

Une nouvelle approche fréquentielle pour la séparation aveugle de signaux non-stationnaires et autocorrélés

Hicham SAYLANI^{1, 2}, Shahram HOSSEINI¹, Yannick DEVILLE¹, Mohamed HABIBI²

¹Laboratoire d'Astrophysique de Toulouse-Tarbes - UMR 5572
Université Paul Sabatier Toulouse 3 - CNRS
14 Av. Edouard Belin, 31400 Toulouse, France

²Laboratoire des Systèmes de Télécommunications et Ingénierie de la Décision,
Faculté des Sciences, Université Ibn Tofail, BP. 133, 14000 Kénitra, Maroc
hsaylani@ast.obs-mip.fr, shosseini@ast.obs-mip.fr, ydeville@ast.obs-mip.fr
mohamed.habibi@caramail.com

Résumé – Nous avons récemment développé une nouvelle méthode pour la séparation aveugle de sources non-stationnaires en mélanges linéaires instantanés, appelée méthode à *décorrélation spectrale*. Contrairement aux méthodes classiques exploitant la non-stationnarité des signaux sources, notre méthode ne nécessite pas la stationnarité par morceaux et traite les mélanges dans le domaine fréquentiel. Cependant, elle suppose que les signaux sources sont temporellement non-corrélés, ce qui n'est pas le cas de la plupart des signaux réels. C'est pourquoi nous proposons dans cet article une extension de cette approche également applicable au cas de signaux non-stationnaires autocorrélés. Les résultats de tests avec ce type de signaux (parole, musique, images) montrent que notre méthode conduit à de meilleures performances que les méthodes classiques de séparation de sources.

Abstract – We have recently developed a new method, called *spectral decorrelation*, for blindly separating linear instantaneous mixtures of non-stationary sources. Contrary to the classical methods exploiting non-stationarity, our method is a frequency-domain approach which does not require the piecewise stationarity of the signals. However, it supposes that the source signals are temporally uncorrelated, while many real-world signals do not satisfy this assumption. That is why we propose in this paper an extension of this approach which allows us to apply this method also to non-stationary autocorrelated signals. Tests using such signals (speech, music, images) show the better performance of our method with respect to some classical source separation methods.

1 Introduction

La Séparation Aveugle de Sources (SAS) consiste à estimer N signaux inconnus, notés $s_i(n)$ ($i = 1, \dots, N$)¹ et appelés sources, d'après la seule connaissance de M mélanges de ces signaux, notés $x_j(n)$ ($j = 1, \dots, M$) et appelés observations. Le terme aveugle signifie qu'aucune information n'est disponible a priori ni sur les sources ni sur les coefficients de mélange. Dans le cas où on a autant d'observations que de sources, et en absence de sources de bruit, le problème de SAS en Mélange Linéaire Instantané (MLI) peut être modélisé comme suit :

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

où $\mathbf{x}(n) = [x_1(n), x_2(n), \dots, x_N(n)]^T$ est le vecteur observation, $\mathbf{s}(n) = [s_1(n), s_2(n), \dots, s_N(n)]^T$ est le vecteur sources et \mathbf{A} la matrice de mélange supposée réelle et inversible. Le but de la SAS est de trouver une estimation de l'inverse de la matrice \mathbf{A} , appelée matrice de séparation, à une matrice de permutation et une matrice diagonale près [1]. Il est montré dans [2] que la SAS peut être réalisée en exploitant la non-gaussianité, l'autocorrélation ou la non-stationnarité des signaux, ce qui a donné lieu à de nombreux algorithmes [1, 3].

Plusieurs méthodes statistiques de SAS exploitent la non-stationnarité des sources [4]-[9]. Dans [4] et [5], la séparation de signaux non-stationnaires est réalisée en utilisant un réseau de neurones artificiels qui procède à l'annulation de l'intercorrélolation (sans décalage) des signaux de sortie à chaque instant. L'approche présentée dans [6] est basée sur la maximisation de la non-stationnarité mesurée par un cumulants croisés d'une combinaison linéaire des observations. Dans [7], les signaux observés sont divisés en deux sous-intervalles et la diagonalisation conjointe des matrices de covariance estimées sur ces deux sous-intervalles permet de séparer les sources. Deux autres méthodes semblables à cette dernière utilisent plusieurs matrices de covariance au lieu de deux [8, 9]. Dans [8], Pham et Cardoso modélisent les sources non-stationnaires par des séquences gaussiennes blanches et stationnaires par morceaux. Ils proposent une solution au sens du maximum de vraisemblance et montrent que l'optimisation du critère résultant peut être réalisée par diagonalisation conjointe, sans contrainte d'orthonormalité², d'un ensemble de matrices de covariance locales correspondant à différents intervalles adjacents des observations. Quant à la méthode

¹On considère ici des signaux à temps discret. Le formalisme de SAS est le même dans le cas des signaux à temps continu.

