelty Detection in Learning Systems*. *Neural Computing Surveys* , 3, pp. 1-39.
- Marwedel, P., 2011. *Embedded Systems Foundations of Cyber-Physical Systems*. 2nd Edition ed. Springer Science: Business Media.
- Medina, V., 2011. *Embedded data acquisition system with MDSPlus*, *IEEE Transactions on Instrumentation and Measurement* [0018-9456].
- Microsemi Corporation, 2013. *Design of a Safe and Secure Process Control System. Application Example.*
- Modeseni, . P. A. & Braga , P. A., 2009. *Analysis of Time Series Novelty Detection Strategies for Synthetic and Real Data*, *Neural Process Lett Springer Science+Business Media, LLC.*
- Neumann, J. V., 1956. *Probabilistic Logics Automata Studies*, Princeton University Press.
- Nishijima, K., Kanasugi, A. & Ando, K., 2014. *Accuracy improvement of genetic algorithm for obtaining floating-point solution*, *Artificial life and robotics* [1433-5298].
- Rajpal, R., 2012. *Embedded data acquisition system for neutron monitors*, *Fusion engineering and design* [0920-3796].
- Ranous, C. A., 2007. *Reliability, Education*, *IEEE Transactions*. ISSN 0018-9359.
- Simon, D. & Simon, D. L., 2010. *Analytic Confusion Matrix Bounds for Fault Detection and Isolation Using a Sum-of-Squared-Residuals Approach*, s.l.
- Smith, S. W., 1997. *The Scientist and Engineer's Guide to Digital Signal Processing*, Hard Cover.
- Verges, J. & Sanfeliu, A., 2005. *Evaluation of Distances Between Color Image Segmentations*, *IbPRIA 2005, LNCS 3523*.