

# IDENTIFICAÇÃO ESTOCÁSTICA NO ESPAÇO DE ESTADO POR ANÁLISE DE CORRELAÇÕES CANÔNICAS: TEORIA, APLICAÇÃO E VALIDAÇÃO

ANGIE J. FORERO\* J. ANDRES PUERTO ACOSTA\* CELSO P. BOTTURA\*

\**Laboratório de Controle e Sistemas Inteligentes -LCSI-DSIF-FEEC-UNICAMP  
Av. Albert Einstein - 400, Cidade Universitária Zeferino Vaz  
Distrito Barão Geraldo  
Campinas, SP, 13083-852, Brasil*

Email: aforero@dsif.fee.unicamp.br, japa1@dsif.fee.unicamp.br, bottura@fee.unicamp.br

**Abstract**— In this paper, we treat the stochastic realization problem with exogenous inputs, which is to find a state vector  $x$  and calculate the state space model in the innovative form. The state vector  $x$  is given by the base vector of the predictor space calculated using the canonical correlation analysis. This method is applied to experimental identification of a vibrational rotary electromechanical system. Finally by the step forward prediction by the Kalman filter, is validated the identification due to the CCA method.

**Keywords**— State space identification, Multivariate stochastic system, CCA method, Kalman filter.

**Resumo**— Neste trabalho é abordado o problema da realização estocástica com entradas exógenas, o qual consiste em encontrar um vetor de estado  $x$  e calcular o modelo no espaço de estado na forma inovativa. O vetor de estado  $x$  é dado pelo vetor base do espaço preditor, calculado usando a análise de correlação canônica (CCA). O método é aplicado na identificação experimental de um sistema eletromecânico giratório vibracional. Finalmente pela predição de um passo a frente através do filtro de Kalman, valida-se a identificação devido ao método CCA.

**Palavras-chave**— Identificação no espaço de estado, Sistema estocástico multivariável, Método CCA, Filtro de Kalman.

## 1 INTRODUÇÃO

Neste trabalho apresenta-se um método que faz uma abordagem ao problema de realização estocástica de sistemas estacionários lineares com entrada exógena, usando as relações canônicas condicionais entre o passado e o futuro do conjunto de dados finitos de entrada e saída em um processo estocástico estacionário (Picci and Katayama, 1996), (Lindquist and Picci, 1996), (Larimore, 1983), (Chiuso, 2007) o qual é baseado no trabalho de Akaike (1974, 1975, 1976). O método CCA<sup>1</sup> apresentado por Picci e Katayama (1996) usa dita correlação canônica para construir o vetor de estado e derivar as matrizes  $(A, B, C, D, K)$  que descrevem o modelo de Markov com entrada exógena.

No conteúdo do trabalho apresenta-se o problema de realização estocástica com entradas exógenas seguido de uma breve revisão do método de identificação por espaço de estado CCA. Depois apresenta-se uma aplicação prática em uma bancada de vibração torcional. Finalmente é apresentada na Seção 5 uma validação que inclui o uso do filtro de Kalman de um passo a frente e o erro de predição calculado a partir de dito filtro. A validação é baseada no método apresentado em (Barreto, 2002) para séries temporais e estendido neste trabalho para sistemas com entrada exógena.

## 2 PROBLEMA DE REALIZAÇÃO ESTOCÁSTICA COM ENTRADAS EXÓGENAS

Considere um conjunto de dados finitos de entrada e saída de um processo. O problema de realização estocástica é encontrar um modelo matemático no espaço de estado que possa descrever adequadamente a dinâmica do sistema desconhecido. O modelo no espaço de estado inovativo é dado por:

$$\begin{aligned}x(t+1) &= Ax(t) + Bu(t) + Ke(t) \\y(t) &= Cx(t) + Du(t) + e(t)\end{aligned}\quad (1)$$

onde,  $x(t) \in R^n$  é o vetor de estado,  $u(t) \in R^m$  é a entrada exógena e  $y(t) \in R^p$  é a saída do processo,  $e(t) \in R^p$  é o processo estocástico de inovação,  $A \in R^{n \times n}$  é a matriz de estado,  $B \in R^{n \times m}$  é a matriz de entradas,  $C \in R^{p \times n}$  é a matriz de saída,  $D \in R^{p \times m}$  é a matriz de transmissão direta,  $K \in R^{n \times p}$  é a matriz do ganho de Kalman.

