

Recuperação Cega de Sinais

Conceitos, Estratégias e Tendências

Charles Casimiro Cavalcante¹

charles@gtel.ufc.br

João Marcos T. Romano²

romano@decom.fee.unicamp.br

¹ Grupo de Pesquisa em Telecomunicações Sem Fio – GTEL
Universidade Federal do Ceará – UFC
<http://www.gtel.ufc.br>




² Lab. de Processamento de Sinais para Comunicações – DSPCom
Universidade Estadual de Campinas – UNICAMP
<http://www.dspcom.fee.unicamp.br>



XXI Simpósio Brasileiro de Telecomunicações (SBT2004)
6-9 de Setembro, Belém-PA, Brasil

- Modelagem abrange uma variedade muito grande de problemas
- Estratégias utilizam conhecimentos de várias disciplinas
 - Processamento de sinais
 - Estatística
 - Teoria da informação
- Aplicação em diversas áreas
 - Comunicações
 - Processamento de imagens
 - Reconhecimento de padrões
 - Econometria
 - ...

Contexto - Cocktail party



- Modelagem matemática do problema de recuperação cega de sinais
 - Multidimensional
 - Unidimensional
- Estratégias de recuperação cega de sinais
- Modelagem de sistemas de comunicação multi-usuário no contexto de recuperação de sinais
- Ilustrar casos particulares de interesse prático

- 1 Separação cega de fontes
- 2 Processamento multi-usuário
- 3 Casos particulares: formalismo e conceitos
- 4 Tendências e perspectivas
- 5 Sugestões bibliográficas

Part I

Separação Cega de Fontes

Considerações iniciais I

- Sistemas de comunicação digital: utilização de seqüências conhecidas para remover “dispersões” inseridas pelo meio transmissão
- Eficiência da estratégia é diminuída pela ocupação do espectro com sinais que não contém efetivamente mensagem a ser transmitida
- Estratégias que permitam a recuperação dos sinais envolvidos têm grande apelo prático

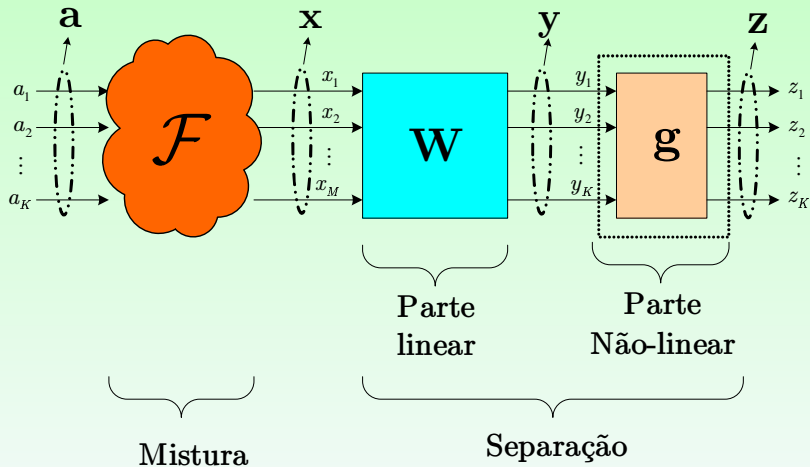
Denominações de tais estratégias

- 1 *Autodidata*
- 2 *Cega*
- 3 *Não-supervisionada*

Considerações iniciais II

- Estudos iniciais: anos 70 e 80, utilizando sistemas de comunicação digital com única fonte
- 1985: modelo genérico, múltiplas fontes, surgimento de uma nova linha de pesquisa denominada *separação cega de fontes*
- Confluência de várias áreas de conhecimento

Modelo geral



Modelo

$$\mathbf{x}(n) = \mathcal{F}(\mathbf{a}(n), \mathbf{v}(n), n) \longleftarrow \text{Mapeamento}$$

$$\mathbf{a}(n) = [a_1(n) \quad a_2(n) \quad \cdots \quad a_K(n)]^T \longleftarrow K \text{ fontes}$$

$$\mathbf{v}(n) = [v_1(n) \quad v_2(n) \quad \cdots \quad v_V(n)]^T \longleftarrow V \text{ sinais de ruído}$$

$$\mathbf{x}(n) = [x_1(n) \quad x_2(n) \quad \cdots \quad x_M(n)]^T \longleftarrow M \text{ sensores.}$$

Considerações usuais

- \mathcal{F} é linear e invariante no tempo
- Fontes mutuamente independentes e independentes do ruído
- $V = M$
- $M \geq K$ (mais sensores que fontes no mínimo)

Mistura

$$\mathbf{x}(n) = \mathbf{H}\mathbf{a}(n) + \mathbf{v}(n)$$

Separação

$$\mathbf{y}(n) = \mathbf{W}^H \mathbf{x}(n) = \hat{\mathbf{a}}(n)$$

Características

- 1 Indeterminação em relação a permutação e escalonamento

$$\mathbf{y}(n) = \mathbf{P}\mathbf{D}\mathbf{a}(n)$$

\mathbf{P} é uma matriz de permutação de ordem $K \times K$ e \mathbf{D} é uma matriz diagonal e inversível de ordem $K \times K$.

- 2 Possível inserção de não-linearidade após \mathbf{W}

$$\mathbf{x} = \mathbf{H}\mathbf{a}$$

$$\begin{cases} x_1 = h_{11}a_1 + h_{12}a_2 \\ x_2 = h_{21}a_1 + h_{22}a_2 \end{cases}$$

Duas (K) variáveis e duas (M) equações!

- Caso sem ruído: *separar é possível se* $\mathbf{W} = \mathbf{H}^{-1}$

Questão 1

Como identificar \mathbf{H} para projetar \mathbf{W} ?

Questão 2

Quais (e quantas) estatísticas são necessárias para prover a separação?

Resposta para questão 1: Como identificar \mathbf{H} ?

- Observando a matriz de autocorrelação do vetor de sinais recebidos:

$$\mathbf{R}_x = \mathbb{E} \{ \mathbf{x}(n) \mathbf{x}^T(n) \} = \mathbf{H} \mathbf{R}_a \mathbf{H}^T = \mathbf{H} \mathbf{H}^T,$$

- Observar que $\mathbf{H} \mathbf{Q}^T$, em que \mathbf{Q} é uma matriz ortogonal também soluciona equação
- Conclui-se que: $\mathbf{H} = \mathbf{R}_x^{\frac{1}{2}}$
- Extração de raiz quadrada de matrizes: através de decomposição em valores singulares (SVD, Singular Value Decomposition)

Identificando \mathbf{H} : possibilidades

- Escrevendo

$$\mathbf{H} = \mathbf{U}\mathbf{\Lambda}^{\frac{1}{2}}\mathbf{V}^T,$$

em que \mathbf{U} e \mathbf{V} são matrizes retangulares de ordem $K \times M$, tais que $\mathbf{U}\mathbf{U}^T = \mathbf{V}\mathbf{V}^T = \mathbf{I}_M$ e $\mathbf{U}^T\mathbf{U} = \mathbf{V}^T\mathbf{V} = \mathbf{I}_K$

- Então...

$$\begin{aligned}\mathbf{R}_x &= \mathbf{U}\mathbf{\Lambda}^{\frac{1}{2}}\mathbf{V}\mathbf{V}^T\mathbf{\Lambda}^{\frac{1}{2}}\mathbf{U}^T \\ &= \mathbf{U}\mathbf{\Lambda}\mathbf{U}^T.\end{aligned}$$

- Resultado: através da matriz de autocorrelação (estatística de ordem 2) só é possível identificar as matrizes \mathbf{U} e $\mathbf{\Lambda}$
- Estatísticas de ordem 2 (SOS, Second Order Statistics) não resolvem o problema por completo
- **Resposta parcial da questão 2: estatísticas necessárias para separação!**

Processamento

Projeção dos dados na direção da inversa da matriz de autocorrelação: $\mathbf{T} = \mathbf{R}_x^{-\frac{1}{2}}$

- Assim, tem-se o seguinte conjunto de dados:

$$\bar{\mathbf{x}}(n) = \mathbf{T}\mathbf{x}(n)$$

de tal forma que

$$\begin{aligned}\mathbf{R}_{\bar{\mathbf{x}}} &= \mathbf{T}\mathbf{R}_x\mathbf{T}^T \\ &= \mathbf{U}\mathbf{\Lambda}^{-\frac{1}{2}}\mathbf{U}^T\mathbf{U}\mathbf{\Lambda}\mathbf{U}^T\mathbf{U}^T\mathbf{\Lambda}^{-\frac{1}{2}}\mathbf{U} \\ &= \mathbf{I}_K\end{aligned}$$

- Branqueamento!** - em separação cega de fontes é denominado de *esferatização*

- Projeção dos dados na direção dos principais autovetores de \mathbf{R}_x
- Técnica de análise por componentes principais (PCA, Principal Component Analysis): projeção dos dados nas direções definidas pelos principais autovetores de \mathbf{H}
- Matriz de branqueamento, ou *transformação de Mahalanobis*, é escrita como

$$\mathbf{T} = \mathbf{\Lambda}^{-\frac{1}{2}} \mathbf{U}_x^T.$$

- Redução do problema para uma matriz de mistura ortogonal

$$\bar{\mathbf{x}}(n) = \mathbf{T}\mathbf{H}\mathbf{a}(n) = \mathbf{Q}\mathbf{a}(n)$$

em que $\mathbf{Q}\mathbf{Q}^T = \mathbf{I}$.

