

ESTIMADOR DE ESTADO ADAPTATIVO PARACONSISTENTE PARA CONSISTENT ADAPTIVE STATE ESTIMATOR

Arnaldo de Carvalho Jr¹, João Inácio da Silva Filho², Mauricio Conceição Mario²

¹Instituto Federal de Educação, Ciência e Tecnologia de São Paulo, Campus Cubatão, R. Maria Cristina, 50 - Casqueiro, Cubatão - SP, 11533-160

²Universidade Santa Cecília – UNISANTA, Rua Oswaldo Cruz 266 Bloco F Sala 84^a, Boqueirão, Santos – SP, 11045907.

Resumo

O Filtro Kalman é um algoritmo capaz de fornecer uma estimativa do valor real de uma grandeza medida, prever uma saída e o grau de incerteza associado, entregando uma média ponderada entre o valor medido e o predito, sendo muito utilizado em sistemas de automação e controle para os mais variados fins. Este artigo apresenta um Estimador de Estado Adaptativo Paraconsistente, utilizando uma célula Neural Artificial Paraconsistente de aprendizagem por extração do efeito da contradição (cNAPapxct), desenvolvida a partir da Lógica Paraconsistente Anotada com Anotação de 2 valores (LPA2v), que apresenta resultados próximos ao Filtro Kalman, nos cenários estudados.

Palavras-chave: LPA2v; cNAP; cNAPapxct; Kalman.

Abstract

The Kalman Filter is an algorithm capable of providing an estimate of the real value of a measured quantity, predicting an output and the associated degree of uncertainty, delivering a weighted average between the measured value and the predicted value, being widely used in automation and control systems for the most varied purposes. This article presents a Paraconsistent Adaptive State Estimator using a Paraconsistent Artificial Neural Cell of Learning by extracting the contradiction effect (PANClctx), developed from the Paraconsistent Annotated Logic with 2 Value Annotation (PAL2v), which presents results close to the Kalman Filter, in the scenarios studied.

Keywords: PAL2v, PANC, PANClctx; Kalman.

Introdução

Um algoritmo que utiliza uma série de medidas realizadas no tempo, com ruído estatístico e imprecisões e produz estimativas de variáveis desconhecidas tendendo a ser mais preciso que medições baseadas em apenas uma única medida apresenta inúmeras aplicações em tecnologia, tais como orientação, navegação e controle de veículos, inclusive aeronaves e naves espaciais [1]. Um algoritmo bastante utilizado para estas aplicações é o Filtro de Kalman, um estimador quadrático linear proposto por Rudolf E. Kálmán [2].

A LPA2v, derivada da Lógica Paraconsistente Anotada (LPA), é uma lógica não clássica, da família de lógicas paraconsistentes (LP). Um operador “ $\sim$ ” que tem o sentido de negação é introduzido na LPA2v [3], sendo definido como segue:

$$\sim: \tau \mapsto |\tau|, \text{ onde } \tau = \{(\mu, \lambda)\} \mid \mu, \lambda \in [0, 1] \subset \mathfrak{R}$$

Na LPA2v, através de um par de valores normalizados (μ - grau de evidência favorável, λ - grau de evidência desfavorável), é possível expressar conhecimento sobre uma proposição P , com os limites extremos de V - Verdadeiro, F - Falso, T - Inconsistente e $\perp$ - Indeterminado, conforme a Figura 1 [4].




Figura 1. Reticulado da LPA2v com Graus de Certeza e de Contradição.

As equações e interpretações da LPA2v escritas na forma de algoritmo formam um Nó de Análise Paraconsistente (NAP), base para diversos tipos de células neurais artificiais paraconsistentes (cNAP), entre elas, a cNAP de aprendizagem por extração do efeito da contradição (cNAPapxct) [5], cuja representação é indicada pela Figura 2, sendo uma evolução da cNAP de aprendizagem (cNAPap) e que funciona como integrador, com maior ou menor grau, mediante um Fator de Aprendizagem (F_A), limitado entre 0 e 1. As equações da cNAPapxct são apresentadas (1) e (2) a seguir; sendo k , o instante atual, μ_{Ek} , o grau de evidência resultante atual, e $\mu_{E(k-1)}$, a saída μ_E anterior. As cNAPapxct em cascata se comportam como filtro, chamado de Filtro LPA2v [6].




Figura 2. Representação da cNAP (a) e cNAPapxct (b).

$$\mu_{Ek} = \mu_{E(k-1)} + G_{CT} * F_A \quad (1)$$

$$\lambda_{(k)} = 1 - \mu_{E(k-1)} \quad (2)$$

O presente trabalho apresenta os resultados de uma cNAPapxct comparada com Filtro Kalman de uma variável, como Estimador de Estado Adaptativo.

Materiais e Métodos

Uma cNAPapxct foi projetada no MATLAB® SIMULINK R2008a tendo sua saída comparada com uma célula Filtro Kalman já existente no *software*, conforme Figura 3. Os sinais simulados, assim como as medições de campo, são introduzidos no *software*, normalizados entre 0 e 1 para atender a LPA2v e aplicados sobre os 2 filtros para fins de comparação.




Figura 3. cNAPapxct projetada (a) e Comparação com Filtro Kalman (b) no Simulink.

Os seguintes parâmetros foram utilizados para o Filtro Kalman: 1 filtro com 1 matriz de medida; condição inicial para estado estimado em zero; condição inicial para covariância do erro estimado em um, covariância do ruído de processo de 0,5 e covariância do ruído da medida (*measurement noise covariance*) variável durante os ensaios, conforme apresentado na Figura. 4.




Figura 4. Janela de Configuração do Kalman e Parâmetros Utilizados.

