



IDENTIFICAÇÃO DE UM MODELO PARA SINAIS DE ELETROMIOGRAFIA DO MOVIMENTO ÚNICO DA MÃO

Isabela oliveira zaparoli*¹, Victor Hugo Soares Lopes¹

¹PPGEL– Universidade Federal de São João Del Rei

Resumo - O sinal de *eletromiografia* (EMG) gerado pelos músculos esqueléticos durante a contração ou relaxamento desempenha um papel significativo em muitas aplicações clínicas e biomédicas, uma vez que a análise de sinais EMG auxilia na detecção de movimentos. Este trabalho utilizou sinais de sensores de flexão nos dedos e sinais de EMG retirados do antebraço para a identificação de um modelo capaz de descrever o movimento dos dedos através dos sinais mio-elétricos para aplicação no controle de um dispositivo protético. Técnicas de identificação foram utilizadas para desenvolver um modelo linear e outro não-linear, e o desempenho desses modelos identificados foram comparados. Os resultados mostraram que modelos lineares, para determinados movimentos, podem ser tão eficientes quanto modelos não lineares.

Palavras-Chave - Identificação de sistemas, Eletromiografia, Sensores de flexão, Modelo ARX, Modelo NARX.

IDENTIFICATION OF A MODEL FOR ELECTRO-GRAPHIC SIGNS OF THE SINGLE MOVEMENT OF THE HAND

Abstract - The electromyographic (EMG) signal generated by the skeletal muscles during contraction or relaxation plays a significant role in many clinical and biomedical applications, since EMG signal analysis assists in motion detection. This work uses signals of flexion sensors in the fingers and EMG signals taken from the forearm for an identification of a model capable of describing the movement of the fingers through the myoelectric signals for uncontrolled application of a prosthetic device. Identification techniques for a linear and a non-linear model, and the performance of the models identified as compared. The results showed that linear models, for certain movements, can be as efficient as nonlinear models.

Keywords - Identification of systems, EMG's, Flexural sensors, ARX linear model, NARX nonlinear model.

*oliveirazaparoli@gmail.com

I. INTRODUÇÃO

O controle de próteses e dispositivos biomecânicos por meio de *eletromiografia* (EMG) foi demonstrado pela primeira vez em 1948 por Heinhold Reiter em Hannover, Alemanha[1]. Em 1961, Kobrinski apresentou na primeira conferência da Federação Internacional de Controle e Automação um novo modelo de prótese controlada por eletromiografia [1]. O sinal eletromiográfico é a resultante de transmissões sinápticas e potenciais de ação neuromotores que ocorrem no processo de contração das fibras musculares [2]. O sinal pode ter amplitudes de aproximadamente 3 mV para um músculo saudável [3], e possui frequências desde a componente cc até cerca de 500 Hz para eletrodos de superfície, sendo dominante entre 50 e 150 Hz [4].


Nos últimos anos, houve um grande aumento no número de estudos envolvendo modelos que utilizam sinais de EMG para descrever o movimento de membros inferiores e superiores do corpo [5]. Modelos polinomiais dos tipos *autoregressive* (AR), *autoregressive exogenous input* (ARX), *nonlinear autoregressive exogenous inputs* (NARX) e modelos de *erro na saída* são comumente utilizados [6].

Neste contexto, o objetivo deste trabalho é a obtenção de um modelo apropriado que consiga explicar os sinais eletromiográficos, coletados no antebraço, que são gerados a partir do movimento de fechar e abrir a mão, juntamente com suas posições intermediárias. Esses movimentos são captados por cinco sensores de flexão, também chamados de extensômetros, posicionados sobre cada dedo. Estes sensores são capazes de medir a deformação de corpos pela variação da sua resistência, permitindo obter a posição de cada dedo. O modelo obtido deverá ser utilizado futuramente para compor o controle de um braço robótico.

Para que o controle deste braço robótico seja aplicado corretamente, é fundamental que as características bioelétricas do braço humano, ou pelo menos os padrões eletromiográficos que se correlacionam com o movimento dos dedos sejam conhecidos. A criação de modelos com sinais EMG deve ser cautelosa dado que, as leis físicas que regem a dinâmica deste processo são complexas. Para designação de modelos capazes de descrever a relação do movimento *'hand-close'* (fechar e abrir a mão), com a assinatura eletromiográfica coletada, foram utilizadas técnicas de identificação.