Para a consideração estocástica do problema, são definidas as matrizes de covariâncias do conjunto entrada-saída  $w$ , como segue:

$$\begin{aligned}\Lambda_{ww}(l) &= E \{w(t+l)w^T(t)\} \\&= \begin{bmatrix} \Lambda_{yy}(l) & \Lambda_{yu}(l) \\ \Lambda_{uy}(l) & \Lambda_{uu}(l) \end{bmatrix}, \quad l = 0, \pm 1, \dots\end{aligned}\quad (2)$$

onde  $E\{\cdot\}$  representa a esperança matemática e  $w \in R^d$  é definido por:

$$w := \begin{bmatrix} u(t) \\ y(t) \end{bmatrix}\quad (3)$$

<sup>1</sup>Do inglês: "Correlation Canonical Analysis"

A matriz de densidade espectral é dada por:

$$\Phi_{ww}(z) = \sum_{l=-\infty}^{\infty} \Lambda_{ww}(l)z^{-l} = \begin{bmatrix} \Phi_{yy}(z) & \Phi_{yu}(z) \\ \Phi_{uy}(z) & \Phi_{uu}(z) \end{bmatrix} \quad (4)$$

Para resolver este problema de realização estocástica com entradas exógenas é usado o método de análise de correlação canônica, descrito na seguinte seção.

### 3 MÉTODO CCA

Para um conjunto de dados finitos de entrada  $u$  e de saída  $y$  de um processo, dados da forma:

$$\{u(t), y(t) \quad \text{com} \quad t = 0, 1, \dots, N + 2k - 2\} \quad (5)$$

onde  $N$  é o número de dados disponíveis para a identificação e  $k$  é o número de linhas das matrizes bloco de Hankel (6) e (7) e de Toeplitz (8) de dados;  $k$  é escolhido com o critério de  $k \gg n$ , onde  $n$  é a ordem do sistema obtida na identificação. O valor inicial de  $k$  é escolhido suficientemente grande e de forma arbitrária.

Com os vetores de entrada e saída são construídas as matrizes de Hankel de dados, da seguinte forma:

$$U_{k|2k-1} = \begin{bmatrix} u(k) & \cdots & u(k+N-1) \\ u(k+1) & \cdots & u(k+N) \\ \vdots & & \vdots \\ u(2k-1) & \cdots & u(N+2k-2) \end{bmatrix} \quad (6)$$

$\in \mathcal{R}^{km \times N}$

e

$$Y_{k|2k-1} = \begin{bmatrix} y(k) & \cdots & y(k+N-1) \\ y(k+1) & \cdots & y(k+N) \\ \vdots & & \vdots \\ y(2k-1) & \cdots & y(N+2k-2) \end{bmatrix} \quad (7)$$

$\in \mathcal{R}^{kp \times N}$

As notações  $U_{k|2k-1}$  e  $Y_{k|2k-1}$  representam os dados futuros de entrada e saída respectivamente, começando desde o instante  $k$  até o instante  $2k-1$ .

Com a matriz  $w$  de (3) é construída a matriz Toeplitz de dados de entrada-saída, na forma:

$$\check{W}_{0|k-1} = \begin{bmatrix} w(k-1) & \cdots & w(k+N-2) \\ w(k-2) & \cdots & w(k+N-3) \\ \vdots & & \vdots \\ w(0) & \cdots & w(N-1) \end{bmatrix} \in \mathcal{R}^{kd \times N} \quad (8)$$

A notação  $\check{W}_{0|k-1}$  representa os dados do passado de entrada-saída, começando no instante 0 até  $k-1$

A técnica CCA para identificação de sistemas estocásticos multivariáveis no espaço de estado

baseia-se na busca da correlação canônica condicional entre o futuro e o passado dadas as entradas futuras, com a qual é possível obter as matrizes de observabilidade e controlabilidade estendidas, (Katayama, 2005).