Resultados e Discussão

A partir da comparação de resultados da aplicação de uma função degrau unitário na entrada, com diferentes ajustes do F_A para a cNAPapxct e R (Covariância do Ruído da Medida) para o Filtro Kalman, chegou-se a Tabela 1 comparativa, cuja equação aproximada por regressão não linear é dada em (3).

Tabela 1. cNAPapxct versus Filtro Kalman.

F_A	R
0,6	0,5
0,5	1
0,2	10
0,095	50
0,065	100

$$F_A \cong \frac{(R + 5,855)}{(0,103 \cdot R^2 + 6,107 \cdot R + 7,509)} \quad (3)$$

As Figuras 5 e 6 apresentam os resultados de diferentes simulações de uma Função Degrau com e sem ruído aplicada às entradas do Filtro Kalman e da cNAPapxct, no Simulink. Pode-se observar que a resposta da cNAPapxct é bastante próxima à do Filtro Kalman, nos ajustes utilizados.

Observa-se pela Tabela 1, e também pelas Figuras 5 e 6, que o Fator de Aprendizagem (F_A) da cNAPapxct na função de Estimador de Estado varia de forma inversa ao Fator de Covariância do Ruído da Medida (R) do Filtro Kalman. Apesar de o F_A poder variar entre 0 e 1, para aplicações práticas equivalentes ao Filtro Kalman ele está geralmente abaixo de 0,2.




Figura 5. Função Degrau Unitário aplicada ao Filtro Kalman e à cNAPapxct no SIMULINK, sendo $R = 1$ e $F_A = 0,5$ (a) e $R = 100$ e $F_A = 0,065$ (b).




Figura 6. Função Degrau com ruído aleatório aplicada ao Filtro Kalman e à cNAPapxct no SIMULINK, sendo $R = 10$ e $F_A = 0,20$ (a) e $R = 60$ e $F_A = 0,08$ (b).

A Figura 7 apresenta em um ensaio com 490 amostras normalizadas de medição real e contínua da Potência Recebida (*Received Signal Strenght Indicator – RSSI*) por um computador conectado à rede sem fio em diferentes distâncias e obstáculos, submetido tanto ao Filtro Kalman quanto à cNAPapxct.




Figura 7. Resposta da cNAPapxct ($F_A = 0,1265$) e Filtro Kalman ($R = 30$) na filtragem do sinal RSSI de rede sem fio.

De modo a consistência com a LPA, a métrica de RSSI foi convertida em uma escala de 0 a 1, conforme a equação (4).

$$\mu = \frac{RSSI - (-100)}{(-20 - (-100))} = \frac{RSSI + 100}{80} \quad (4)$$

Assim como nas simulações apresentas nas Figuras 5 e 6, conforme a Figura 7, também com variáveis reais a cNAPapxct, apresenta uma resposta bastante próxima ao Kalman para os parâmetros utilizados. Isso significa que a cNAPapxct pode também ser utilizada para o tratamento de sinais e variáveis físicas reais em indicadores ou análises que requeiram um sinal com menos variações e ruídos.

Conclusão

De acordo com os resultados apresentados ficou demonstrado que uma cNAPapxct pode ser utilizada como Estimador de Estado Adaptativo, com resultados similares aos obtidos pelo Filtro Kalman de uma variável e demais valores utilizados, com a vantagem de utilizar um algoritmo e equações mais simples, podendo ser utilizada na filtragem de variáveis contaminadas por ruídos e incertezas, no tratamento de sinais em sistemas de controle e automação, robótica, comunicações, no algoritmo de tratamento de imagens, entre outras aplicações. É importante destacar que o sinal a ser aplicado à cNAPapxct deve antes ser normalizado com valores limitados a 0 e 1, de modo a ser consistente com a LPA2v.

Referências

- [1] P. Zarchan and H. Musoff, “Fundamentals of Kalman Filtering: A Practical Approach”. American Institute of Aeronautics and Astronautics, Incorporated. ISBN 978-1-56347-455-2, 2000.
- [2] R. E. Kalman, "A new approach to linear filtering and prediction problems", Transactions of ASME - Journal of Basic Engineering, vol. 82, D, pp. 35-45, Mar, 1960.
- [3] T. Jayasri and M. HEMALATHA, “Link Quality Estimation using Soft Computing Technique”, Middle-East Journal of Scientific Research, vol. 21 (1), pp. 158-168, 2014.
- [4] N. C. A. Da Costa, J. M. Abe and V. S. Subrahmanian, “Remarks on annotated logic”, Zeitschrift f. math. Logik und Grundlagen d. Math, no. 37, pp 561-570, 1991.
- [5] J. I. Da Silva Filho, “Lógica Paraconsistente e Probabilidade Pragmática no Tratamento de Incertezas”, Revista Seleção Documental, no. 9, pp. 16-27, Ed. Paralogike, Brasil, Jan, 2008.
- [6] J. I. Da Silva Filho, “Introdução às Células Neurais Artificiais Paraconsistentes”, Revista Seleção Documental, no. 8, pp. 5-14, Ed. Paralogike, Brasil, Dez, 2007.
- [7] M. F. Minicz, G. R. Matuck, P. M. Tasinaffo, et al. “Célula Neural Artificial Paraconsistente de Aprendizagem por Extração do Efeito da Contradição”, Revista Seleção Documental, n. 33, São Paulo, Brasil. 2014.
- [8] A. De Carvalho Jr, ”Proposta de Estimador de Qualidade de Enlace em Redes de Sensores Industriais Sem Fio Utilizando Rede Neural Artificial Paraconsistente”. 2017. 113f. Dissertação (Mestrado Profissional em Engenharia Mecânica) – Universidade Santa Cecília – UNISANTA, Programa de Pós-Graduação em Engenharia Mecânica, Santos – SP, 2017.