Encontrando a matriz \mathcal{V}

Considerar um atraso arbitrário ℓ para o qual, não haja duas fontes, i e j , com a mesma autocorrelação

$$\mathbb{E} \{a_i(n)a_i(n - \ell)\} \neq \mathbb{E} \{a_j(n)a_j(n - \ell)\} \quad \forall i \neq j,$$

Diferentes densidades espectrais!

$$\begin{aligned} \mathbf{R}_{\bar{x}}(k) &= \mathbb{E} \{ \bar{\mathbf{x}}(n) \bar{\mathbf{x}}^T(n - \ell) \} \\ &= \mathbf{T} \mathbf{H} \mathbf{R}_a(\ell) \mathbf{H}^T \mathbf{T}^T \\ &= \underbrace{\mathbf{\Lambda}^{-\frac{1}{2}} \mathbf{U}^T}_{\mathbf{T}} \underbrace{\mathbf{U} \mathbf{\Lambda}^{\frac{1}{2}} \mathcal{V}^T}_{\mathbf{H}} \mathbf{R}_a(\ell) \underbrace{\mathcal{V} \mathbf{\Lambda}^{\frac{1}{2}} \mathbf{U}^T}_{\mathbf{H}^T} \underbrace{\mathbf{U} \mathbf{\Lambda}^{-\frac{1}{2}}}_{\mathbf{T}^T} \\ &= \mathcal{V}^T \mathbf{R}_a(\ell) \mathcal{V}. \end{aligned}$$

- Fontes independentes $\Rightarrow \mathbf{R}_a(\ell)$ diagonal
- Autovalores distintos: fontes com diferentes autocorrelações
- Conclusão: *uso somente de SOS permite separar fontes com espectros diferentes!*
- Algoritmo clássico: *Algorithm for Multiple Unknown Signals Extraction* (AMUSE)
- Na prática, fontes com espectros similares (embora diferentes) não são separáveis
- Impossibilidade de separar fonte brancas ou i.i.d.

Como separar fontes com mesmo espectro?

Proposição de uma nova técnica

- Não procura-se estimar \mathbf{H} para projetar \mathbf{W}
- Fator decisivo: suposição de independência das fontes!
- Projetar \mathbf{W} de maneira que sejam obtidas fontes *o mais independentes possível* na saída do dispositivo de separação
- *Independent Component Analysis (ICA)*
- Restrição: no máximo uma fonte pode ser gaussiana
 - Teorema Central do Limite: mistura de gaussianas é gaussiana!
- Interpretação: ponto chave é a não-gaussianidade das fontes.

Questão

Como medir a não-gaussianidade das fontes e utilizar o fato de que as mesmas são estatisticamente independentes para separá-las?

Independência estatística

$$p_{\mathbf{y}}(\mathbf{y}) \triangleq \prod_{i=1}^K p_{y_i}(y_i)$$

$$\mathbb{E}\{y_1 \cdot y_2 \cdots y_K\} = \mathbb{E}\{y_1\} \cdot \mathbb{E}\{y_2\} \cdots \mathbb{E}\{y_K\}$$

Descorrelação estatística

$$\mathbb{E}\{y_1 \cdot y_2 \cdots y_K\} - \mathbb{E}\{y_1\} \cdot \mathbb{E}\{y_2\} \cdots \mathbb{E}\{y_K\} = 0.$$

Independência \Rightarrow Descorrelação
 \nLeftarrow

Entropia e informação mútua

$$\mathcal{H}(\mathbf{x}) \triangleq -\mathbb{E} \{ \ln [p_x(\mathbf{x})] \} = - \int_{-\infty}^{\infty} p_x(\mathbf{x}) \cdot \ln [p_x(\mathbf{x})] d\mathbf{x}$$

entropia diferencial


$$\begin{aligned} \mathcal{H}(\mathbf{x}|\mathbf{y}) &= -\mathbb{E} \{ \ln [p_{x|y}(\mathbf{x}|\mathbf{y})] \} \\ &= \int p_{x,y}(\mathbf{x}, \mathbf{y}) \cdot \ln [p_{x|y}(\mathbf{x}|\mathbf{y})] d\mathbf{x}d\mathbf{y} \end{aligned}$$

entropia condicional


$$I(\mathbf{x}, \mathbf{y}) = \mathcal{H}(\mathbf{x}) - \mathcal{H}(\mathbf{x}|\mathbf{y})$$

informação mútua entre \mathbf{x} e \mathbf{y}

E se as fontes forem gaussianas?



Mistura de fontes gaussianas



Mistura de fontes uniformes

Não há direções preferenciais!

Divergência de Kullback-Leibler (KLD)

$$D(p_x(\mathbf{x})||g_x(\mathbf{x})) \triangleq \int_{-\infty}^{\infty} p_x(\mathbf{x}) \cdot \ln \left[\frac{p_x(\mathbf{x})}{g_x(\mathbf{x})} \right] dx$$

em que $p(x)$ e $g(x)$ são duas funções estritamente positivas

Propriedades:

- 1 é sempre de valor positivo ou zero; KLD é zero para o caso específico de $p_x(\mathbf{x}) = g_x(\mathbf{x})$.
- 2 é invariante com relação as seguintes mudanças nas componentes do vetor \mathbf{x} :
 - permutação de ordem
 - escalonamento de amplitude
 - transformação monotônica não-linear

Usando a KLD...

$$\begin{aligned} I(\mathbf{x}, \mathbf{y}) &= \int p_{x,y}(\mathbf{x}, \mathbf{y}) \cdot \ln \left[\frac{p_{x,y}(\mathbf{x}, \mathbf{y})}{p_x(\mathbf{x}) p_y(\mathbf{y})} \right] d\mathbf{x} d\mathbf{y} \\ &= D(p_{x,y}(\mathbf{x}, \mathbf{y}) \| p_x(\mathbf{x}) p_y(\mathbf{y})) \end{aligned}$$

ou ainda

$$\begin{aligned} I(\mathbf{y}) &= D(p_y(\mathbf{y}) \| \tilde{p}_y(\mathbf{y})) \\ &= \int \cdots \int p_y(y_1, \dots, y_K) \cdot \ln \left[\frac{p_y(y_1, \dots, y_K)}{\prod_{i=1}^K p_{y_i}(y_i)} \right] dy_1 \cdots dy_K \end{aligned}$$

Finalmente...

$$I(\mathbf{y}) = -\mathcal{H}(\mathbf{y}) + \sum_{i=1}^K \mathcal{H}(y_i),$$

o que significa que minimizar a informação mútua entre os componentes do vetor \mathbf{y} significa tornar a entropia de \mathbf{y} o mais próximo possível da soma de suas entropias marginais.

Negentropia - I

- Medida de “não-gaussianidade” baseado na medida de entropia diferencial
- Diferença entre a entropia da v.a. \mathbf{y} e a entropia de uma v.a. \mathbf{y}^G de distribuição gaussiana e com os mesmos momentos de ordem um e dois (média e variância) de \mathbf{y}

$$N_G(\mathbf{y}) \triangleq \mathcal{H}(\mathbf{y}^G) - \mathcal{H}(\mathbf{y}).$$

ou

$$N_G(\mathbf{y}) \triangleq D(p_{\mathbf{y}}(\mathbf{y}) \| p_{\mathbf{y}^G}(\mathbf{y}))$$

- **Problema: requer conhecimento ou estimativa da densidade de probabilidade de \mathbf{y} !**

Negentropia - II

- Possibilidade de expressar estatísticas necessárias para separação
- Utilizando KLD e informação mútua pode-se escrever:

$$I(\mathbf{y}) = I(\mathbf{y}^G) + \left(N_G(\mathbf{y}) - \sum_{i=1}^K N_G(y_i) \right).$$

- 1 Primeiro termo utiliza SOS
- 2 Segundo termo mede não-gaussianidade do sinal

Kurtosis

- Cumulante de quarta ordem

$$\mathcal{K} \{y\} \triangleq \mathbb{E} \{y^4\} - 3 \cdot (\mathbb{E} \{y^2\})^2.$$

- Faixa de valores:

- ▶ Distribuição gaussiana: $\mathcal{K} \{y\} = 0$
- ▶ Distribuição sub-gaussiana: $\mathcal{K} \{y\} \leq 0$
- ▶ Distribuição super-gaussiana: $\mathcal{K} \{y\} \geq 0$

- Propriedades

$$\mathcal{K} \{y_1 + y_2\} = \mathcal{K} \{y_1\} + \mathcal{K} \{y_2\}$$

$$\mathcal{K} \{\alpha \cdot y\} = \alpha^4 \cdot \mathcal{K} \{y\}$$

Funções de contraste

- Uma função $\Psi(\cdot)$, no espaço de K fdps (distintas ou não) é dita ser um *contraste* se respeita as seguintes condições:

- 1 $\Psi(p_y)$ é invariante a permutações:

$$\Psi(p_{P_y}) = \Psi(p_y) \text{ para qualquer matriz de permutação } \mathbf{P}$$

- 2 $\Psi(p_y)$ é invariante a mudanças de escala:

$$\Psi(p_{D_y}) = \Psi(p_y) \text{ para qualquer matriz diagonal } \mathbf{D}$$

- 3 Se y possui componentes independentes, então:

$$\Psi(p_{W_y}) \leq \Psi(p_y) \text{ para qualquer matriz inversível } \mathbf{W}$$

Algumas funções de contraste

$$\Psi_{\text{ICA}}(p_y) = -I(\mathbf{y})$$

ou ainda em relação à matriz de separação

$$\Psi_{\text{ICA}}(\mathbf{W}) = \ln [|\det(\mathbf{W})|] - \mathbb{E} \left\{ \ln \left[\prod_{i=1}^K p_{y_i}(y_i) \right] \right\}$$

Aproximações da negentropia

- Necessário para evitar estimações da fdp
- Momentos de ordem superior (clássica)

$$N_G(\mathbf{y}) \approx \frac{1}{12} [\mathbb{E} \{\mathbf{y}^3\}]^2 + \frac{1}{48} [\mathcal{K} \{\mathbf{y}\}]^2,$$


- Classe de aproximações (*FastICA*)

$$N_G(\mathbf{y}) \approx \sum_{i=1}^p \varrho_i \cdot [\mathbb{E} \{g_i(\mathbf{y})\} - \mathbb{E} \{g_i(\nu)\}]^2$$

$$g_1(u) = \frac{1}{a_1} \log [\cosh(a_1 u)] \text{ e}$$

$$g_2(u) = -\exp\left(-\frac{u^2}{2}\right)$$

Diferença ICA × PCA



- 1 PCA: projeta numa dimensão menor preservando *máxima variância* dos dados
- 2 ICA: projeta numa dimensão menor preservando *estrutura* dos dados

MaxEnt/InfoMax - I

- Separação é obtida quando estimativas das fontes são independentes $\Rightarrow I(\mathbf{y}) = 0$

$$I(\mathbf{z}, \mathbf{x}) = \mathcal{H}(\mathbf{z}) - \mathcal{H}(\mathbf{z}|\mathbf{x})$$