Este braço robótico deve ser capaz de reconhecer os padrões de EMG e apresentar como saída o posicionamento dos dedos do braço mecânico. A Figura 1 apresenta o diagrama simplificado do sistema de processamento de sinais EMG e de sensores de flexão para o controle do mecanismo. Neste sistema, o sinal de EMG é adquirido por meio de um par de eletrodos de superfície fixados sobre o músculo flexor radial do carpo no antebraço. Um terceiro eletrodo é utilizado como sinal de referência.

Figura 1: Diagrama do sistema de controle do braço robótico.



Para o desenvolvimento deste trabalho, foi realizado a coleta dos sinais no braço direito de um indivíduo saudável e a partir desses sinais, pelo menos dois modelos foram obtidos. Por fim, tais modelos, sendo um linear e outro não linear, foram comparados quanto ao desempenho.

II. MÉTODOS

Para o desenvolvimento deste trabalho, foi realizado a coleta dos sinais no braço direito de um indivíduo saudável e a partir desses sinais, pelo menos dois modelos foram obtidos. Por fim, tais modelos, sendo um linear e outro não linear, foram comparados quanto ao desempenho.

A. Aquisição de dados


Para a identificação do modelo, primeiramente foram registrados os sinais de EMG por meio de eletromiografia e a posição dos dedos para o movimento *hand-close* utilizando sensores de flexão. A eletromiografia foi feita através da placa de condicionamento de sinais EMG comercialmente disponível e de baixo custo *Muscle Sensor v3.0 (MSV3)* [6]. Com o uso desta, o número de movimentos possíveis para a aplicação do modelo foi limitado, dado que a saída do condicionador contempla apenas as componentes de baixa frequência do sinal EMG devido ao filtro passa baixa de 2Hz. Isto faz com que muitas informações importantes sejam perdidas [7]. Ao utilizar apenas um canal de leitura, não foi possível cobrir uma ampla área muscular do antebraço com eletrodos, e as informações disponíveis nos demais músculos foram ignoradas. A saída da MSV3 é um sinal analógico que varia entre a referência e a tensão de alimentação dependendo da contração muscular realizada.

Os eletrodos de sinal foram posicionados ao longo do músculo flexor radial do antebraço direito, próximos ao punho, a uma distância de 2 cm entre eles. O eletrodo de referência, que permite minimizar o ruído elétrico externo, foi colocado na superfície próximo ao cotovelo do mesmo braço.

Para o condicionamento de sinal dos cinco sensores de flexão, foi utilizado um circuito divisor de tensão, capaz de transformar a variação da resistência do sensor em um sinal

de tensão. A Figura 2, ilustra como foi realizada a coleta de dados. Na luva estão fixados os cinco sensores de flexão de forma que esses sinais sejam adquiridos simultaneamente com as informações de EMG.


Figura 2: Coleta de dados utilizando a luva com os sensores de flexão e eletrodos para a obtenção dos sinais de EMG.



O sistema a ser identificado contém cinco entradas, dadas pelos sensores de flexão, e uma saída, dada pelo sinal de EMG, caracterizando um sistema *multiple-input single-output (MISO)*. Ao fechar e abrir a mão, todos os dedos desempenham o mesmo movimento de flexão e extensão. Deste modo, afim de simplificar o modelo, o sinal de entrada foi tomado como a média aritmética de todos os sensores de flexão. Assim, o sistema passa a ser *single-input single-output (SISO)* e o modelo a ser elaborado depende apenas de uma entrada e uma saída.

Os dados foram coletados em um período de 10 segundos. Durante esse intervalo, o movimento foi realizado de maneira pertinente. A Figura 3 apresenta os dados de entrada e saída que foram coletados.

Figura 3: Representação gráfica do sinal de entrada, dado pelos extensômetros (superior). Sinal de saída do sistema, dado pelo sinal de Eletromiografia.