As matrizes de covariância entre futuro e passado são definidas por:

$$\begin{bmatrix} \Sigma_{uu} & \Sigma_{up} & \Sigma_{uf} \\ \Sigma_{pu} & \Sigma_{pp} & \Sigma_{pf} \\ \Sigma_{fu} & \Sigma_{fp} & \Sigma_{ff} \end{bmatrix} = \frac{1}{N} \begin{bmatrix} U_{k|2k-1} \\ \check{W}_{0|k-1} \\ Y_{k|2k-1} \end{bmatrix} \begin{bmatrix} U_{k|2k-1} \\ \check{W}_{0|k-1} \\ Y_{k|2k-1} \end{bmatrix}^T = \bar{L}\bar{L}^T \quad (9)$$

onde  $\bar{L}$  representa a matriz bloco triangular inferior. Dita matriz é obtida através da decomposição LQ da matriz conjunta das matrizes bloco de Hankel e Toeplitz, como é mostrado na equação a seguir:

$$\frac{1}{\sqrt{N}} \begin{bmatrix} U_{k|2k-1} \\ \check{W}_{0|k-1} \\ Y_{k|2k-1} \end{bmatrix} = \begin{bmatrix} L_{11} & 0 & 0 \\ L_{21} & L_{22} & 0 \\ L_{31} & L_{32} & L_{33} \end{bmatrix} \begin{bmatrix} Q_1^T \\ Q_2^T \\ Q_3^T \end{bmatrix} = \bar{L}Q^T \quad (10)$$

De acordo com a teoria da decomposição LQ, obtém-se matrizes triangulares inferiores  $\bar{L}$  com um bloco zero na parte superior direita, e matrizes  $Q$  ortogonais tais que  $Q_i^T Q_j = I\delta_{ij}$ .

Desta forma substituindo a matriz  $\bar{L}$  em (10) na equação (9), obtém-se:

$$\Sigma = \begin{bmatrix} \Sigma_{uu} & \Sigma_{up} & \Sigma_{uf} \\ \Sigma_{pu} & \Sigma_{pp} & \Sigma_{pf} \\ \Sigma_{fu} & \Sigma_{fp} & \Sigma_{ff} \end{bmatrix} = \begin{bmatrix} L_{11} & 0 & 0 \\ L_{21} & L_{22} & 0 \\ L_{31} & L_{32} & L_{33} \end{bmatrix} \begin{bmatrix} L_{11}^T & L_{21}^T & L_{31}^T \\ 0 & L_{22}^T & L_{32}^T \\ 0 & 0 & L_{33}^T \end{bmatrix} \quad (11)$$

De (11) pode-se obter cada uma das matrizes de covariância de  $\Sigma$ , como:

$$\begin{aligned} \Sigma_{uu} &= L_{11}L_{11}^T, & \Sigma_{pu} &= L_{21}L_{11}^T, \\ \Sigma_{fu} &= L_{31}L_{11}^T, & \Sigma_{pp} &= L_{21}L_{21}^T + L_{22}L_{22}^T, \\ \Sigma_{fp} &= L_{31}L_{21}^T + L_{32}L_{22}^T, \\ \Sigma_{ff} &= L_{31}L_{31}^T + L_{32}L_{32}^T + L_{33}L_{33}^T \end{aligned} \quad (12)$$

Sejam

$$f(t) = \begin{bmatrix} y(t) \\ y(t+1) \\ \vdots \\ y(t+k-1) \end{bmatrix} \in \mathcal{R}^{kp}, \quad (13)$$

$$u_+(t) = \begin{bmatrix} u(t) \\ u(t+1) \\ \vdots \\ u(t+k-1) \end{bmatrix} \in \mathcal{R}^{km}$$

respectivamente os vetores de saídas e entradas futuras.

Para o passado os vetores de saídas e entradas de dimensão infinita são:

$$y_- = \begin{bmatrix} y(t-1) \\ y(t-2) \\ \vdots \end{bmatrix}, \quad u_-(t) = \begin{bmatrix} u(t-1) \\ u(t-2) \\ \vdots \end{bmatrix} \quad (14)$$

Para o passado entrada-saída definimos os vetores de dimensão infinita:

$$p(t) = \begin{bmatrix} w(t-1) \\ w(t-2) \\ \vdots \end{bmatrix}, \quad (15)$$

$$w(t) = \begin{bmatrix} y(t) \\ u(t) \end{bmatrix} \in \mathcal{R}^d \quad \text{com} \quad d = p + m$$