²Les auteurs montrent que dans le cas $M = N$, l'algorithme de diagonalisation conjointe de matrices carrées hermitiennes définies positives, proposé par Pham [10], permet d'estimer la matrice de séparation sans avoir recours à une orthonormalisation préalable.

SONS (*Second Order Nonstationary Source separation*) proposée dans [9] par Choi et al., elle exploite, en plus de la non-stationnarité des signaux sources, leur corrélation temporelle. De plus, contrairement à la méthode de Pham et Cardoso [8], la diagonalisation conjointe des matrices de covariance se fait après une orthonormalisation préalable (c-à-d après blanchiment des observations), comme pour l'algorithme *SOBI* (*Second Order Blind Identification*) [1]. Si les sources sont stationnaires, l'algorithme *SONS* se réduit à l'algorithme *SOBI*.

Toutes ces méthodes statistiques sont des méthodes *temporelles*³ pour lesquelles l'estimation des statistiques considérées exige que ces dernières ne changent pas dans chaque intervalle d'estimation. Cela nécessite donc *la stationnarité par morceaux* des sources non-stationnaires par rapport à la statistique considérée, hypothèse qui, malheureusement, n'est pas rigoureusement vérifiée pour la plupart des signaux réels.

Par opposition à ces méthodes *temporelles*, une méthode statistique dite *fréquentielle*⁴, appelée méthode à *décorrélacion spectrale*, a été récemment développée au sein de notre laboratoire [11, 12]. Cette méthode consiste à transformer les sources, en changeant ainsi leurs propriétés, afin de pouvoir les séparer dans le domaine fréquentiel. Elle peut être utilisée pour la séparation des MLI de signaux non-stationnaires, réels, mutuellement non-corrélés, gaussiens et non-gaussiens. Contrairement aux méthodes citées ci-dessus, elle ne nécessite pas *la stationnarité par morceaux* des signaux sources. Cependant, elle suppose que les signaux sources sont non-corrélés dans le temps. C'est pourquoi nous proposons dans cet article une extension de cette approche également applicable aux signaux non-stationnaires autocorrélés.

2 Décorrélacion spectrale

Supposons que l'on dispose de N MLI de N sources $s_i(n)$ ($i = 1, \dots, N$) non-stationnaires, réelles, centrées, non-corrélées dans le temps et mutuellement non-corrélées. En appliquant la transformation de Fourier à l'équation (1) on obtient :

$$\mathbf{X}(\omega) = \mathbf{A}\mathbf{S}(\omega), \quad (2)$$

où $\mathbf{S}(\omega) = [S_1(\omega), S_2(\omega), \dots, S_N(\omega)]^T$, $\mathbf{X}(\omega) = [X_1(\omega), X_2(\omega), \dots, X_N(\omega)]^T$; $S_i(\omega)$ et $X_i(\omega)$ ($i = 1, 2, \dots, N$) sont respectivement les transformées de Fourier de $s_i(n)$ et $x_i(n)$. Ainsi, les observations fréquentielles $X_i(\omega)$ sont des MLI des sources fréquentielles $S_i(\omega)$. On peut facilement montrer que ces nouvelles sources ($S_i(\omega)$) sont aussi mutuellement non-corrélées. La méthode à *décorrélacion spectrale* est basée sur le théorème suivant [12].

Théorème 1 : Si $s_i(n)$ est un signal réel, centré et non-corrélé dans le temps, avec une variance $\gamma_i(n)$, c-à-d

³Les critères et les algorithmes de séparation correspondants sont appliqués aux mélanges exprimés dans le domaine temporel.

⁴Les critères et les algorithmes de séparation correspondants sont appliqués aux mélanges exprimés dans le domaine fréquentiel.