As magnitudes apresentadas neste gráfico referem-se ao valor visto pelo controlador Atmega328. Este possui um conversor *A/D* com 10 bits de resolução e um intervalo de leitura de 0 a 5 V. Os valores presentes na Figura 3 são apresentados em volts seguindo a Equação 1.

$$Sinal = \frac{5}{2^{10}} (\text{valor lido pelo conv. A/D}) [V] \quad (1)$$

Na Figura 3, à medida que o sinal dos sensores de flexão diminui a sua taxa de variação, o sinal EMG apresenta um

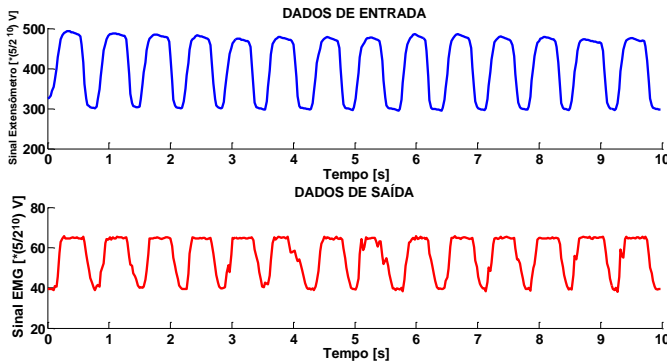
aumento abrupto em sua magnitude, formando espículas. Essa característica do sinal de EMG é dada devido ao aumento da contração muscular ao forçar os dedos contra a mão ao fecha-la. Portanto, neste intervalo, os sensores de flexão não conseguem explicar o sinal de EMG, visto que tais valores não se correlacionam.

Neste estudo as características de torque e força exercidos pela mão durante o movimento não é investigada, uma vez que o braço robótico possui um torque constante para qualquer movimento. Trabalhos que relacionam o sinal de EMG com o torque exercido durante os movimentos podem ser vistos em [4], [8]. Portanto, as influências do torque no sinal de eletromiografia foram descartadas. Para isso foi utilizado um filtro de saturação.

B. Filtro de saturação

Este filtro digital consiste em observar até que ponto o sinal de saída é influenciado pelo sinal de entrada. Quando a correlação entre ambos se torna nula, o filtro satura o valor de saída na última amplitude lida. A Figura 4 mostra o sinal de eletromiografia condicionado para não receber influência do torque exercido ao apertar os dedos contra a mão.

Figura 4: Representação gráfica do sinal de entrada, dado pelos extensômetros (superior). Sinal de saída do sistema, dado pelo sinal de Eletromiografia condicionado para não receber influência de torque.



Com este filtro, o sinal de saída apresentado na Figura 4, passa a não conter as espículas vistas na Figura 3. Os modelos estimados utilizando este conjunto de dados se mostraram mais eficientes para determinada aplicação.

C. Representação e Estrutura do Modelo

Os modelos estimados são representações polinomiais dos tipos ARX e NARX. Estes modelos são lineares e não-lineares respectivamente, e se caracterizam por serem autoregressivos com excitação externa. A equação generalizada, considerando a parcela de erro de predição nula, do modelo ARX é apresentada na Equação (2) [10]

$$y(k) = a_1y(k-1) + \dots + a_{ny}y(k-ny) + \dots + b_0u(k-\tau_d) + \dots + b_{nb-1}u(k-nb) \quad (2)$$

Modelos do tipo NARX são normalmente representados como na Equação (3) [11]:

$$y(k) = F[y(k-1), \dots, y(k-ny), \dots, u(k-\tau_d), \dots, u(k-nb)] \quad (3)$$

Onde u é a entrada, y é a saída do sistema, k é o instante atual, ny o número de polos, nb o número de zeros e τ o atraso puro de tempo. Modelos NARX são mais complexos

devido a função F não-linear associada aos termos regressores.

Por se tratar de uma entrada proveniente de associações resistivas e uma saída altamente filtrada, os sinais coletados sofreram poucas variações devido ao ruído. Deste modo, não foi necessário a obtenção de modelos do tipo *autoregressive moving average with exogenous inputs* (ARMAX) ou *nonlinear autoregressive moving average with exogenous inputs* (NARMAX).

Para definição da ordem dos modelos, utilizou-se o critério de informação de Akaike (AIC). Este critério calcula estatisticamente um número ótimo de termos para o modelo [3].

O AIC pode ser definido como mostra a Equação (4):

$$AIC_{n\theta} = N \ln[\sigma_{\text{erro}}^2(n\theta)] + 2n\theta \quad (4)$$

Onde N é o número de dados; $\sigma_{\text{erro}}^2(n\theta)$ é a variância do erro de modelagem e $n\theta$ é o número de parâmetros no modelo.