- Mapeamento é determinístico, logo $\mathcal{H}(\mathbf{z}|\mathbf{x}) = 0$

$$I(\mathbf{y}, \mathbf{x}) = \mathcal{H}(\mathbf{y})$$

- Entropia de \mathbf{y} não é limitada, então

$$\mathbf{z} = \mathbf{g}(\mathbf{W}\mathbf{x})$$

MaxEnt/InfoMax - II

- Funções $g_i(\cdot)$ monotonicamente crescentes, limitadas de tal forma que $g_i(-\infty) = 0$ e $g_i(\infty) = 1$
- Se $g_i(\cdot)$ for igual à função de distribuição cumulativa (fdc) da i -ésima fonte

$$p_z(\mathbf{z}) = U[0, 1], \quad \text{para}$$

- Adaptação

$$\Delta \mathbf{W} \propto (\mathbf{W}^{-T})^{-1} - 2 \cdot \tanh(\mathbf{W}\mathbf{x}) \mathbf{x}^T,$$

- Função contraste

$$\max_{\mathbf{W}} \left(\Psi_{\text{InfoMax}}(\mathbf{W}) \triangleq \ln [|\det(\mathbf{W})|] - \mathbb{E} \left\{ \ln \left[\prod_{i=1}^K g'_i(y_i) \right] \right\} \right).$$

Máxima verossimilhança - I

- Entropia

$$\mathcal{H}(\mathbf{z}) = - \int p_z(\mathbf{z}) \ln \left[\frac{p_z(\mathbf{z})}{\prod_{i=1}^K U(z_i)} \right] d\mathbf{z} = -D(p_z(\mathbf{z}) \| U_N(\mathbf{z}))$$

- Modelo paramétrico Θ

$$\mathcal{L}_Q(\Theta) = \frac{1}{Q} \ln \left[\prod_{q=1}^Q p_x(\mathbf{x}(q) | \Theta) \right] = \frac{1}{Q} \sum_{q=1}^Q \ln [p_x(\mathbf{x}(q) | \Theta)].$$

Máxima verossimilhança - II

- Lei dos grandes números

$$\mathcal{L}_Q(\Theta) \xrightarrow{Q \rightarrow \infty} \mathcal{L}(\mathbf{W}) \triangleq \int p_y(\mathbf{y}|\mathbf{W}) \ln [p_{\tilde{\mathbf{a}}}(\mathbf{y})] d\mathbf{y} + \ln [|\det(\mathbf{W})|].$$

- Usando KLD

$$\begin{aligned} \mathcal{L}(\mathbf{W}) &= -D(p_x(\mathbf{y}|\mathbf{W}) \| p_{\tilde{\mathbf{a}}}(\mathbf{y})) - \mathcal{H}(\mathbf{y}|\mathbf{W}) + \ln [|\det(\mathbf{W})|] \\ &= -D(p_x(\mathbf{y}|\mathbf{W}) \| p_{\tilde{\mathbf{a}}}(\mathbf{y})) - \mathcal{H}(\mathbf{x}) \end{aligned}$$

- Função contraste MV

$$\Psi_{MV}(\mathbf{W}) = -D(\mathbf{W}\mathbf{H}\mathbf{a} \| \tilde{\mathbf{a}}).$$

Máxima verossimilhança - III

- Interpretação da MV

$$-\Psi_{MV}(\mathbf{W}) = -\Psi_{ICA}(\mathbf{W}) + \sum_{i=1}^K D(\tilde{z}_i \| \tilde{a}_i)$$

ou seja

$$\begin{pmatrix} \text{Desvio} \\ \text{total} \end{pmatrix} = \begin{pmatrix} \text{Desvio da} \\ \text{independência} \end{pmatrix} + \begin{pmatrix} \text{Desvio} \\ \text{marginal} \end{pmatrix}.$$

e ainda

$$\Psi_{ICA}(\mathbf{W}) = \max_{\tilde{\mathbf{a}}} (\Psi_{MV}(\mathbf{W})).$$

Critério “universal”

$$J_{\text{BSS}}(\mathbf{W}) = \ln [|\det|(\mathbf{W})|] - \ln \left[\prod_{i=1}^K \phi_i(y_i) \right]$$

em que $\mathbf{y} = \mathbf{W}\mathbf{x}$ e, idealmente, as funções $\phi_i(\cdot)$ são as fdps das fontes.

Questão

Como encontrar ou estimar as fdps das fontes?

Resposta possível

Expansões polinomiais através dos cumulantes.

Critério geral

- Derivando J_{BSS} em relação a \mathbf{W}

$$\nabla J(\mathbf{W}) = (\mathbf{W}^T)^{-1} - \mathbf{f}(\mathbf{z}) \mathbf{x}^T$$

em que

$$\mathbf{f}(\mathbf{z}) = \left[-\frac{\phi'_1(z_1)}{\phi_1(z_1)} \quad -\frac{\phi'_2(z_2)}{\phi_2(z_2)} \quad \dots \quad -\frac{\phi'_K(z_K)}{\phi_K(z_K)} \right]^T.$$

e

$$\Delta \mathbf{W}(n) \propto (\mathbf{W}^T)^{-1} - \mathbf{f}(\mathbf{z}(n)) \mathbf{x}(n)^T.$$

- Se $\phi_i(z_i) = \frac{1}{1 + \exp(-z_i)}$, o algoritmo torna-se *InfoMax/MaxEnt*

Algoritmo Jutten-Hérault - I

- Trabalho pioneiro em BSS: cancelamento das correlações cruzadas para obter sinais independentes
- Utilização de funções não-lineares
- Correlações do tipo $\mathbb{E} \{g_1(y_i)g_2(y_j)\}$, em que $g_1(\cdot)$ e $g_2(\cdot)$ são funções não-lineares adequadamente escolhidas
- Adaptação

$$\Delta \mathbf{W}_{ij} \propto g_1(y_i) \cdot g_2(y_j) \quad \forall i \neq j$$
$$\mathbf{y} = (\mathbf{I} + \mathbf{W})^{-1} \mathbf{x}$$


- Solução *ad hoc* - problemas de convergência

Algoritmo Jutten-Hérault - II

- Outra implementação

$$\Delta \mathbf{W} \propto (\mathbf{I} - g_1(\mathbf{y}) \cdot g_2(\mathbf{y}^T)) \cdot \mathbf{W},$$

em que $\mathbf{y} = \mathbf{W}\mathbf{x}$



Equivariância e gradiente relativo/natural - I

- Algoritmo Jutten-Hérault: necessidade de inversão de matriz a cada instante
- Condicionado ao tipo de matriz de mistura
- *Estimador equivariante*: $\hat{\mathbf{E}} \langle \mathbf{W}\mathbf{x} \rangle = \mathbf{W} \hat{\mathbf{E}} \langle \mathbf{x} \rangle$
- Logo

$$\begin{aligned}\hat{\mathbf{a}} &= \left(\hat{\mathbf{E}} \langle \mathbf{x} \rangle \right)^{-1} \mathbf{x} \\ &= \left(\hat{\mathbf{E}} \langle \mathbf{H}\mathbf{a} \rangle \right)^{-1} \mathbf{H}\mathbf{a} \\ &= \left(\mathbf{H} \hat{\mathbf{E}} \langle \mathbf{a} \rangle \right)^{-1} \mathbf{H}\mathbf{a} \\ &= \left(\hat{\mathbf{E}} \langle \mathbf{a} \rangle \right)^{-1} \mathbf{a}\end{aligned}$$

Equivariância e gradiente relativo/natural - II

- Algoritmo EASI (*Equivariant Adaptive Separation via Independence*)

$$\Delta \mathbf{W}(n) \propto (\mathbf{I} - \mathbf{f}(\mathbf{z}(n)) \mathbf{z}^T(n)) \mathbf{W}(n)$$

- Na resposta combinada $\mathbf{G} = \mathbf{H}\mathbf{W}$


$$\Delta \mathbf{G}(n) \propto (\mathbf{I} - \mathbf{f}(\mathbf{z}(n)) \mathbf{z}^T(n)) \mathbf{G}(n)$$

- Gradiente relativo/natural

$$\tilde{\nabla} \Lambda(\mathbf{W}) \triangleq \left. \frac{\partial \Lambda((\mathbf{I} + \mathbf{\Xi})\mathbf{W})}{\partial \mathbf{\Xi}} \right|_{\mathbf{\Xi}=\mathbf{0}}$$

Deflation

- Separação *serial* das fontes
- Interessante quando não se deseja todas as fontes da mistura
- Algum conhecimento é utilizado para identificar uma fonte e as outras são removidas por etapas



FastICA - I

- Tem por base a maximização da negentropia através de uma aproximação específica

$$\max_{\mathbf{G}^T \mathbf{G} = \mathbf{I}} \left(\Psi_{\text{FastICA}}(\mathbf{W}) \triangleq \left| \mathbb{E} \{g(\mathbf{y}) - g(\mathbf{y}^{\mathbf{G}})\} \right|^2 \right)$$

- Maximizar a divergência entre variável e sua versão gaussiana utilizando funções não-lineares que extraem informações das HOS
- Processamento com restrição

$$\begin{cases} \max_{\mathbf{w}_1, \dots, \mathbf{w}_K} \sum_{i=1}^K \Psi_{\text{FastICA}}(\mathbf{w}_i) \\ \text{sujeito a} & \mathbf{w}_i \mathbf{w}_j^T = \delta_{ij}, \end{cases}$$

FastICA - II

- Se cada vetor \mathbf{w}_i possui norma unitária e $g(\mathbf{y}^G)$ é constante então

$$\max_{\|\mathbf{g}_i\|=1} \mathbb{E} \{F(\mathbf{w}_i^T \mathbf{x})\}$$

- A solução da equação é dada por $\mathbb{E} \{ \mathbf{x} f(\mathbf{w}_i^T \mathbf{x}) \} - \beta \mathbf{w}_i = \mathbf{0}$
- Aplicação da aproximação de Newton no gradiente da solução fornece

$$\mathbf{w}_i^\dagger(n+1) = \mathbb{E} \{ \mathbf{x} f(\mathbf{w}_i^T(n) \mathbf{x}) \} - \mathbb{E} \{ f'(\mathbf{w}_i^T(n) \mathbf{x}) \} \mathbf{w}_i(n)$$

$$\mathbf{w}_i(n+1) = \frac{\mathbf{w}_i^\dagger(n+1)}{\|\mathbf{w}_i^\dagger(n+1)\|}$$

FastICA

Nonlinear PCA - I

- Generalização de PCA através de uma projeção não-linear
- Função custo

$$\Psi_{\text{nPCA}}(\mathbf{W}) = \mathbb{E} \{ \|\mathbf{x} - \mathbf{W}^T \mathbf{g}(\mathbf{W}\mathbf{x})\|^2 \}$$

- Para \mathbf{W} ortogonal (branqueamento)

$$\begin{aligned} \Psi_{\text{nPCA}}(\mathbf{W}) &= \mathbb{E} \{ \|\mathbf{W}\mathbf{x} - \mathbf{g}(\mathbf{W}\mathbf{x})\|^2 \} \\ &= \mathbb{E} \{ \|\mathbf{y} - \mathbf{g}(\mathbf{y})\|^2 \} \\ &= \sum_{i=1}^K \mathbb{E} \{ |y_i - g_i(y_i)|^2 \} \end{aligned}$$

- Forte ligação com critério de Bussgang (equalização cega)!

