

# Métodos para Separação de Misturas com Não-Linearidade Posterior Baseados em Inteligência Computacional

Filipe O. Pereira<sup>1,2</sup>, Leonardo T. Duarte<sup>1</sup>, Ricardo Suyama<sup>1,3</sup>, Romis Attux<sup>1,2</sup>

1 – Laboratório de Processamento de Sinais para Comunicações (DSPCom)

2 – Departamento de Engenharia de Computação e Automação Industrial (DCA)

3 – Departamento de Microonda e Óptica (DMO)

Faculdade de Engenharia Elétrica e de Computação (FEEC)

Universidade Estadual de Campinas (UNICAMP)

Caixa Postal 6101, CEP 13083-970 – Campinas, SP, Brasil

{filipe, attux}@dca.fee.unicamp.br; {leonardo.tomazeli.duarte}@gmail.com;  
{rsuyama}@dmo.fee.unicamp.br

**Abstract** – This work is concerned with the problem of blind separation of post-nonlinear mixtures. After a brief exposition of the problem of blind source separation in its linear and nonlinear versions, we discuss the elements of our research on the subject and the aspects that shall be investigated in the final stages of our research project.

**Keywords** – blind source separation, post-nonlinear mixtures, bio-inspired computing.

## 1. Introdução

O problema de separação cega de fontes (*blind source separation* – BSS) é definido a partir da ideia de recuperar, usando o mínimo de informação *a priori* possível, um conjunto de sinais – denominados fontes – a partir de misturas dos mesmos. Ao longo das décadas de 1980 e 1990, o problema de BSS foi tratado fundamentalmente em sua versão linear, o que deu origem a um notável corpo de resultados teóricos de relevo. No entanto, o interesse por métodos para a realização de BSS não-linear [1] tem crescido nos últimos anos, o que se justifica, por exemplo, pela contínua busca por novos e mais complexos domínios de aplicação [2].

Em BSS não-linear, merece destaque o modelo de mistura com não-linearidade posterior (PNL – *post-nonlinear*) [3], o qual, além de representativo, é interessante por permitir o tratamento do problema de BSS via análise de componentes independentes (*ICA-independent component analysis*). Para que se possa resolver o problema PNL de modo não-supervisionado, é essencial que o sistema separador seja composto de aproximadores monotônicos. Nesse caso, pode-se adotar uma metodologia baseada num contraste de informação mútua, havendo, para tanto, necessidade de realizar convenientemente a estimação da entropia das saídas do misturador.

Tendo em vista essa ideia, Duarte et al. [4][5] estabeleceram uma solução composta de um aproximador monotônico polinomial *ad hoc*, de

um processo de estimação de entropia baseado em estatísticas de ordem e num método de otimização bio-inspirado, a rede imunológica artificial opt-aiNet [6]. Em nosso trabalho de mestrado, conforme será exposto neste artigo, pretendemos estender o trabalho de Duarte et al. em dois sentidos: ampliando o leque de ferramentas de otimização por meio da adoção de um sistema imunológico artificial mais simples e de um algoritmo de enxame de partículas e através de adoção de uma gama de estruturas monotônicas mais ampla.

## 2. Separação de Misturas com Não-Linearidade Posterior Através de ICA

A realização de separação cega de fontes (BSS) via análise de componentes independentes (ICA) se baseia na ideia de estimar, de modo não supervisionado, um conjunto de sinais de interesse, supostos mutuamente independentes e não-gaussianos, a partir de misturas dos mesmos. Seja  $\mathbf{s}(t) = [s_1(t), \dots, s_N(t)]^T$  o vetor de sinais das fontes e  $\mathbf{x}(t) = [x_1(t), \dots, x_N(t)]^T$  o vetor de misturas, ambos, *ex hypothesi*, de mesma dimensão. No caso de misturas instantâneas e lineares – o mais usual da literatura [1] –, matematicamente, as misturas são combinações lineares das fontes e podem ser representadas na forma matricial:

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) \quad (1)$$

onde  $\mathbf{A}$  denota a matriz de mistura. Neste caso, uma possibilidade natural é realizar a separação multiplicando o vetor por uma matriz de separação  $\mathbf{W}$ :

$$\mathbf{y}(t) = \mathbf{W}\mathbf{x}(t) \quad (2)$$

A aplicação de ICA ao problema de separação se liga à idéia de escolher  $\mathbf{W}$  de modo que os elementos de  $\mathbf{y}(t)$  sejam estatisticamente independentes [1]. Quando é estruturalmente possível inverter a mistura, isso leva à recuperação das fontes a menos de ambigüidades de permutação e fator de escala [7].