A medida que termos são incluídos no modelo, melhores ajustes dos dados podem ser tomados, de modo que σ_{erro}^2 diminui à medida que $n\theta$ aumenta. A primeira parcela de (4) quantifica a diminuição da variância dos resíduos devido a cada termo incluso, já a segunda parcela quantifica a penalidade devido a inclusão de tal termo [10].

No que se refere a escolha dos termos, de um conjunto de regressores possíveis, foi utilizado o ERR (“Error Reduction Ratio”) para definir os que possuíam um maior grau de importância na composição estrutural do modelo. O uso deste método é viável quando o modelo é essencialmente representado em uma base ortogonal [10].

C. Critério de Validação

Para avaliar o desempenho dos modelos foi utilizada a raiz média do erro quadrático (RMSE) definida conforme (5):

$$RMSE = \sqrt{\frac{\sum_{i=0}^{n-1} [y(i) - \hat{y}(i)]^2}{\sum_{i=0}^{n-1} [y(i) - \bar{y}(i)]^2}} \quad (5)$$

Onde $y(i)$ e $\hat{y}(i)$ são, o dado medido e o valor do modelo estimado no instante i , respectivamente. O índice RMSE compara as predições do modelo com a média temporal do sinal, neste caso, quanto menor o valor do RMSE mais próximo do ideal está o modelo analisado [11]. Este índice quantificou o desempenho dos modelos com base na proximidade estatísticas do dado e do modelo.

Também foi utilizado o índice *variance accounted for* (VAF) que representa porcentualmente a variância do resíduo em relação à variância do sinal medido, ou seja, o VAF de dois sinais idênticos corresponde a 100%, porém, se eles são diferentes este índice será menor [11]. O VAF é calculado como mostra (6):

$$VAF = \left(1 - \frac{\text{var}(y - \hat{y})}{\text{var}(y)}\right) \cdot 100\% \quad (6)$$

Onde var representa a variância do termo entre parênteses.

III. RESULTADO E DISCUSSÃO

Os quatro modelos estimados foram simulados utilizando o conjunto de dados separado para validação.

Os modelos obtidos utilizando o conjunto de dados sem o tratamento de saturação visto na seção 2.A., não obtiveram boas estimações.


Os modelos obtidos utilizando o conjunto de dados sem o tratamento de saturação visto na seção II.B, não obtiveram boas estimações. A Tabela I apresenta para cada modelo, os termos e parâmetros utilizados, a última coluna desta tabela é apresentada o ERR correspondente a cada parâmetro.

Estes modelos foram simulados de forma livre e as respostas obtidas pelos modelos comparadas com os dados de validação. A resposta do modelo linear é mostrada na Figura 5.

Tabela I: Termos, Parâmetros e Taxa de Redução de Erro para os modelos estimados com dados puros.

Termos	$\hat{\theta}_i$	ERR
MODELO ARX ($n\theta_{AIC} = 9,0$)		
y(k-1)	1,282585	$9,80 \times 10^{-1}$
y(k-2)	-0,75825	$4,70 \times 10^{-3}$
u(k-1)	0,238198	$2,64 \times 10^{-3}$
u(k-4)	-0,43855	$7,47 \times 10^{-4}$
y(k-3)	0,604701	$1,65 \times 10^{-3}$
Constante	-15,0879	$3,07 \times 10^{-4}$
u(k-4)	-0,0305	$1,40 \times 10^{-4}$
u(k-2)	-0,3934	$2,19 \times 10^{-4}$
u(k-3)	0,274363	$1,14 \times 10^{-4}$
MODELO NARX ($n\theta_{AIC} = 4,0$)		
y(k-1)	0,831576	$9,8 \times 10^{-1}$
y(k-2) ²	-0,00226	$5,04 \times 10^{-3}$
u(k-1)y(k-1)	0,002247	$2,36 \times 10^{-3}$
u(k-2)y(k-1)	-0,00143	$3,93 \times 10^{-4}$

Figura 5: Comparação da resposta do modelo ARX estimado com dados puros (em Vermelho) e dados de validação observados no sistema (em preto).




Na Figura 6 é apresentada a resposta do sistema utilizando o modelo não-linear.

Como era esperado, o comportamento caótico ocasionado pela força gerada na contração da mão ao fechá-la, ou que também pode ser decorrente do hardware utilizado, faz com que o modelo não consiga explicar as espículas do sinal de EMG medido mostrado na Figura 3. Tendo em vista que o objetivo é apenas identificar o movimento e não controlar a força do movimento, não cabe a este trabalho encontrar um modelo que represente este comportamento.