Nonlinear PCA - II

- Adaptação possível

$$\Delta \mathbf{w}_i \propto g(y_i) \mathbf{x} - g(y_i) \sum_{j=1}^i g(y_j) \mathbf{w}_j$$

- Simplificação: *algoritmo bigradiente*

$$\Delta \mathbf{W}(n) \propto \mu(n) g[\mathbf{W}(n) \mathbf{x}(n)] \mathbf{x}^T(n) + \alpha [\mathbf{I} - \mathbf{W}(n) \mathbf{W}^T(n)] \mathbf{W}(n)$$

- Ou de forma equivalente

$$\Delta \mathbf{W}(n) \propto [\mathbf{x}^T(n) - \mathbf{W}(n) \mathbf{f}(\mathbf{z}^T(n))] \mathbf{f}(\mathbf{z}(n))$$

Part II

Processamento multi-usuário

Características de processamento multi-usuário

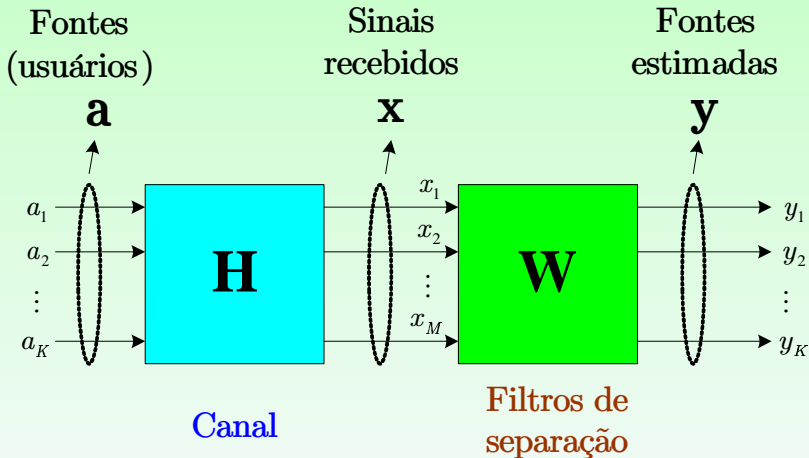
- Múltiplos usuários dividindo recursos do canal
- Diversidade espacial no receptor é considerada para fornecer remoção de interferência (múltiplo acesso e inter-simbólica): geralmente é empregado um arranjo de antenas
- Modelo espacial ou espaço-temporal: depende da faixa considerada do canal comparada com a faixa dos sinais
- **Processamento multi-usuário**: separar *todos* os usuários de uma combinação dos sinais

Características da fonte

- Fontes discretas
- Alfabeto finito
- Mesma distribuição de probabilidade

Processamento é possível com estruturas lineares!

Esquema de processamento multi-usuário: notação



- Resposta do canal entre o k -ésimo usuário e o elemento de referência do arranjo

$$h_{0,k}(t) = \sum_{i=0}^{L_k-1} \alpha_{k,i} \cdot \delta(t - \tau_{k,i}),$$

onde L_k é o número de multipercursos, $\alpha_{k,i}$ é uma v.a. que modela o desvanecimento e rotação de fase e $\tau_{k,i}$ são os atrasos relativos de cada multipercurso do k -ésimo usuário

- Resposta do canal entre k -ésimo usuário e m -ésimo elemento do arranjo

$$h_{m,k}(t) = f_m(\theta_k) \cdot \sum_{i=0}^{L_k-1} \alpha_{k,i} \cdot \delta(t - \tau_{k,i}),$$

- Vetor de resposta impulsiva

$$\mathbf{h}_{m,k}(t) = \sum_{i=0}^{L_k-1} \mathbf{f}(\theta_{k,i}) \cdot \alpha_{k,i} \cdot \delta(t - \tau_{k,i}),$$

Interferência de múltiplo acesso: modelo I

- Faixa do canal é mais estreita que a da portadora
- Todos os delays relativos são aproximadamente iguais:

$$\tau_{k,i} = \tau_k$$

$$\mathbf{h}_{m,k}(t) = \delta(t - \tau_k) \sum_{i=0}^{L_k-1} \mathbf{f}(\theta_{k,i}) \cdot \alpha_{k,i} = \delta(t - \tau_k) \cdot \mathbf{s}_k,$$

em que \mathbf{s}_k é a *assinatura espacial* do k -ésimo usuário, dada por

$$\mathbf{s}_k = \sum_{i=0}^{L_k-1} \mathbf{f}(\theta_{k,i}) \cdot \alpha_{k,i}.$$

Interferência de múltiplo acesso: modelo II

- No m -ésimo elemento do arranjo o sinal é dado por

$$x_m(t) = \sum_{k=1}^K \sqrt{P_k} a_k(t - \tau_k) \cdot \alpha_{k,m} \cdot f_m(\theta_k) + v(t),$$

em que P_k é a potência transmitida do k -ésimo usuário e $v(t)$ é uma v.a. de um processo estocástico gaussiano

- Considerando
 - 1 τ_k múltiplos do período de símbolo (T)
 - 2 perfeito sincronismo

$$\mathbf{x}(n) = \sum_{k=1}^K \sqrt{P_k} a_k(n) \cdot \alpha_{k,m} \cdot \mathbf{f}(\theta_k) + \mathbf{v}(n)$$

- Utilizando notação matricial

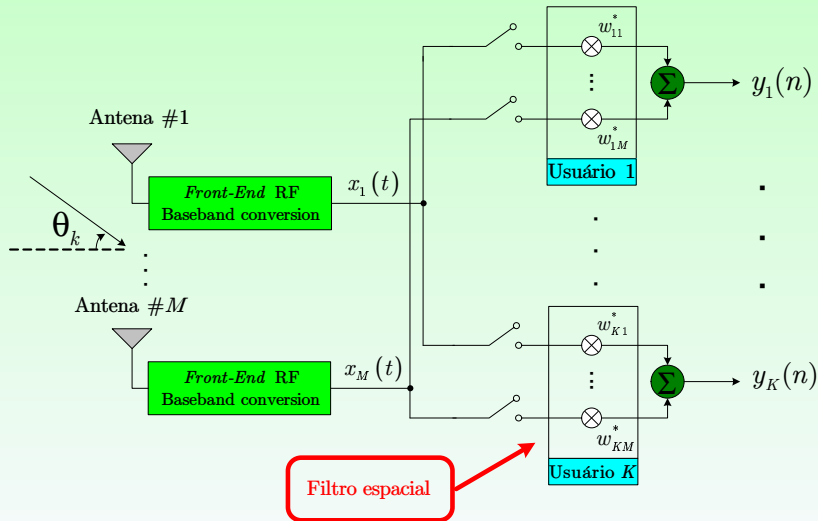
$$\mathbf{x}(n) = \mathbf{F}\mathbf{a}(n) + \mathbf{v}(n),$$

em que

$$\mathbf{x}(n) = \begin{bmatrix} x_1(n) \\ \vdots \\ x_M(n) \end{bmatrix}, \quad \mathbf{F} = [\mathbf{f}(\theta_1) \mid \cdots \mid \mathbf{f}(\theta_K)]_{M \times K} \quad \text{e}$$

$$\mathbf{a}(n) = \begin{bmatrix} a_1(n) \\ \vdots \\ a_K(n) \end{bmatrix}$$

Esquema de processamento espacial com arranjos de antenas



- Saída do k -ésimo filtro

$$y_k(n) = \mathbf{w}_k^H(n)\mathbf{x}(n),$$

- Na forma matricial

$$\mathbf{y}(n) = \mathbf{W}^H(n)\mathbf{x}(n),$$

em que

$$\mathbf{y}(n) = \begin{bmatrix} y_1(n) \\ \vdots \\ y_K(n) \end{bmatrix} \quad \text{e} \quad \mathbf{W} = \left[\mathbf{w}_1(n) \mid \cdots \mid \mathbf{w}_K(n) \right]_{M \times K}.$$

- Faixa do canal é da ordem da portadora
- $\tau_{k,i} \neq \tau_k$
- Vetor de resposta impulsica do usuário k para o elemento m é

$$\mathbf{h}_{m,k}(t) = \sum_{i=0}^{L_k-1} \mathbf{f}(\theta_{k,i}) \cdot \alpha_{k,i} \cdot \delta(t - \tau_{k,i})$$

Interferências de múltiplo acesso e inter-simbólica: modelo II

- Representação do sinal recebido

$$\begin{aligned}\mathbf{x}(t) &= \sum_{k=1}^K a_k(t) \star \mathbf{h}_k(t) + \mathbf{v}(t) \\ &= \sum_{k=1}^K \sum_{i=0}^{L_k-1} \mathbf{f}(\theta_{k,i}) \cdot \alpha_{k,i} \cdot a_k(t - \tau_k) + \mathbf{v}(t),\end{aligned}$$