$E[s_i(n_1)s_i(n_2)] = \gamma_i(n_1)\delta(n_1 - n_2)$ où $\delta(n)$ est l'impulsion unité, alors sa transformée de Fourier $S_i(\omega)$ est stationnaire au sens large, avec une autocorrélacion $\Gamma_i(\nu)$ qui n'est autre que la transformée de Fourier de $\gamma_i(n)$, c-à-d :

$$E[S_i(\omega + \nu)S_i^*(\omega)] = \Gamma_i(\nu) = \sum_{n=-\infty}^{+\infty} \gamma_i(n) e^{-j\nu n}. \quad (3)$$

Par ailleurs, si $s_i(n)$ est non-stationnaire en termes de variance, c-à-d si $\gamma_i(n)$ n'est pas constante, alors $S_i(\omega)$ est autocorrélé.

D'après ce théorème, si les sources temporelles sont non-stationnaires et non-corrélées dans le temps, leurs transformées de Fourier sont stationnaires au sens large et autocorrélées. Plusieurs algorithmes ont été proposés pour séparer les MLI de telles sources (e.g. *AMUSE*, *SOBI*, *TD-SEP* [1]). Bien que ces algorithmes soient à l'origine développés pour des processus *temporellement* stationnaires au sens large et corrélés dans le domaine temporel, rien ne nous interdit de les appliquer à des processus *fréquentiellement* stationnaires au sens large et corrélés dans le domaine fréquentiel. Ainsi, rien qu'en observant dans le domaine fréquentiel nos mélanges de signaux initialement non-stationnaires et non-corrélés dans le temps, la SAS peut être réalisée en employant une des nombreuses méthodes développées précédemment pour des mélanges de signaux stationnaires et corrélés dans le temps. A titre d'exemple, un algorithme simple de SAS, qui peut être considéré comme une version modifiée de l'algorithme *AMUSE* dans le domaine fréquentiel, consiste à diagonaliser la matrice $(E[\mathbf{X}(\omega)\mathbf{X}^H(\omega)])^{-1} \cdot E[\mathbf{X}(\omega + \nu)\mathbf{X}^H(\omega)]$ pour un certain décalage fréquentiel ν bien choisi. La matrice de séparation est identifiable si les profils de variance normalisés des sources ne sont pas identiques.

Cependant, si les sources à séparer sont autocorrélées dans le domaine temporel, les conditions du théorème 1 ne sont plus satisfaites et la méthode n'est pas applicable. Afin de pallier ce problème, on propose donc ici une nouvelle approche qui consiste à passer d'un MLI de sources autocorrélées à un MLI de sources non-corrélées dans le temps, tout en gardant les autres propriétés nécessaires pour appliquer la méthode à *décorrélacion spectrale*.

3 Approche proposée

L'approche proposée est basée sur le théorème suivant.

Théorème 2 : Soient $s_i(n)$ ($i = 1, \dots, N$) N signaux aléatoires réels, centrés, *autocorrélés* et mutuellement non-corrélés. Si $g(n)$ est un signal aléatoire réel non-corrélé dans le temps, stationnaire et indépendant de toutes les sources $s_i(n)$, alors les signaux $s'_i(n)$ définis par $s'_i(n) = g(n)s_i(n)$ sont réels, centrés, *non-corrélés dans le temps* et mutuellement non-corrélés. Par ailleurs, les nouvelles sources $s'_i(n)$ ont les mêmes profils de variance normalisés que les sources originales $s_i(n)$.

Preuve : Soit $g(n)$ un signal aléatoire non-corrélé dans le temps, stationnaire et indépendant de toutes les sources $s_i(n)$, supposées réelles, centrées et mutuellement non-corrélées. Soient $s'_i(n) = g(n)s_i(n)$ les nouvelles sources, et soit \mathbf{s}' le nouveau vecteur source défini par $\mathbf{s}'(n) = g(n)\mathbf{s}(n)$. Quels que soient les instants n_1 et n_2 , on a :

$$E[\mathbf{s}'(n_1)\mathbf{s}'(n_2)^T] = E[g(n_1)g(n_2)\mathbf{s}(n_1)\mathbf{s}(n_2)^T]. \quad (4)$$