Apesar de contraditório, a Figura 5, sugere que o sistema possua características lineares mais abrangentes do que as não lineares, dado que, apesar do modelo NARX ter descrito

melhor o sistema para as magnitudes mais baixas, o modelo ARX descreveu melhor o sistema em magnitudes mais altas.

Figura 6: Comparação da resposta do modelo NARX estimado com dados puros (em Vermelho) e dados de validação observados no sistema (em preto).



Os modelos obtidos utilizando o conjunto de dados com o tratamento de saturação visto na seção II.B, obtiveram boas estimações.

Para a composição estrutural dos modelos NARX, cinco estruturas candidatas para cada conjunto de dados foram testadas. Tais estruturas foram obtidas alterando a margem de não-linearidade, número máximo de polos e zeros permitidos, e a melhor foi escolhida para determinar o modelo NARX.

A Tabela II apresenta os termos, os coeficientes e o ERR para ambos os modelos.

Tabela II: Termos, Parâmetros e Taxa de Redução de Erro para os modelos estimados com dados condicionados.

Termos	$\hat{\theta}_i$	ERR
MODELO ARX ($n\theta_{AIC} = 9,0$)		
u(k-2)	-0,00319	$9,97 \times 10^{-1}$
y(k-1)	1,126519	$1,17 \times 10^{-3}$
y(k-2)	-0,67115	$6,63 \times 10^{-4}$
u(k-1)	0,046765	$1,90 \times 10^{-4}$
y(k-3)	0,468295	$1,62 \times 10^{-5}$
y(k-4)	-0,29286	$7,80 \times 10^{-5}$
Constante	2,169691	$2,54 \times 10^{-5}$
u(k-4)	0,02639	$1,48 \times 10^{-5}$
u(k-3)	-0,02499	$1,38 \times 10^{-6}$
MODELOS NARX ($n\theta_{AIC} = 6,0$)		
y(k-1)	1,712388	$9,97 \times 10^{-1}$
y(k-2)	-0,30127	$2,97 \times 10^{-4}$
u(k-1) ²	7,00E-05	$1,06 \times 10^{-4}$
u(k-2)y(k-1)	-0,00195	$7,99 \times 10^{-6}$
Constante	-28,9663	$1,02 \times 10^{-6}$
u(k-2)	0,097326	$2,24 \times 10^{-7}$

A representação gráfica do resultado do modelo linear, juntamente com os dados de validação, é mostrado na Figura 7. De maneira semelhante, na Figura 8 é apresentado o modelo NARX.

O modelo NARX apresentado na Figura 6 se caracterizou por apresentar resultados próximos ao ideal em magnitudes

mais altas, enquanto o modelo ARX descreve melhor o sistema para as baixas magnitudes.

Figura 7: Comparação da resposta do modelo ARX estimado com dados condicionados (em Vermelho) e dados de validação observados no sistema (em preto).


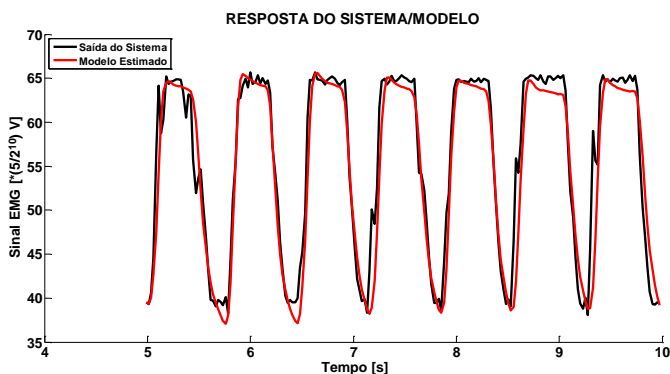


Figura 8: Comparação da resposta do modelo NARX estimado com dados condicionados (em Vermelho) e dados de validação observados no sistema (em preto).



IV. VALIDAÇÃO DOS MODELOS

Os índices RMSE e VAF dos modelos elaborados são apresentados na Tabela III. Além de quantificar o desempenho dos modelos apresentados na Figura 5 e 6, esta tabela também apresenta o desempenho dos modelos estimados com os dados puros, ou seja, dados sem o condicionamento do filtro de saturação.