- Modelo discreto

$$\mathbf{x}(n) = \sum_{k=1}^K \sum_{i=0}^{L_k-1} h_k(i) \cdot a_k(n - i) \cdot \mathbf{f}(\theta_{k,i}) + \mathbf{v}(n),$$

em que $h_k(i)$ representa o i -ésimo coeficiente da resposta impulsiva do canal do k -ésimo usuário, representando $\alpha_{k,i}$

- Matriz do canal do k -ésimo usuário é

$$\mathbf{H}_k = \mathbf{F}(\theta_k) \cdot \boldsymbol{\alpha}_k,$$

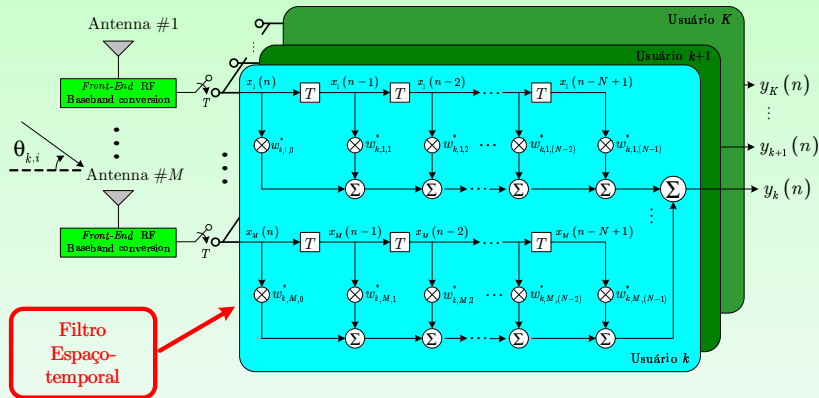
em que

$$\mathbf{F}(\theta_k) = \left[\mathbf{f}(\theta_{k,0}) \mid \mathbf{f}(\theta_{k,1}) \mid \cdots \mid \mathbf{f}(\theta_{k,L_k-1}) \right]_{M \times L}$$

e

$$\boldsymbol{\alpha}_k = \text{diag} \left(\left[h_k(0) \quad h_k(1) \quad \cdots \quad h_k(L_k - 1) \right] \right)$$

Estrutura de processamento espaço-temporal



Representação de sinais I

- Representação **tensorial**
- Notação mais compacta

$$\mathcal{X}(n) = \sum_{k=1}^K \mathcal{H}_k \mathcal{A}_k(n) + \mathcal{V}(n)$$

em que

$$\mathcal{X}(n) = \begin{bmatrix} \mathbf{x}(n) \\ \vdots \\ \mathbf{x}(n - N + 1) \end{bmatrix}_{MN \times 1} \quad \mathbf{x}(n) = \begin{bmatrix} x_1(n) \\ \vdots \\ x_M(n) \end{bmatrix},$$

$$\mathcal{A}_k(n) = \begin{bmatrix} a_k(n) \\ \vdots \\ a_k(n - L_k - N + 2) \end{bmatrix}_{(L_k + N - 1) \times 1} \quad \mathcal{V}(n) = \begin{bmatrix} \mathbf{v}(n) \\ \vdots \\ \mathbf{v}(n - N + 1) \end{bmatrix}_{MN \times 1}$$

Matriz de convolução espaço-temporal

$$\mathcal{H}_k = \begin{bmatrix} \mathbf{H}_k(n) & & & \mathbf{0}_{M \times (N-1)} \\ \mathbf{0}_{M \times 1} & \mathbf{H}_k(n-1) & & \mathbf{0}_{M \times (N-2)} \\ \mathbf{0}_{M \times 1} & \mathbf{0}_{M \times 1} & \mathbf{H}_k(n-2) & \mathbf{0}_{M \times (N-3)} \\ \vdots & \dots & & \ddots \\ & \mathbf{0}_{M \times (N-1)} & & \mathbf{H}_k(n-N+1) \end{bmatrix}_{MN \times (N+L-1)},$$

em que $\mathbf{0}_{k \times l}$ é uma matriz de dimensão $k \times l$ de zeros

Matriz de convolução espaço-temporal: exemplo

- $M = 4$, $L = 3$ and $N = 3$

$$\mathcal{H}_k = \begin{bmatrix} h_{k,1,0}(n) & h_{k,1,1}(n) & h_{k,1,2}(n) & 0 & 0 \\ h_{k,2,0}(n) & h_{k,2,1}(n) & h_{k,2,2}(n) & 0 & 0 \\ h_{k,3,0}(n) & h_{k,3,1}(n) & h_{k,3,2}(n) & 0 & 0 \\ h_{k,4,0}(n) & h_{k,4,1}(n) & h_{k,4,2}(n) & 0 & 0 \\ 0 & h_{k,1,0}(n-1) & h_{k,1,1}(n-1) & h_{k,1,2}(n-1) & 0 \\ 0 & h_{k,2,0}(n-1) & h_{k,2,1}(n-1) & h_{k,2,2}(n-1) & 0 \\ 0 & h_{k,3,0}(n-1) & h_{k,3,1}(n-1) & h_{k,3,2}(n-1) & 0 \\ 0 & h_{k,4,0}(n-1) & h_{k,4,1}(n-1) & h_{k,4,2}(n-1) & 0 \\ 0 & 0 & h_{k,1,0}(n-2) & h_{k,1,1}(n-2) & h_{k,1,2}(n-2) \\ 0 & 0 & h_{k,2,0}(n-2) & h_{k,2,1}(n-2) & h_{k,2,2}(n-2) \\ 0 & 0 & h_{k,3,0}(n-2) & h_{k,3,1}(n-2) & h_{k,3,2}(n-2) \\ 0 & 0 & h_{k,4,0}(n-2) & h_{k,4,1}(n-2) & h_{k,4,2}(n-2) \end{bmatrix} \quad 12 \times 5$$

Modelo do sinal do receptor

$$y_k(n) = \mathcal{W}_k^H(n) \mathcal{X}(n),$$

em que

$$\mathcal{W}_k = \begin{bmatrix} \mathbf{w}_{k0} \\ \mathbf{w}_{k1} \\ \vdots \\ \mathbf{w}_{k(N-1)} \end{bmatrix}_{MN \times 1}, \quad \mathbf{w}_{k\hat{n}} = \begin{bmatrix} w_{k,1,\hat{n}} \\ w_{k,2,\hat{n}} \\ \vdots \\ w_{k,M,\hat{n}} \end{bmatrix}_{M \times 1}$$

Sinal desejado não disponível: métodos através de HOS

- Sinal desejado é aproximado por alguma medida estatística
- Complexidade de estimação de momentos de ordem superior
- Análise mais elaborada e difícil
- Diferentes abordagens
 - 1 Critério **Constant modulus** (CM) ou de Godard
 - 2 **Directed-decision** (DD)
 - 3 Critério de **Sato**
 - 4 Critério de **Shalvi-Weinstein**
 - 5 Algoritmo de **Benveniste-Goursat**
 - 6 Critérios baseados em **teoria da informação**

Estratégias de processamento multi-usuário cegas

- Estratégias lineares baseadas em técnicas do domínio temporal podem ser aplicadas
- Critérios adicionais são utilizados para recuperação de todas as fontes
- Caso contrário: a recuperação das fontes pode ser errônea devido ao efeito “near-far” ou desbalanceamento de potência

Multuser Constant Modulus Algorithm (MU-CMA)

- Penaliza sinais fora de um raio de módulo constante:

$$J_{\text{CMA}}(\mathbf{w}_k) = \mathbb{E} \left\{ \left(|y(n)|^2 - \rho_2 \right)^2 \right\}, \text{ em que } \rho_2 = \frac{\mathbb{E} \{ a_k^4(n) \}}{\mathbb{E} \{ a_k^2(n) \}}$$

- Critério adicional: descorrelação explícita

$$J_{\text{MU-CMA}}(\mathbf{w}_k) = J_{\text{CMA}}(\mathbf{w}_k) + \gamma \sum_{i=1}^K \sum_{\substack{j=1 \\ j \neq i}}^K |r_{ij}|^2$$

$r_{ij} = \mathbb{E} \left\{ y_i(n) y_j^*(n) \right\}$ e γ é um fator de regularização

$$\mathbf{w}_k(n+1) = \mathbf{w}_k(n) + \mu \cdot \left(1 - |y(n)|^2\right) \cdot y_k^* \cdot \mathbf{x}(n) - \gamma \sum_{\substack{i=1 \\ i \neq k}}^K \hat{r}_{ik}(n) \hat{\mathbf{p}}_i(n)$$

$\hat{r}_{ik}(n)$ é o (i, k) -ésimo elemento de $\hat{\mathbf{R}}_y(n)$ e $\hat{\mathbf{p}}_i(n)$ é a i -ésima coluna de $\hat{\mathbf{P}}(n)$.

$$\begin{aligned}\hat{\mathbf{R}}_y(n+1) &= \varsigma \hat{\mathbf{R}}_y(n) + (1 - \varsigma) \mathbf{y}(n) \mathbf{y}^H(n) \\ \hat{\mathbf{P}}(n+1) &= \varsigma \hat{\mathbf{P}}(n) + (1 - \varsigma) \mathbf{x}(n) \mathbf{y}^H(n),\end{aligned}$$

MU-CMA: adaptação (caso espaço-temporal)

$$\mathcal{W}_k(n+1) = \mathcal{W}_k(n) + \mu \cdot (1 - |y_k(n)|^2) \cdot y(n)_k^* \cdot \mathcal{X}(n) - \gamma \sum_{\substack{i=1 \\ i \neq k}}^K \sum_{\ell=-\frac{\Delta}{2}}^{\frac{\Delta}{2}} \hat{r}_{ik,\ell}(n) \hat{\mathbf{p}}_{i,\ell}(n)$$

em que

$$\mathbf{R}_{y,\ell}(n+1) = \varsigma \mathbf{R}_{y,\ell}(n) + (1 - \varsigma) \mathbf{y}(n) \mathbf{y}^H(n - \ell)$$