A extensão para o caso *post-nonlinear*, ilustrado na Fig. 1, leva ao seguinte modelo de mistura [5]:

$$\mathbf{x}(t) = \mathbf{f}(\mathbf{A}\mathbf{s}(t)) \quad (3)$$

onde  $\mathbf{f}(\cdot) = [f_1(\cdot), \dots, f_N(\cdot)]^T$  corresponde a um conjunto de não-linearidades inversíveis e sem memória. A matriz  $\mathbf{A}$  também deve ser inversível para que a separação seja viável. Um candidato natural ao sistema separador nesse caso é:

$$\mathbf{y}(t) = \mathbf{W}\mathbf{g}(\mathbf{x}(t)) \quad (4)$$

onde  $\mathbf{g}(\cdot) = [g_1(\cdot), \dots, g_N(\cdot)]^T$  são funções não-lineares que devem ser corretamente ajustadas para “anular o efeito” de  $\mathbf{f}(\cdot)$ , ou seja, fazer com que a cascata de funções  $g_i(\cdot)$  e  $f_i(\cdot)$ , para  $i = 1, \dots, N$ , sempre seja uma função linear.

Diante desses modelos, o processo de separação passa a depender de dois aspectos fundamentais: a escolha de um critério que permita quantificar o grau de independência entre as saídas do separador e de um método de parametrização das funções não-lineares  $\mathbf{g}(\cdot)$ .

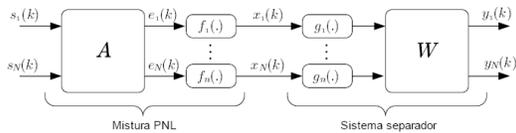


Figura 1. Sistema com Não-Linearidade Posterior

Duarte et al. [5] adotaram a informação mútua (estimada com a ajuda de estatísticas de ordem) como critério de separação e uma parametrização de  $\mathbf{g}(\cdot)$  baseada em polinômios com restrição de monotonicidade, e esse caminho foi seguido por nós em [8]. Vejamos, pois, o problema de otimização resultante em mais detalhe.

### 3. Função Custo Baseada na Informação Mútua e Estimação da Entropia Através de Estatísticas de Ordem

A informação mútua, contraste de ICA que temos adotado, é definida como:

$$I(\mathbf{y}) = \sum_i H(y_i) - H(\mathbf{y}) \quad (5)$$

onde  $H(\mathbf{y})$  representa a entropia diferencial conjunta da saída do separador  $\mathbf{y}$  e  $H(y_i)$  a entropia diferencial de cada um dos elementos desse vetor. Considerando a estrutura de separação mostrada na Figura 1, pode-se expressar a informação mútua das saídas do separador, considerando que as funções  $g_i(\cdot)$  são inversíveis, da seguinte forma:

$$I(\mathbf{y}) = \sum_i H(y_i) - H(\mathbf{x}) - \log |\det \mathbf{W}| - \sum_i \log |g'_i(x_i)| \quad (6)$$

onde  $g'_i$  denota a primeira derivada da  $i$ -ésima não-linearidade  $g_i(\cdot)$  do sistema separador. Analisando essa expressão, vemos que a estimação de  $I(\mathbf{y})$  requer, fundamentalmente, que sejam estimadas as entropias marginais  $H(y_i)$ , já que  $H(\mathbf{x})$  é constante e os demais termos são diretamente determinados pelos parâmetros do separador. Em nosso trabalho, a estimação das entropias marginais tem sido realizada por meio de uma metodologia baseada em estatísticas de ordem [9], uma solução robusta e eficiente do ponto de vista computacional. Para uma descrição mais detalhada dessa metodologia, recomendamos ao leitor a leitura de [4][5][8][9].

O problema de minimizar a informação mútua das saídas do separador, ou, equivalentemente, de minimizar a soma de suas entropias marginais engendra uma tarefa de otimização altamente multimodal e para a qual é proibitivo manipular a função custo (e.g. para obter derivadas). Percebemos, então, que se trata de um cenário propício ao uso de ferramentas de computação natural. De fato, inspirados pelo trabalho de Duarte et al. [5], realizamos uma investigação de dois métodos que ainda não haviam sido usados em separação de misturas PNL, uma versão para otimização real do CLONALG [10] e um algoritmo de enxame de partículas [11], sendo a nossa conclusão de que ambos são opções interessantes e plenamente aplicáveis ao problema em questão. Em nosso trabalho de tese, pretendemos realizar novas investigações no sentido de comparar essas ferramentas.