Usando os vetores (13), (14) e (15) define-se a correlação canônica condicional das saídas futuras dadas as entradas futuras:

$$\Sigma_{ff|u} := E \left\{ \hat{E}(f|u_+^\perp) \hat{E}(f|u_+^\perp)^T \right\} \quad (16)$$

onde  $\hat{E}(f|u_+^\perp)$  indica a projeção ortogonal do futuro sobre o complemento ortogonal de  $u$ ; a projeção ortogonal pode ser expressa mediante esperanças como:

$$\hat{E}(f|u) = E \{ fu^T \} E \{ uu^T \}^\dagger u = \Sigma_{fu} \Sigma_{uu}^\dagger u \quad (17)$$

e

$$\hat{E}(f|u^\perp) = f - \hat{E}(f|u) = f - \Sigma_{fu} \Sigma_{uu}^\dagger u \quad (18)$$

onde  $\dagger$  é a pseudo-inversa.

Então, a covariância condicional do futuro dada a entrada futura é dada por:

$$\begin{aligned} \Sigma_{ff|u} &= E \left\{ \hat{E}(f|u_+^\perp) \hat{E}(f|u_+^\perp)^T \right\} \\ &= \Sigma_{ff} - \Sigma_{fu} (\Sigma_{uu})^\dagger \Sigma_{uf} \end{aligned} \quad (19)$$

Da mesma forma são obtidas as matrizes de covariâncias condicionais  $\Sigma_{pp|u}$  e  $\Sigma_{fp|u}$ .

Assim, usando as covariâncias de (12) e as definições anteriores, obtém-se as covariâncias condicionais como:

$$\begin{aligned} \Sigma_{ff|u} &= \Sigma_{ff} - \Sigma_{fu} \Sigma_{uu}^{-1} \Sigma_{uf} \\ &= L_{32} L_{32}^T + L_{33} L_{33}^T \end{aligned} \quad (20)$$

$$\Sigma_{pp|u} = \Sigma_{pp} - \Sigma_{pu} \Sigma_{uu}^{-1} \Sigma_{up} = L_{22} L_{22}^T \quad (21)$$

$$\Sigma_{fp|u} = \Sigma_{fp} - \Sigma_{fu} \Sigma_{uu}^{-1} \Sigma_{up} = L_{32} L_{22}^T \quad (22)$$

As matrizes com os autovetores canônicos são obtidas mediante os cálculos das raízes quadradas inversas das matrizes de covariâncias condicionais  $\Sigma_{ff|u}$  e  $\Sigma_{pp|u}$ , da forma:

$$\Sigma_{ff|u} = LL^T \quad \Sigma_{pp|u} = MM^T \quad (23)$$

Mediante a decomposição em valores singulares das matrizes  $L$  e  $M$  e da matriz de covariância

condicional do futuro e do passado dadas as entradas futuras  $\Sigma_{fp|u}$ , são obtidas as matrizes de observabilidade e controlabilidade estendidas como:

$$\begin{aligned} L^{-1} \Sigma_{fp|u} M^{-T} &= U \Sigma V^T, \\ \mathcal{O} &= LU \Sigma^{1/2} \quad \mathcal{C} = \Sigma^{1/2} V^T M^T \end{aligned} \quad (24)$$

As equações acima são obtidas pela decomposição em valores singulares da matriz de Hankel normalizada, ver (Akaike, 1976):

$$\begin{aligned} L^{-1} H M^{-T} &= U \Sigma V^T \\ H &= LU \Sigma V^T M^T \\ H &= (LU \Sigma^{1/2}) (\Sigma^{1/2} V^T M^T) = \mathcal{O} \mathcal{C} \end{aligned} \quad (25)$$

O vetor de estado estimado  $\hat{X}_k$ , é calculado usando a controlabilidade estendida, da forma:

$$\hat{X}_k = C_k \Sigma_{pp|u}^{-1} \check{W}_{0|k-1} \quad (26)$$

A partir de (1) obtém-se:

$$\begin{bmatrix} \hat{X}_{k+1} \\ \hat{Y}_{k|k} \end{bmatrix} = \begin{bmatrix} A & B \\ C & D \end{bmatrix} \begin{bmatrix} \hat{X}_k \\ U_{k|k} \end{bmatrix} + \begin{bmatrix} Ke \\ e \end{bmatrix} \quad (27)$$

onde  $\hat{X}_{k+1}$  é o vetor de estado estimado no instante  $k+1$ .