Tabela III: Índices de desempenho para os modelos em estudo.

MODELO	RMSE	VAF
DADOS CONDICIONADOS		
ARX	0,2880	92.2671%
NARX	0,3088	91.3078%
DADOS PUROS		
ARX	0.63721	62.9824%
NARX	0.69645	53.3079%

A Tabela III revela que o modelo linear estimado com dados condicionados conseguiu melhor desempenho dentre os demais. Porém o modelo não-linear dado com o mesmo conjunto de dados obteve índices muito próximos do melhor modelo. Para os modelos obtidos por dados puros, os índices confirmam a desvantagem de se modelar um sistema na qual nem todas as entradas que o influenciam são controladas.

V. CONCLUSÕES

Neste trabalho, desenvolveu-se modelos matemáticos que relacionam os sinais de EMG medidos sobre o músculo do antebraço, e o movimento da mão, fechar e abrir, usando modelos paramétricos lineares (ARX) e modelos não-lineares (NARX).

A partir dos resultados mostrados na Tabela III, conclui-se que os valores RMSE e VAF obtidos para o modelo linear utilizando dados condicionados pelo filtro de saturação obteve o melhor desempenho.

Considerando que o objetivo do modelo é apenas identificar o movimento de *hand-close*, o modelo linear é simples e capaz de atender a todas as necessidades do projeto.

REFERÊNCIAS

- [1] Ortolan, R. L. (2002). Estudo e Avaliação de Técnicas de Processamento do Sinal Eletromiográfico para o controle de Sistemas de Reabilitação. Tese de Mestrado em Engenharia Elétrica Programa de Pós-Graduação em Engenharia. Universidade de São Paulo – São Carlos - Brasil
- [2] Guyton, Arthur C. Fisiologia humana. Rio de Janeiro GUYTON, ARTHUR C. Fisiologia humana. Rio de Janeiro: Guanabara Koogan, 2008.
- [3] Martins S. Barbosa A. e Nepomuceno E. "Determinação do número de termos de modelos polinomiais: O critério de informação de akaike multiobjetivo", XI Simpósio Brasileiro de Automação Inteligente, outubro 2013.
- [4] E. A. Clancy, L. Liu, P. Liu e D. V. Z. Moyer, "Identification of Constant-Posture EMG-Torque Relationship About the Elbow Using Nonlinear Dynamic Models," IEEE Transactions on Biomedical Engineering, vol. 59, no. 1, pp. 205-212, Jan. 2012. doi: 10.1109/TBME.2011.2170423.
- [5] DEMPSEY, Erika J.; WESTWICK, David T. Identification of Hammerstein models with cubic spline nonlinearities. **IEEE Transactions on Biomedical Engineering**, v. 51, n. 2, p. 237-245, 2004. Omry Paiss e Gideon F. Inbar, "Autoregressive Modeling of Surface EMG and Its Spectrum with Application to Fatigue", *IEEE Transactions on Biomedical Engineering*, vol.34, no. 10, pp. 761-769, October 1987.
- [6] Advancer Technologies. Muscle Sensor v3 Manual. Acedido em 20 de Outubro de 2016, em: <http://www.advancertechnologies.com/p/muscle-sensor-v3.html>
- [7] Khushaba R. N., Kodagoda S. e Dissanayake G;" Toward improved control of prosthetic fingers using surface electromyogram", Science Direct, vol.39, no 12, 99 10731-10738, Setembro 2012.
- [8] Jafari Z, Edrisi M, Marateb HR. An Electromyographic-driven Musculoskeletal Torque Model using Neuro-Fuzzy System Identification: A Case Study. Journal of Medical Signals and Sensors. 2014;4(4):237-246.
- [9] Vishnu R S e Shalu George K, "Modeling of Surface EMG Signals using System Identification Techniques", International Journal of Engineering Research & Technology, Vol.4, pp. 702-705, July-2015.

[10]Aguirre L. “Introdução à identificação de sistemas: técnicas Lineares e não-lineares aplicadas a sistemas reais. ed UFMG, 3º edição revisada e ampliada, 2007.

[11]PETERSON, Robert A. A meta-analysis of variance accounted for and factor loadings in exploratory factor

analysis. **Marketing Letters**, v. 11, n. 3, p. 261-275, 2000.