En utilisant l'indépendance du signal $g(n)$ de toutes les sources $s_i(n)$ on en déduit :

$$E[\mathbf{s}'(n_1)\mathbf{s}'(n_2)^T] = E[g(n_1)g(n_2)]E[\mathbf{s}(n_1)\mathbf{s}(n_2)^T], \quad (5)$$

et en utilisant le fait que le signal $g(n)$ est stationnaire et non-corrélé dans le temps on obtient :

$$E[\mathbf{s}'(n_1)\mathbf{s}'(n_2)^T] = \sigma_g^2 \delta(n_1 - n_2) E[\mathbf{s}(n_1)\mathbf{s}(n_2)^T] \quad (6)$$

où σ_g^2 est la puissance du signal $g(n)$.

Or comme les signaux $s_i(n)$ sont supposés centrés et mutuellement non-corrélés, la matrice $E[\mathbf{s}(n_1)\mathbf{s}(n_2)^T]$ est diagonale. La matrice $E[\mathbf{s}'(n_1)\mathbf{s}'(n_2)^T]$ est donc à son tour diagonale et par conséquent les nouvelles sources $s'_i(n)$, qui sont centrées, sont mutuellement non-corrélées.

D'autre part, d'après l'équation (6), les éléments diagonaux de la matrice $E[\mathbf{s}'(n_1)\mathbf{s}'(n_2)^T]$ s'écrivent :

$$\begin{aligned} E[s'_i(n_1)s'_i(n_2)] &= \sigma_g^2 \delta(n_1 - n_2) E[s_i(n_1)s_i(n_2)] \\ &= \sigma_g^2 \delta(n_1 - n_2) E[s_i^2(n_1)] \end{aligned} \quad (7)$$

Les nouvelles sources $s'_i(n)$ sont donc non-corrélées dans le temps. De plus, en considérant le cas $n_1 = n_2 = n$ l'équation (7) devient :

$$E[s_i'^2(n)] = \sigma_g^2 E[s_i^2(n)] \quad (8)$$

ce qui signifie que les nouvelles sources $s'_i(n)$ ont les mêmes profils de variance normalisés que les sources originales $s_i(n)$.

D'après l'équation (1), si on pose $\mathbf{A} = (a_{ij})_{(i,j=1,\dots,N)}$ on a :

$$x_j(n) = \sum_{i=1}^N a_{ij}s_i(n), \quad j = 1, \dots, N. \quad (9)$$

Les observations $x_j(n)$ sont donc des MLI de sources $s_i(n)$ réelles, centrées, non-stationnaires, *autocorrélées* et mutuellement non-corrélées. En multipliant les deux membres de l'équation (9) par un signal aléatoire $g(n)$, satisfaisant les conditions du théorème 2, on obtient :

$$\begin{aligned} g(n)x_j(n) &= g(n) \left(\sum_{i=1}^N a_{ij}s_i(n) \right) \\ &= \sum_{i=1}^N a_{ij}(g(n)s_i(n)), \quad j = 1, \dots, N \end{aligned} \quad (10)$$

En posant $x'_j(n) = g(n)x_j(n)$ et en tenant compte du fait que $s'_i(n) = g(n)s_i(n)$, l'équation (10) devient :

$$x'_j(n) = \sum_{i=1}^N a_{ij}s'_i(n), \quad j = 1, \dots, N, \quad (11)$$

soit sous forme matricielle :

$$\mathbf{x}'(n) = \mathbf{A}\mathbf{s}'(n), \quad (12)$$

où $\mathbf{x}'(n) = [x'_1(n), x'_2(n), \dots, x'_N(n)]^T$ et $\mathbf{s}'(n) = [s'_1(n), s'_2(n), \dots, s'_N(n)]^T$. On obtient donc un nouveau MLI, mais avec la même matrice de mélange que dans le MLI initial. Or, d'après le théorème 2, les nouvelles sources $s'_i(n)$ sont réelles, centrées, *non-corrélées dans le temps* et mutuellement non-corrélées. Les signaux $x'_j(n)$ sont donc des MLI de nouvelles sources $s'_i(n)$ qui vérifient les conditions du théorème 1. Par ailleurs, selon le théorème 2, cette transformation ne modifie pas les profils de variance normalisés des sources et n'a donc pas d'influence sur l'identifiabilité de la matrice de séparation.