Resolvendo o sistema sobredeterminado (27) e usando o método de regressão linear, obtém-se o conjunto de matrizes  $(A, B, C, D)$ .

De aqui para frente para facilitar a notação  $Ke$  é chamado de  $\varrho$ .

Para calcular o ganho de Kalman  $K$  e a solução da equação algébrica de Riccati (ARE) do filtro de Kalman  $P$ , é necessário calcular as matrizes de covariâncias do erro de predição, dadas por:

$$\begin{bmatrix} Q & S \\ S^T & R \end{bmatrix} = \frac{1}{N-1} \begin{bmatrix} \varrho \varrho^T & \varrho e^T \\ e \varrho^T & ee^T \end{bmatrix} \quad (28)$$

O ganho de Kalman é dado por:

$$K = (APC^T + S)(CPC^T + R)^{-1} \quad (29)$$

onde a ARE do filtro de Kalman, é dada por:

$$\begin{aligned} P &= APA^T - \\ &(APC^T + S)(CPC^T + R)^{-1}(APC^T + S)^T + Q \end{aligned} \quad (30)$$

Assim, encontrando as matrizes do sistema  $(A, B, C, D, K)$  chegamos no modelo inovativo (1)

## 4 APLICAÇÃO

O método de identificação CCA apresentado neste artigo é aplicado em um sistema eletromecânico rotacional que será chamado de bancada de vibração torcional, a qual está composta de um servo motor, um acoplamento, um disco, um encoder e dois freios eletromagnéticos. Na Figura 1 é apresentada uma foto da bancada. Na figura pode-se

observar que o eixo do motor está ligado com um disco de 3 mm de espessor, através de um acoplamento. O motor fornece um torque no eixo do disco e o torque aplicado gera uma mudança na posição angular e na velocidade no disco.




Figura 1: Bancada de vibração torcional.

#### 4.1 Modelo analítico considerando o acoplamento como um corpo rígido.

Na Figura 2 apresenta-se a representação esquemática da bancada de vibração torcional da Figura 1.




Figura 2: Representação esquemática do sistema eletromecânico de um grau de liberdade.

Na Figura 3 apresenta-se o diagrama de corpo livre do sistema da Figura 2 considerando o acoplamento como um corpo com rigidez infinita, que para simplificar a notação será chamado de acoplamento rígido. No diagrama de corpo livre da Figura 3,  $T(t)$  em  $Nm$  representa o torque aplicado no eixo do servo motor,  $J_{eq}$  em  $Kgm^2$  é a inércia equivalente;  $T_d$  representa o atrito no disco e é expresso como  $T_d = C\dot{\theta}(t)$ , onde  $C$  em  $Nms/rad$  é o coeficiente de amortecimento.




Figura 3: Diagrama de corpo livre considerando que o acoplamento é um corpo rígido.

#### 4.2 Sinal de excitação e de saída

O sinal de excitação é um sinal seno-chirp (Pintelon et al., 2011) de  $320 \times 10^{-3} N.m$  de amplitude e um período de 20s, na faixa de frequência de  $500 \times 10^{-3} Hz$  até 15 Hz. O sinal de torque de referência é chamado de  $T_{ref}$ , e é adquirido com a placa de captura da dSpace, modelo DS1104. O sinal de saída é um sinal de velocidade angular denominado  $V_{enc1}$ . Os sinais de entrada-saída tem frequência de amostragem de  $1 \times 10^3 Hz$  e sete períodos de 20s de duração cada um.

#### 4.3 Identificação pelo método CCA

Na identificação usando o método CCA, foi obtido um modelo no espaço de estado discreto de primeira ordem, dado por:

$$\begin{aligned} \hat{x}(t+1) &= (0,99)\hat{x}(t) - 2,55 \times 10^{-4}u(t) - 2,88 \times 10^{-5}e(t) \\ y(t) &= (-3,10 \times 10^3)\hat{x}(t) + (3,32)u(k) + e(t) \end{aligned} \quad (31)$$

Na figura 4 é mostrada a comparação gráfica do sinal de velocidade medido na bancada de vibração torcional e a velocidade estimada pelo método de identificação CCA.




Figura 4: Comparação entre Velocidade Medida e Velocidade Estimada pelo Método CCA.