#### 4. Reflexões sobre as Não-Linearidades do Separador

Em [3], trabalho pioneiro na área de separação de misturas PNL, a solução proposta para a parametrização das não-linearidades do separador foi o uso de uma rede do tipo perceptron de múltiplas camadas. Tal solução sempre nos pareceu arriscada, uma vez que o emprego de uma estrutura tão flexível pode levar a soluções espúrias num contexto não-supervisionado. Tendo isso em vista, Duarte et al. [4][5] optaram pelo uso de polinômios com restrição de monotonicidade, uma solução certamente segura. Apesar disso, consideramos que seria uma contribuição interessante buscar novas estruturas monotônicas, preferencialmente estruturas com capacidade de aproximação universal, o que nos levaria a uma proposta genérica para lidar com o problema PNL. Essa investigação está sendo presentemente conduzida por nós e a sua conclusão coincidirá com o término do trabalho de mestrado.

#### 5. Conclusões

Neste trabalho, apresentamos os fundamentos do problema de separação cega de fontes no contexto de misturas com não-linearidade posterior. Ademais, apresentamos as bases de nosso trabalho de mestrado e também algumas possibilidades que temos investigado e que, certamente, formarão parte importante desse esforço.

#### Agradecimentos

Gostaríamos de agradecer a colaboração do pesquisador Everton Nadalin, que muito tem contribuído para o avanço dessa pesquisa. Também somos gratos à CAPES, que financia este trabalho de mestrado.

#### Referências

- [1] Hyvärinen, A., Karhunen, J., Oja, E., *Independent Component Analysis*, John Wiley & Sons (2001).
- [2] Duarte, L.T., *Design of Smart Chemical Sensor Arrays: an Approach Based on Source Separation Methods*. Tese de Doutorado, Institut Polytechnique de Grenoble, Novembro de 2009.
- [3] Taleb, A., Jutten, C., “*Source Separation in Postnonlinear Mixtures*”, IEEE Trans. Signal

Processing, Vol. 47, No. 10, pp. 2807-2820 (1999).

[4] Duarte, L.T., *Um Estudo sobre Separação Cega de Fontes e contribuições ao Caso de Misturas Não-lineares*. Tese de Mestrado, Faculdade de Engenharia Elétrica e de Computação – FEEC – UNICAMP, Campinas, Agosto de 2006.

[5] Duarte, L.T., Suyama, R., Attux, R., Von Zuben, F.J., Romano, J.M.T., “*Blind Source Separation of Post-Nonlinear Mixtures Using Evolutionary Computation and Order Statistics*”, Springer Lecture Notes in Computer Science, vol. 3889, pp. 66–73 (2006).

[6] de Castro, L. N., Timmis, J., “*An Artificial Immune Network for Multimodal Function Optimization*”, Proceedings of the IEEE Congress on Evolutionary Computation, EUA (2002).

[7] Comon, P., “*Independent Component Analysis, a New Concept?*”, Signal Processing, Vol. 36, No. 3, pp. 287-314 (1994).

[8] Pereira, F. O. ; Nadalin, E. Z. ; Suyama, R. ; Attux, R. R. de F. “*Análise do Emprego de Ferramentas de Computação Natural no Problema de Separação de Misturas com Não-Linearidade Posterior*”. In: XXVII SIMPÓSIO BRASILEIRO DE TELECOMUNICAÇÕES SBrT 2009, 2009, Blumenau. Anais do XXVI Simpósio Brasileiro de Telecomunicações (SBrT'09), 2009.

[9] Pham, D.-T., “*Blind Separation of Instantaneous Mixtures of Sources Based on Order Statistics*”, IEEE Trans. Signal Processing, Vol. 48, No. 2, pp. 363-375 (2000).

[10] de Castro, L. N., Von Zuben, F. J., “*Learning and Optimization Using the Clonal Selection Principle*”, IEEE Trans. on Evolutionary Computation, Vol. 6, No. 3, pp. 239-251 (2002).

[11] Kennedy, J., Eberhart, R. C., “*Particle Swarm Optimization*”, Proceedings of the IEEE International Conference on Neural Networks, Austrália (1995).