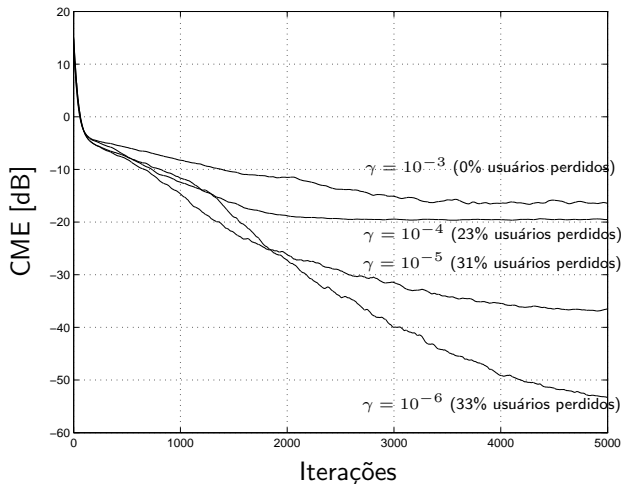
$$\mathbf{P}_\ell(n+1) = \varsigma \mathbf{P}_\ell(n) + (1 - \varsigma) \mathcal{X}(n) \mathbf{y}^H(n - \ell)$$

$$\mathbf{y}(n - \ell) = \begin{bmatrix} y_1(n - \ell) & \cdots & y_K(n - \ell) \end{bmatrix}^T$$

$$\ell = -\frac{\Delta}{2}, \dots, \frac{\Delta}{2}$$

- 1 Robustez e simplicidade
- 2 Funciona mesmo para sinais que não apresentam módulo constante
- 3 Convergência lenta
- 4 Problema de inicialização
- 5 Compromisso entre termo de regularização e desempenho em regime

Desempenho: usuários perdidos \times erro do módulo constante (CME)



Fast Multiuser Constant Modulus (FMU-CMA)

Metas

- Melhorar a taxa de convergência por meio de um procedimento recursivo e um algoritmo tipo DMI utilizando o critério do módulo constante para cálculo de \mathbf{R}_{yy} e \mathbf{p}_y
- Melhorar o desempenho de erro em regime sem perda de usuários utilizando um termo de regularização adaptativo que mede a correlação dos sinais de saída dos filtros e penaliza-os quando esta é alta

$$\mathbf{w}_k(n) = \mathbf{R}_{xy,k}^{-1}(n) \mathbf{d}_{xy,k}(n)$$

$$\mathbf{R}_{xy,k}(n+1) = \zeta \mathbf{R}_{xy,k}(n) + (1 - \zeta) |y_k(n)|^2 \mathbf{x}(n) \mathbf{x}^H(n)$$

$$\mathbf{d}_{xy,k}(k+1) = \zeta \mathbf{d}_{xy,k}(n) + (1 - \zeta) \cdot \rho_2 \cdot y_k^*(n) \mathbf{x}(n) - \gamma(n) \sum_{\substack{i=1 \\ i \neq k}}^K \hat{r}_{ik}(n) \hat{\mathbf{p}}_i(n)$$

$$\hat{\mathbf{R}}_y(n+1) = \varsigma \hat{\mathbf{R}}_y(n) + (1 - \varsigma) \mathbf{y}(n) \mathbf{y}^H(n)$$

$$\hat{\mathbf{P}}(n+1) = \varsigma \hat{\mathbf{P}}(n) + (1 - \varsigma) \mathbf{x}(n) \mathbf{y}^H(n),$$

$$\bar{r}_k(n) = \frac{1}{K-1} \sum_{\substack{i=1 \\ i \neq k}}^K |\hat{r}_{ik}(n)|^2$$

$$\gamma_k(n) = \tanh[\bar{r}_k(n)]$$

Propriedades

- Maior taxa de convergência
- Menor erro em regime sem perda de usuários
- Maior complexidade computacional (inversão de matrizes)

Multiuser Kurtosis (MUK) Criterion

- Baseado na generalização das condições para recuperação cega de sinais
- Generalização do teorema de Shalvi-Weinstein
 - 1 $a_l(n)$ é i.i.d. e de média nula ($l = 1, \dots, K$);
 - 2 $a_l(n)$ e $a_q(n)$ são estatisticamente independentes para $l \neq q$ e têm a mesma fdp;
 - 3 $|\mathcal{K}[y_l(n)]| = |\mathcal{K}_a| \quad (l = 1, \dots, K)$;
 - 4 $\mathbb{E} \left\{ |y_l(n)|^2 \right\} = \sigma_a^2 \quad (l = 1, \dots, K)$;
 - 5 $\mathbb{E} \left\{ y_l(n)y_q^*(n) \right\} = 0, \quad l \neq q,$

em que \mathcal{K}_a é a kurtosis dos sinais transmitidos e $\mathcal{K}[\cdot]$ é o operador de kurtosis

- Maximizar a kurtosis da saída e igualar as potências da entrada e saída: remoção da interferência
- Necessidade de diferentes (descorrelação) fontes
- Evitar termo de regularização
- Alternativa: forçar a resposta global (canal combinado + filtros de separação) a ser uma matriz identidade
- **Problema com restrições!**

$$\left\{ \begin{array}{l} \max_{\mathbf{G}} J_{\text{MUK}}(\mathbf{G}) = \sum_{k=1}^K |\mathcal{K}[y_k]| \\ \text{subject to : } \mathbf{G}^H \mathbf{G} = \mathbf{I} \end{array} \right.$$

Etapas

- 1 Remoção da interferência: \mathbf{W}^e

$$\nabla J_{\text{MUK}}(\mathbf{G}) = 4 \cdot \text{sign}(\mathcal{K}_a) \cdot \sum_{k=1}^K \mathbb{E} \left\{ |y_k(n)|^2 \cdot y_k(n) \cdot \mathbf{y}^*(n) \right\}$$

- 2 Ortogonalização: \mathbf{W}

$$\mathbf{w}_k(n+1) = \frac{\mathbf{w}_k^e(n+1) - \sum_{l=1}^{k-1} [\mathbf{w}_l^H(n+1) \mathbf{w}_k^e(n+1)] \mathbf{w}_l(n+1)}{\left\| \mathbf{w}_k^e(n+1) - \sum_{l=1}^{k-1} [\mathbf{w}_l^H(n+1) \mathbf{w}_k^e(n+1)] \mathbf{w}_l(n+1) \right\|}$$

Propriedades

- Ortogonalização de Gram-Schmidt
- Descarta termo de regularização
- Baixa complexidade (entretanto deve ter dados esferatizados para garantir separação!)
- Baixa taxa de convergência

Observação sobre as estratégias de BSS para processamento multi-usuário

Questão

Há um método cego com as desejáveis características de alta velocidade de convergência, erro em regime baixo e computacionalmente simples?

Proposta: aspectos gerais

- Proposição inicial para sistemas SISO (equalização mono-usuário)
- Caracterização da função de densidade de probabilidade (fdp) da saída do *equalizador ideal*
- Estimação paramétrica
- Critério: estimação/entropia
 - Divergência de Kullback-Leibler (KLD)
 - Função contraste

Sinal na saída do equalizador ideal

$$\begin{aligned}y(n) &= (\mathcal{H}^H \mathbf{a}(n) + \mathbf{v}(n))^H \mathbf{w}_{\text{ideal}} \\&= \mathbf{a}^H(n) \mathcal{H} \mathbf{w}_{\text{ideal}} + \mathbf{v}^H(n) \mathbf{w}_{\text{ideal}} \\&= \mathbf{a}^T(n) \underbrace{\mathcal{H} \mathbf{w}_{\text{ideal}}}_{\mathbf{g}^{\text{ideal}}} + \mathbf{v}^H(n) \mathbf{w}_{\text{ideal}} \\&= \mathbf{a}^H(n) \mathbf{g}^{\text{ideal}} + \vartheta(n) \\&= a(n - \ell) + \vartheta(n),\end{aligned}$$

fdp de $y(n)$

$$p_Y(y) = \frac{1}{\sqrt{2\pi\sigma_\vartheta^2}} \sum_{i=1}^{\mathfrak{C}} \exp\left(-\frac{|y(n) - \mathbf{a}_i|^2}{2\sigma_\vartheta^2}\right) \Pr(\mathbf{a}_i),$$

Minimizar a divergência

Modelo paramétrico

$$\Phi(y) = \underbrace{\frac{1}{\sqrt{2\pi\sigma_r^2}}}_A \cdot \frac{1}{e} \cdot \sum_{i=1}^e \exp\left(-\frac{|y(n) - \mathbf{a}_i|^2}{2\sigma_r^2}\right), \quad (1)$$

Como medir a similaridade?

Divergência de Kullback-Leibler (KLD)

$$D(p_Y(y) || \Phi(y)) = \int_{-\infty}^{\infty} p_Y(y) \cdot \ln \left[\frac{p_Y(y)}{\Phi(y)} \right] dy$$

Fitting pdf Criterion

Termo da KLD dependente de $\Phi(y)$

$$\begin{aligned} J_{\text{FP}}(\mathbf{w}) &= \int_{-\infty}^{\infty} p_Y(y) \cdot \ln \left(\frac{1}{\Phi(y)} \right) dy \\ &= -\mathbb{E} \{ \ln [\Phi(y)] \} \\ &= -\mathbb{E} \left\{ \ln \left[A \cdot \sum_{i=1}^c \exp \left(-\frac{|y - \mathbf{a}_i|^2}{2\sigma_r^2} \right) \right] \right\} \end{aligned}$$

Fitting pdf Algorithm

$$\nabla J_{\text{FPC}}(\mathbf{w}) = \frac{\sum_{i=1}^{\mathfrak{c}} \exp\left(-\frac{|y(n)-\mathbf{a}_i|^2}{2\sigma_r^2}\right) [y(n) - \mathbf{a}_i^*]}{\sigma_r^2 \cdot \sum_{i=1}^{\mathfrak{c}} \exp\left(-\frac{|y(n)-\mathbf{a}_i|^2}{2\sigma_r^2}\right)} \mathbf{x}(n),$$

$$\mathbf{w}(n+1) = \mathbf{w}(n) - \mu \nabla J_{\text{FPC}}(\mathbf{w}).$$

- Solução do FPA quando se dispõe dos dados coincide com a solução MMSE
- Pode ser visto como um caso generalizado dos critérios CM e de Sato
- Equivalência do comportamento da função custo com algoritmo de decisão dirigida
- Relação importante com critério de minimização da probabilidade de erro (SBT2004)

FP \times MAP

$$J_{\text{MAP}} = J_{\text{FPC}} - J_{\text{MMSE}}$$

- Critério adicional para penalizar a adaptação quando há réplicas do mesmo sinal