## 5 VALIDAÇÃO USANDO O FILTRO DE KALMAN

O processo de validação usando o filtro de Kalman é descrito a seguir.

### 5.1 Método de Validação

1. Dividir os vetores de dados de entrada-saída em dois subconjuntos. O primeiro subconjunto é usado para a identificação e o segundo subconjunto é usado na validação; o subconjunto de validação é subdividido em  $n$  conjuntos.
2. Com os  $n$  subconjuntos de validação dados por  $\{u_1, u_2, u_3, \dots, u_n\}$  entradas e  $\{y_1, y_2, y_3, \dots, y_n\}$  saídas, são realizados os  $n$  modelos de estado dados por
 
$$\{(A_1, B_1, C_1, D_1, K_1), \dots, (A_n, B_n, C_n, D_n, K_n)\}$$
3. Calcula-se o  $n$ -filtro de Kalman para cada  $n$ -conjunto de dados e  $n$ -realização como:

#### Filtro de um passo à frente :

Calcula-se o  $n$ -filtro de Kalman como:

$$\begin{aligned}\hat{x}_n(t+1) &= A_n \hat{x}_n(t) + B_n u_n(t) + K_n e_n(t) \\ \hat{x}_n(t|t) &= \hat{x}_n(t) + K_{fn} e_n(t) \\ e_n(t) &= y_n(t) - C_n \hat{x}_n(t)\end{aligned}\quad (32)$$

#### Ganho do filtro:

$$\begin{aligned}K_n &= (A_n P_n C_n^T + S_n)(C_n P_n C_n^T + R_n)^{-1} \\ K_{fn} &= P_n C_n^T (C_n P_n C_n^T + R_n)^{-1}\end{aligned}\quad (33)$$

#### Matrizes de covariância do erro:

$$\begin{aligned}P_n(t+1) &= A_n P_n(t) A_n^T \\ &\quad - K_n (C_n P_n(t) C_n^T + R_n) K_n^T + Q_n \\ P_n(t|t) &= P_n(t) \\ &\quad - P_n(t) C_n^T [C_n P_n(t) C_n^T + R_n]^{-1} C_n P_n(t)\end{aligned}\quad (34)$$

**Condições iniciais:** Usando o método CCA estima-se  $Q_n$ ,  $R_n$ ,  $S_n$  como em (28), e o estado inicial  $X(0)_n$  é obtido do vetor de estado estimado em (26). Assim as  $Q_n$ ,  $R_n$ ,  $S_n$  estimações das covariâncias e o estado  $X(0)_n$ , são usados como valores iniciais no  $n$ -filtro de Kalman.

4. Calcula-se a saída estimada  $\hat{y}_n(t+1)$  a partir do  $n$ -filtro de Kalman.
5. Calcula-se a  $n$ -matriz de covariância de inovação de Kalman  $\mathcal{E}_n$  dada por:

$$\mathcal{E}_n = C_n P_n C_n^T + R_n \quad (35)$$

6. Calcula-se o  $n$ -erro de predição  $\phi_n(t)$  dado pela diferença entre a saída real e a saída estimada como é mostrado a seguir:

$$\phi_n(t) = y_n(t) - \hat{y}_n(t+1) \quad (36)$$

e a matriz de covariância do erro de predição como:

$$\Xi_n = E\{\phi_n(t)\phi_n(t)^T\} \quad (37)$$

7. Comparam-se o traço da matriz de covariância de inovação  $R_n$  obtido usando o método CCA em (28) com o traço da matriz de covariância do  $n$ -processo de inovação de Kalman  $\mathcal{E}_n$  e com o traço da matriz de covariância do erro de predição  $\Xi_n$ . Se os traços das matrizes de covariâncias calculados para cada caso são aproximadamente iguais, pode-se concluir que o modelo estimado nos  $n$ -conjuntos representa o sistema.

### 5.2 Resultados numéricos

O conjunto de dados tem 120000 amostras, as quais foram divididas em 60000 amostras para identificação e uma quantidade igual para validação. O conjunto de validação foi dividido em 6 subconjuntos com os quais é aplicado o método apresentado na Subsecção 5.1. Assim obteve-se 6 conjuntos de realizações  $(A, B, C, D, K)$  e suas respectivas matrizes de covariâncias.