Par conséquent, en appliquant la méthode à *décorrélacion spectrale* aux nouvelles observations $x'_j(n)$, on peut estimer la matrice de séparation et en déduire les sources originales $s_i(n)$ en utilisant les observations initiales $x_j(n)$ ⁵.

4 Résultats expérimentaux

On utilise la méthode à *décorrélacion spectrale*⁶ pour la séparation de MLI de deux signaux de parole, de musique, ou de deux images, qui sont bien des signaux non-stationnaires et autocorrélés. On considère le cas d'un mélange fort défini par la matrice $\mathbf{A} = [1 \ 0.9; 0.8 \ 1]$. Pour mesurer les performances de notre méthode et la comparer à celles de quelques algorithmes classiques de SAS [13], on utilise comme critère de mesure de performances le rapport signal sur interférence en sortie, noté *SIR* (*Signal to Interference Ratio*), défini par :

$$SIR = \frac{1}{2} \sum_{i=1}^2 10 \cdot \log_{10} \frac{E[s_i(n)^2]}{E[(\hat{s}_i(n) - s_i(n))^2]}, \quad (13)$$

où $\hat{s}_i(n)$ est l'estimation de la source $s_i(n)$ après séparation et après normalisation pour qu'elle ait la même puissance et le même signe que $s_i(n)$. Quant au signal $g(n)$ utilisé par notre approche, supposé indépendant des sources $s_i(n)$, on considère un signal aléatoire blanc, stationnaire et uniforme. On donnera à chaque fois le résultat sans et avec multiplication des observations temporelles par ce signal $g(n)$.

4.1 Parole

On utilise deux signaux de parole de 100000 échantillons chacun. Sans et avec multiplication par le signal $g(n)$ on obtient respectivement des *SIR* de 51.3 dB et 76.9 dB, alors qu'en utilisant les 19 méthodes disponibles dans [13], les meilleurs *SIR* sont de 43.8 dB, 43.3 dB et 42.7 dB, obtenus respectivement en utilisant les méthodes *ERICA*, *PEARSON* et *SONS*. Pour la séparation de signaux de parole en MLI, notre méthode est donc plus performante que la méthode non-stationnaire *SONS* et les autres méthodes statistiques disponibles dans [13], même sans multiplication par le signal $g(n)$, mais bien plus encore avec cette multiplication.

⁵On peut également obtenir les sources $s_i(n)$ en divisant les estimations des sources $s'_i(n)$, point par point, par le signal $g(n)$: $s_i(n) = s'_i(n)/g(n)$.

⁶Parmi les algorithmes pratiques qui peuvent être déduits de cette approche générale pour traiter le MLI dans le domaine fréquentiel, on utilise ici l'algorithme *SOBI*.

4.2 Musique

On utilise deux signaux de musique de 100000 échantillons chacun. Sans et avec multiplication par le signal $g(n)$ on obtient respectivement des *SIR* de 62.1 dB et 85.3 dB, alors qu'en utilisant les 19 méthodes disponibles dans [13], les meilleurs *SIR* sont de 66.1 dB, 65.7 dB et 61.2 dB, obtenus respectivement en utilisant les méthodes *SOBI*, *SOBI-BPF* et *SONS*. Sans multiplication par le signal $g(n)$, notre méthode a donc à peu près les mêmes performances que la méthode *SONS* et elle est légèrement moins performante que les deux autres méthodes classiques. En revanche, avec multiplication par le signal $g(n)$, elle est beaucoup plus performante que toutes ces méthodes.

4.3 Images

On utilise deux images astrophysiques de taille (601, 601). Comme notre méthode traite les données à une dimension, on transforme tout d'abord nos observations à deux dimensions (matrices carrées de taille 601) en observations à une dimension (vecteurs lignes de longueur 601 × 601). Une fois la matrice de séparation estimée, on peut remonter aux sources d'origine à deux dimensions en appliquant la transformation inverse. Sans et avec multiplication par le signal $g(n)$ on obtient respectivement des *SIR* de 70.7 dB et 92.4 dB, alors qu'en utilisant les 19 méthodes disponibles dans [13], les meilleurs *SIR* sont de 73.4 dB, 72.0 dB et 64.0 dB, obtenus respectivement en utilisant les méthodes *JADEtd*, *FPICA* et *SONS*. Sans multiplication par le signal $g(n)$, notre méthode est donc plus performante que la méthode *SONS* et légèrement moins performante que les deux autres. Par contre, avec multiplication par le signal $g(n)$, elle est beaucoup plus performante que toutes ces méthodes.