Critério MU-FPC

$$J_{\text{MU-FPC}}(\mathbf{w}_k) = J_{\text{FPC}}(\mathbf{w}_k) + \gamma \sum_{i=1}^K \sum_{\substack{j=1 \\ j \neq i}}^K |r_{ij}|^2$$

Algoritmo - Processamento espacial

$$\begin{aligned}\mathbf{R}_{yy}(n+1) &= \xi \mathbf{R}_{yy}(n) + (1 - \xi) \mathbf{y}(n) \mathbf{y}^H(n) \\ \mathbf{P}(n+1) &= \xi \mathbf{P}(n) + (1 - \xi) \mathbf{x}(n) \mathbf{y}^H(n),\end{aligned}$$

$$\nabla J_{\text{FPC}}(\mathbf{w}) = \frac{\sum_{i=1}^{\mathfrak{c}} \exp\left(-\frac{|y(n) - \mathbf{a}_i|^2}{2\sigma_r^2}\right) [y(n) - \mathbf{a}_i^*]}{\sigma_r^2 \cdot \sum_{i=1}^{\mathfrak{c}} \exp\left(-\frac{|y(n) - \mathbf{a}_i|^2}{2\sigma_r^2}\right)} \mathbf{x}(n)$$

$$\mathbf{w}_k(n+1) = \mathbf{w}_k(n) - \mu \nabla J_{\text{FPC}}(\mathbf{w}_k) - \gamma \sum_{\substack{i=1 \\ i \neq k}}^K \hat{r}_{ik}(n) \mathbf{p}_i(n)$$

Processamento espaço-temporal

$$J_{\text{MU-FPC}}(\mathcal{W}_k) = J_{\text{FPC}}(\mathcal{W}_k) + \gamma \sum_{i=1}^K \sum_{\substack{j=1 \\ j \neq i}}^K \sum_{\ell=-\frac{\Delta}{2}}^{\frac{\Delta}{2}} |r_{ij}(\ell)|^2$$

$$\mathcal{W}_k(n+1) = \mathcal{W}_k(n) - \mu \nabla J_{\text{FPC}}(\mathcal{W}_k) - \gamma \sum_{\substack{i=1 \\ i \neq k}}^K \sum_{\ell=-\frac{\Delta}{2}}^{\frac{\Delta}{2}} \hat{r}_{ik,\ell}(n) \hat{\mathbf{p}}_{i,\ell}(n)$$

$$\begin{aligned} \mathbf{R}_{y,\ell}(n+1) &= \xi \mathbf{R}_{y,\ell}(n) + (1-\xi) \mathbf{y}(n) \mathbf{y}^H(n-\ell) \\ \mathbf{P}_\ell(n+1) &= \xi \mathbf{P}_\ell(n) + (1-\xi) \mathcal{X}(n) \mathbf{y}^H(n-\ell) \\ \mathbf{y}(n-\ell) &= [y_1(n-\ell) \quad \dots \quad y_K(n-\ell)]^T \\ \ell &= -\frac{\Delta}{2}, \dots, \frac{\Delta}{2} \end{aligned}$$

- Recuperação da fase do sinal transmitido
- Baixa complexidade: algoritmo tipo LMS
- Grau de liberdade: σ_r^2
- Limitações:
 - Dependência com o fator γ
 - *Trade-off* – erro em regime \times usuários perdidos

Condições - Teorema de Shalvi-Weinstein

- C1.** $a_l(n)$ é i.i.d. e de média zero ($l = 1, \dots, K$);
- C2.** $a_l(n)$ e $a_q(n)$ são estatisticamente independentes para $l \neq q$ e têm a mesma fdp;
- C3.** $|\mathcal{K}[y_l(n)]| = |\mathcal{K}_a| \quad (l = 1, \dots, K)$;
- C4.** $\mathbb{E} \left\{ |y_l(n)|^2 \right\} = \sigma_a^2 \quad (l = 1, \dots, K)$;
- C5.** $\mathbb{E} \left\{ y_l(n) y_q^*(n) \right\} = 0, \quad l \neq q .$

- Condições necessárias para recuperação
- Maximização da *kurtosis* – MUK
- Garantia da obtenção de solução
 - Ortogonalização da matriz de resposta global

Critério MU-CFP

$$\left\{ \begin{array}{l} \min_{\mathbf{W}} J_{\text{FP}}(\mathbf{W}) = \sum_{i=1}^K D(p_Y(y_i) \parallel \Phi(y_i)) \\ \text{sujeito a: } \mathbf{G}^H \mathbf{G} = \mathbf{I} \end{array} \right.$$

MU-CFPA

$$\mathbf{w}_k^e(n+1) = \mathbf{w}_k(n) - \mu \left(\frac{\sum_{i=1}^c \exp\left(-\frac{|y_k(n) - \mathbf{a}_i|^2}{2\sigma_r^2}\right) [y_k(n) - \mathbf{a}_i^*]}{\sigma_r^2 \cdot \sum_{i=1}^c \exp\left(-\frac{|y_k(n) - \mathbf{a}_i|^2}{2\sigma_r^2}\right)} \mathbf{x}(n) \right)$$

$$\mathbf{w}_1(n+1) = \frac{\mathbf{w}_1^e(n+1)}{\|\mathbf{w}_1^e(n+1)\|}$$

$$\mathbf{w}_k(n+1) = \frac{\mathbf{w}_k^e(n+1) - \sum_{l=1}^{k-1} [\mathbf{w}_l^H(n+1) \mathbf{w}_k^e(n+1)] \mathbf{w}_l(n+1)}{\left\| \mathbf{w}_k^e(n+1) - \sum_{l=1}^{k-1} [\mathbf{w}_l^H(n+1) \mathbf{w}_k^e(n+1)] \mathbf{w}_l(n+1) \right\|},$$

Critérios com restrição: comparação

- Comparar desempenho de dois algoritmos com a mesma estrutura
- Diferença: número de estatísticas de ordem superior (HOS) consideradas

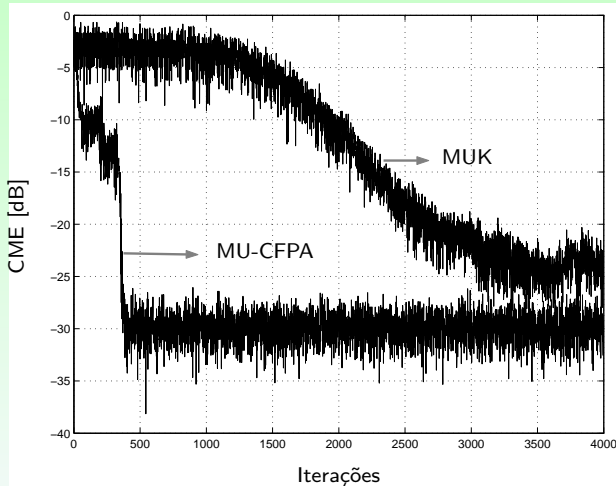
MUK

$$\begin{cases} \max_{\mathbf{G}} J_{\text{MUK}}(\mathbf{G}) = \sum_{k=1}^K |\mathcal{K}[y_k]| \\ \text{sujeito a : } \mathbf{G}^H \mathbf{G} = \mathbf{I} \end{cases}$$

MU-CFPA

$$\begin{cases} \min_{\mathbf{W}} J_{\text{FP}}(\mathbf{W}) = \sum_{i=1}^K D(p(y_i) \parallel \Phi(y_i)) \\ \text{sujeito a : } \mathbf{G}^H \mathbf{G} = \mathbf{I} \end{cases}$$

MUK \times MU-CFPA



Quais HOS são importantes para BSS?

Pelo menos uma. (Teoremas BGR e SW)

Há algum ganho em usar-se mais?

Sim, em versões adaptativas!

Como verificar?

Estimação da fdp do sinal desejado – Critério “universal” de BSS.

- Aproximação da fdp em séries ortonormais
- Expansões em torno de distribuições conhecidas
- Coeficientes da série dados pelas estatísticas do sinal

Aproximação em série

$$p_Y(y) = p_0(y) \sum_{k=1}^{\infty} C_k \cdot \mathbf{b}_k(y)$$

Coefficientes - cumulantes

$$C_1 = 0$$

$$C_2 = 0$$

$$C_3 = \frac{c_3}{6}$$

$$C_4 = \frac{c_4}{24}$$

$$C_5 = \frac{c_5}{120}$$

$$C_6 = \frac{1}{720} (c_6 + 10c_3^2)$$

$$C_7 = \frac{1}{5040} (c_7 + 35c_4c_3)$$

$$C_8 = \frac{1}{40320} (c_8 + 56c_5c_3 + 35c_4^2)$$

Coefficientes - momentos

$$C_1 = \kappa_1$$

$$C_2 = \frac{1}{2} (\kappa_2 - 1)$$

$$C_3 = \frac{1}{6} (\kappa_3 - 3\kappa_2)$$

$$C_4 = \frac{1}{24} (\kappa_4 - 6\kappa_2 + 3)$$

$$C_5 = \frac{1}{120} (\kappa_5 - 10\kappa_3 + 15\kappa_1)$$

$$C_6 = \frac{1}{720} (\kappa_6 - 15\kappa_4 + 45\kappa_2 - 15)$$

$$C_7 = \frac{1}{5040} (\kappa_7 - 21\kappa_5 + 105\kappa_3 - 105\kappa_1)$$

$$C_8 = \frac{1}{40320} (\kappa_8 - 28\kappa_6 + 210\kappa_4 - 420\kappa_2 + 105)$$

Densidade de referência

$$p_0(y) = p_G(y) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{y^2}{2}\right)$$