Na Tabela 1, apresentam-se os traços  $Tr\{\cdot\}$ , das matrizes  $R_n$  de (28),  $\mathcal{E}_n$  de (35) e  $\Xi_n$  de (37) para cada subconjunto de realizações  $(A_n, B_n, C_n, D_n, K_n)$ .

Tabela 1: Comparação dos traços das matrizes das covariâncias.

# da realização	$Tr\{\mathcal{E}_n\}$	$Tr\{R_n\}$	$Tr\{\Xi_n\}$
1	0,0864	0,0832	0,0864
2	0,0917	0,0881	0,0917
3	0,0869	0,0837	0,0869
4	0,0903	0,0871	0,0903
5	0,0849	0,0786	0,0849
6	0,0915	0,0852	0,0915

## 6 Conclusões

Obteve-se um modelo da bancada de vibração torsional com o método de identificação em espaço de estado CCA a partir de dados experimentais.

Apresenta-se uma metodologia de validação do modelo estocástico (obtido a partir do método de identificação CCA), que faz uso do filtro de Kalman de um passo a frente e do cálculo das matrizes de covariâncias do erro, para determinar o ajuste do modelo de estado na forma inovativa. A validação da identificação de sistemas estocásticos é um processo que implica ir para além da comparação da resposta temporal, já que em diversos casos essa resposta temporal pode ser aparentemente diferente, dada a sua estocasticidade.

Portanto o aporte deste trabalho inclui além da breve revisão teórica do método CCA, e a sua aplicação prática a um sistema experimental, o uso do filtro de Kalman para a validação do modelo estocástico de forma convincente.

### Referências

- Akaike, H. (1974). Stochastic theory of minimal realization., *IEEE Trans. Automatic control* **AC-19**: 667–674.
- Akaike, H. (1975). Markovian representation of stochastic processes by canonical variables, *SIAM J. control* **13**: 162–173.
- Akaike, H. (1976). Canonical correlation analysis of time series and the use of an information criterion., *System identification: Advances and case studies* (R. Mehra and D.Lainiotis, eds) pp. 27–96.
- Barreto, G. (2002). *Modelagem Computacional Distribuída e Paralela de Sistemas e de Séries Temporais Multivariáveis no Espaço de Estado*, PhD thesis, Universidade Estadual de Campinas.
- Chiuso, A. (2007). On the relation between cca and predictor-based subspace identification, *Automatic Control, IEEE Transactions on* **52**(10): 1795–1812.
- De Moor, B., Moonen, M., Vandenberghe, L. and Vandewalle, J. (1988). Identification of linear state space models with svd using canonical correlation analysis, *Singular value decomposition and signal processing* (E. Deprettere, ed) pp. 161–169.
- Grewal, M. and Andrews, A. (1993). *Kalman Filtering - Theory and Practice*, Prentice-Hall.
- Ho, B. and Kalman, R. (1966). Effective construction of linear, state-variable models from input/output functions, *Regelungstechnik* **14**: 545–548.
- Kalman, R. (1960). A new approach to linear filtering and prediction problems, *Trans. ASME J. Basic Engineering* **82D**: 34–45.
- Katayama, T. (2005). *Subspace Methods for System Identification*, Springer.
- Katayama, T. and Picci, G. (1999). Realization of stochastic systems with exogenous inputs and subspace identification methods, *Automatica* **35**(10): 1635 – 1652.
- Larimore, W. (1990). Canonical variate analysis in identification, filtering, and adaptive control, *Decision and Control, 1990., Proceedings of the 29th IEEE Conference on*, pp. 596–604 vol.2.
- Larimore, W. E. (1983). System identification, reduced-order filtering and modeling via canonical variate analysis, *American Control Conference, 1983*, pp. 445–451.
- Lindquist, A. and Picci, G. (1996). Canonical correlation analysis, approximate covariance extension, and identification of stationary time series, *Automatica* **32**(5): 709–733.
- Picci, G. and Katayama, T. (1996). Stochastic realization with exogenous inputs and subspace methods identification, *Signal Processing* **52**: 145–160.
- Pintelon, R., Barbé, K., Vandersteen, G. and J., S. (2011). Improved (non-)parametric identification of dynamics systems excited by periodic signals, *Mechanical systems and Signal Processing* **25**: 2683–2704.