5 Conclusion et perspectives

Les résultats expérimentaux présentés dans cet article montrent d'une part que la méthode à *décorrélation spectrale* est une approche robuste et performante, et d'autre part que son extension que nous avons proposée ici est pertinente et permet d'augmenter considérablement les performances de cette méthode par rapport aux méthodes statistiques temporelles. En effet, l'idée clé de passer, grâce à la transformation de Fourier, d'un MLI de *sources temporelles non-stationnaires et non-corrélés dans le temps* à un MLI de *sources fréquentielles stationnaires et autocorrélées* nous permet d'éviter le modèle stationnaire par morceaux supposé par toutes les méthodes statistiques temporelles, et qui n'est pas rigoureusement applicable à la plupart des signaux réels. Il en est de même pour l'approche proposée dans cet article, qui nous permet de passer d'un MLI de *sources autocorrélées* à un MLI de *sources non-corrélées* dans le temps et donc de nous placer dans les conditions idéales de l'application de la méthode à *décorrélation spectrale*.

En guise de perspectives, une étude des performances de cette nouvelle extension de la méthode à *décorrélation spectrale*, en faisant varier le type des sources utilisées, leur nombre, leur taille, et en changeant le signal aléatoire $g(n)$ peut être intéressante. Une comparaison de performances entre notre méthode et quelques méthodes *déterministes* exploitant la non-stationnarité, telles que les méthodes *temps-fréquence* qui sont basées sur le principe de la *parcimonie*, pourrait aussi être intéressante.

Références

- [1] A. Hyvarinen, J. Karhunen, and E. Oja, *Independent Component Analysis*, Wiley, 2001.
- [2] J.-F. Cardoso, The three easy routes to independent component analysis : contrast and geometry, in *Proc. ICA2001*, San Diego, 2001, pp. 1-6.
- [3] A. Cichocki, S.-I. Amari, *Adaptive blind signal and image processing - learning algorithms and applications*, Wiley, New York, 2002.
- [4] K. Matsuoka, M. Ohya, and M. Kawamoto, A neural net for blind separation of non-stationary signals, *Neural Networks*, vol. 8, no. 3, pp. 411-419, 1995.
- [5] S. Choi, A. Cichocki, and S. Amari, Equivariant non-stationary source separation, *Neural Networks*, vol. 15, no. 1, pp. 121-130, Jan. 2002.
- [6] A. Hyvarinen, Blind source separation by non-stationarity of variance : a cumulant based approach, *IEEE Trans. on Neural Networks*, vol. 12, no. 6, pp. 1471-1474, 2001.
- [7] A. Souloumiac, Blind source detection and separation using second-order non-stationarity, in *Proc. ICASSP*, pp. 1912-1915, 1995.
- [8] D.-T. Pham, and J.-F. Cardoso, Blind separation of independent mixtures of non-stationary sources, *IEEE Trans. on Signal Processing*, vol. 49, no. 9, 2001.
- [9] S. Choi, A. Cichocki, and A. Belouchrani, Second order non-stationary source separation, *Journal of VLSI Signal Processing*, vol. 32, no. 1-2, pp. 93-104, Aug. 2002.
- [10] D.-T. Pham. Joint approximate diagonalization of positive definite hermitian matrices, *SIAM J. Mat. Anal. Appl.*, 22(4) : 1136-1152, 2001.
- [11] S. Hosseini, Y. Deville, Blind separation of nonstationary sources by spectral decorrelation, in *Proc. ICA 2004*, pp. 279-286, Grenade, Espagne, Sept. 22-24, 2004.
- [12] S. Hosseini, Y. Deville, H. Saylani, From time-domain separation of stationary temporally correlated sources to frequency-domain separation of nonstationary sources, *PSIP 2005*, pp. 55-59, Toulouse, France, Jan. 31- Feb. 2, 2005.
- [13] A. Cichocki, S. Amari, K. Siwek, T. Tanaka et al., *ICALAB Toolboxes*, <http://www.bsp.brain.riken.jp/ICALAB>.