Base ortonormal – Polinômios de Hermite

$$h_k(y) = (-1)^k \cdot \frac{1}{p_0(y)} \cdot \frac{d^k p_0(y)}{dy^k},$$

Gram-Charlier

$$p_Y(y) = p_G(y) \left(1 + \sum_{k=3}^{\infty} C_k \cdot h_k(y) \right)$$

- Basicamente consiste na aproximação de Gram-Charlier ordenada em ordem decrescente dos coeficientes da série

$$p_y(\mathbf{y}) = p_G(\mathbf{y}) \left[1 + \frac{1}{3!} c_3(\mathbf{y}) \mathfrak{h}_3(\mathbf{y}) + \frac{1}{4!} c_4(\mathbf{y}) \mathfrak{h}_4(\mathbf{y}) + \frac{10}{6!} c_3^2(\mathbf{y}) \mathfrak{h}_6(\mathbf{y}) + \frac{1}{5!} c_5(\mathbf{y}) \mathfrak{h}_5(\mathbf{y}) + \frac{35}{7!} c_3(\mathbf{y}) c_4(\mathbf{y}) \mathfrak{h}_7(\mathbf{y}) + \dots \right]$$

Expansões existentes - Gram-Charlier e Edgeworth

- Não aproximam todos os tipos de fpds
- Somente aquelas que são “próximas” de uma forma gaussiana (concentradas em torno da média)
- Sinais de comunicação digital não são contemplados
- Necessidade de uma expansão que permita avaliar sinais de modulações digitais

Expansão em torno de misturas gaussianas

- Necessidade de expansão em torno de distribuições típicas em comunicações digitais
- Somatório de gaussianas (estimador de Parzen)

Distribuição de referência

$$p_{SG}(y) = \frac{1}{\mathfrak{C}} \sum_{i=1}^{\mathfrak{C}} \frac{1}{\sqrt{2\pi\sigma_{\vartheta}^2}} \exp \left[-\frac{(y - \mathbf{a}_i)^2}{2\sigma_{\vartheta}^2} \right],$$

Recursão da base ortonormal

$$\mathbf{c}_{k+1}(y) = \mathfrak{C} \cdot y \cdot \mathbf{c}_k(y) - k\mathbf{c}_{k-1}(y),$$

$$c_0(y) = 1$$

$$c_1(y) = \mathfrak{e} \cdot y$$

$$c_2(y) = (\mathfrak{e} \cdot y)^2 - 1$$

$$c_3(y) = (\mathfrak{e} \cdot y)^3 - 3(\mathfrak{e} \cdot y)$$

$$c_4(y) = (\mathfrak{e} \cdot y)^4 - 6((\mathfrak{e} \cdot y)^2) + 3$$

$$c_5(y) = (\mathfrak{e} \cdot y)^5 - 10(\mathfrak{e} \cdot y)^3 + 15(\mathfrak{e} \cdot y)$$

$$c_6(y) = (\mathfrak{e} \cdot y)^6 - 15(\mathfrak{e} \cdot y)^4 + 45(\mathfrak{e} \cdot y)^2 - 15$$





$$c_7(y) = (\mathfrak{e} \cdot y)^7 - 21(\mathfrak{e} \cdot y)^5 + 105(\mathfrak{e} \cdot y)^3 - 105(\mathfrak{e} \cdot y)$$

$$c_8(y) = (\mathfrak{e} \cdot y)^8 - 28(\mathfrak{e} \cdot y)^6 + 210(\mathfrak{e} \cdot y)^4 - 420(\mathfrak{e} \cdot y)^2 + 105$$





Destaques

- Estimativa da fdp a partir dos dados disponíveis
- HOS envolvidas no critério compõem a expansão da fdp
- Dependência dos cumulantes (momentos) e da base ortonormal
- Mais HOS aproveitam a “amplificação” fornecida pela base ortonormal
- Maior convergência

Dinâmica da estimativa da fdp - Algoritmo MUK



Dinâmica da estimativa da fdp - Algoritmo MU-CFPA



- Possibilidade de análise da importância das HOS na dinâmica de algoritmos de recuperação cega de sinais
- Nova expansão da densidade de probabilidade permite aproximar densidades de sinais típicos em sistemas de comunicação digital
- Possibilidade de avaliar compromisso velocidade-desempenho em algoritmos baseados em HOS

Part III

Casos particulares

Características

- Redução do número de fontes/sensores: $K = M = 1$
- Canal dispersivo: multipercursos (amplitude e fase)
- Filtros para correção dos efeitos do canal
- Diversidade temporal no receptor
- Medidas estatísticas para estimativa do sinal desejado

Critérios

- Teorema de Benveniste-Goursat-Rouget: igualar as fdps é necessário para equalização cega
- Teorema de Shalvi-Weinstein: igualar dois momentos estatísticos (potência e o de quarta ordem)
- Técnicas de Bussgang
 - *Decision-directed*
 - Sato
 - *Constant modulus* ou Godard
 - Benveniste-Goursat
 - *Stop-and-Go*
- Técnicas baseadas em teoria da informação

Algumas equivalências “conhecidas”

- 1 Shalvi-Weinstein e *Constant Modulus*
- 2 *Constant Modulus* e solução de Wiener
- 3 *Fitting PDF* → Wiener, Sato, CMA

Equivalências com critérios de BSS

- *FastICA* e Algoritmo super-exponencial
- *InfoMax/MaxEnt* e Benveniste-Goursat-Rouget (BGR)
- Funções de Contraste e Shalvi-Weinstein

- Maximizar a informação mútua entre a entrada e saída de um sistema de separação
- BGR: igualar a densidade de probabilidade da entrada e saída
- Informação mútua:

$$\begin{aligned} I(\mathbf{y}, \mathbf{x}) &= \mathcal{H}(\mathbf{y}) \\ &= \mathcal{H}(\mathbf{W}\mathbf{x}) \\ &= \mathcal{H}(\mathbf{W}\mathbf{H}\mathbf{a}) \end{aligned}$$

- Máximo da entropia/informação mútua ocorre quando $p_a(\mathbf{a}) = p_y(\mathbf{y})$

- *FastICA*

$$\mathbf{w}_i^\dagger(n+1) = \mathbb{E} \{ \mathbf{x} f(\mathbf{w}_i^T(n)\mathbf{x}) \} - \mathbb{E} \{ f'(\mathbf{w}_i^T(n)\mathbf{x}) \} \mathbf{w}_i(n)$$

$$\mathbf{w}_i(n+1) = \frac{\mathbf{w}_i^\dagger(n+1)}{\left\| \mathbf{w}_i^\dagger(n+1) \right\|}$$

- Escolhendo fator de passo $\mu(n) = \frac{1}{\beta(n)}$

$$\mathbf{w}_i^\dagger(n+1) = \mathbb{E} \{ \mathbf{x} f(\mathbf{w}_i^T(n)\mathbf{x}) \}$$

$$\mathbf{w}_i(n+1) = \frac{\mathbf{w}_i^\dagger(n+1)}{\left\| \mathbf{w}_i^\dagger(n+1) \right\|}$$

- Sendo $F(y) = y^{2p}$, e daí $f(y) = 2py^{2p-1}$: **SEA!**

Equivalência função de contraste e SW

- SW: estatísticas de ordem superior
- Função contraste: medida de não-gaussianidade sujeito a respeitar propriedades
- Função contraste pode ser definida como função da kurtosis e do momento de segunda ordem

Características

- Caso específico: $K = 1$ e M sensores
- Subcanais são gerados por diversidade (temporal ou espacial)
- Modelo análogo ao de BSS: simplificação pois todas as variáveis são do mesmo sinal
- Redução de complexidade

Critérios

- Cicloestacionaridade: construção de técnicas que usam tal fato
- Diversidade espacial: múltiplas cópias do sinal (modelos equivalentes)
- Técnicas de BSS se aplicam: $M \geq K$
- Possibilidade de mais técnicas adaptativas
- Subespaços (PCA), predição linear (função contraste)!

Part IV

Tendências e perspectivas

Separação de fontes

- Misturas convolutivas: maioria das técnicas derivada para misturas instantâneas
- Misturas não-lineares: maior generalização de problemas passíveis de serem abordados
- Novas estratégias: simples, rápidas e eficientes
- Independência em misturas não-lineares não é preservada: como fazer?
- Não-estacionariedade
- Assincronismo
- Problemas sub-determinados ($M \leq K$)
- álgebra multi-linear
- Geometria diferencial
- ...

Processamento multi-usuário




- Critério e algoritmos simples: aplicações em tempo real
- Misturas convolutivas necessitam de estratégias mais elaboradas
- Modelagem do sistema (canal, usuários e interferência) apresenta ganhos quando modelada com tensores
- Critérios com melhor relação de compromisso velocidade/desempenho podem ser derivados
- Assincronismo
- ...



Equalização cega mono e multi-canal





- Equalizar é encontrar amostras temporais independentes
- Novos critérios baseados em ICA
- Possibilidade de equalização cega com redes neurais
- Critérios mais elaborados
- Novas estratégias de aprendizado
- ...

Part V

Sugestões bibliográficas

-  A. Hyvärinen, E. Oja, and J. Karhunen, *Independent Component Analysis*. John Wiley & Sons, 2001.
-  A. Cichocki and S. ichi Amari, *Adaptive Blind Signal and Image Processing: Learning Algorithms and Applications*. John Wiley & Sons, 2002.
-  S. Haykin, Ed., *Unsupervised Adaptive Filtering*, ser. (Series on Adaptive and Learning Systems for Signal Processing, Communications and Control). John Wiley & Sons, 2000, vol. I: Source Separation.

-  S. Haykin, Ed., *Unsupervised Adaptive Filtering*, ser. (Series on Adaptive and Learning Systems for Signal Processing, Communications and Control). John Wiley & Sons, 2000, vol. II: Blind Deconvolution.
-  C. C. Cavalcante, “Sobre Separação Cega de Fontes: Proposições e Análise de Estratégias para Processamento Multi-Usuário,” Tese de Doutorado, Universidade Estadual de Campinas (UNICAMP) – DECOM, Campinas, SP - Brasil, Abril 2004.

-  A. Hyvärinen and E. Oja, “Independent Component Analysis: Algorithms and Applications,” *Neural Networks*, vol. 13, no. 4-5, pp. 411–430, 2000.
-  A. Hyvärinen, “Survey on Independent Component Analysis,” *Neural Computing Surveys*, vol. 2, pp. 94–128, 1999.
-  P. Comon, “Independent Component Analysis: A New Concept?” *Signal Processing*, vol. 36, no. 3, pp. 287–314, April 1994.
-  J.-F. Cardoso, “Blind Signal Separation: Statistical Principles,” *Proceedings of the IEEE*, vol. 86, no. 10, pp. 2009–2025, October 1998.