

## **ВЫЯВЛЕНИЕ ИСТОЧНИКОВ РАДИОАКТИВНОГО ИЗЛУЧЕНИЯ ПРИ ПОМОЩИ МЕТОДА НЕЗАВИСИМЫХ КОМПОНЕНТ**

*Предлагаемый в работе метод позволяет повысить точность локализации и идентификации источника излучения. При наличии системы датчиков расположенных на различных расстояниях от источника излучения, либо под различными углами к источнику становится возможным произвести выделение скрытого источника при помощи анализа независимых компонент (independent component analysis, ICA)*

Возникновение и развитие радиационных аварий проходит, как правило, в очень короткий срок, что требует принятия безотлагательных мер по их ликвидации. Это соответственно налагает очень жесткие требования на характеристики автоматизированных систем радиологического контроля. В первую очередь к требованиям относятся - повышение точности, скорости и надежности дозиметрических и радиометрических измерений, определение радионуклидного состава радиационных выбросов, направления их распространения. При проведении оперативного радиационного мониторинга в большинстве случаев невозможно быстрое применение аналитического оборудования стационарных лабораторий. На достоверность и точность измерения данных радиационных полей влияют флуктуации природного радиационного фона, территориальная распределенность источников излучения, сложность спектра их излучения, необходимость проведения измерений в естественной среде и в достаточно короткое время. Поэтому особенно актуальным является создание нового поколения информационно измерительных технологий, с помощью которых можно осуществлять оперативный дистанционный контроль радиационного состояния окружающей среды, локализовать, идентифицировать и воспроизвести параметры полей радиоактивного загрязнения с высокой пространственной разрешающей способностью, достоверностью и точностью. Предлагаемый в работе метод позволяет повысить точность локализации и идентификации источника излучения. При наличии системы датчиков расположенных на различных расстояниях от источника излучения, либо под различными углами к источнику становится возможным произвести выделение скрытого источника при помощи анализа независимых компонент [1, 2, 3, 4].

**Задача выделения скрытых источников.** В задачах *выделения скрытых источников* (ВСИ) данные представлены выборкой  $L$  векторов выходов  $D_L = \{\mathbf{y}_i\}_{i=1,L}$ ,  $\mathbf{y}_i \in \mathcal{R}^N$ . Известно, что вектор выходов  $\mathbf{y}$  связан с вектором входов (источников)  $\mathbf{x} \in \mathcal{R}^N$  линейной моделью:  $\mathbf{y} = \mathbf{A}\mathbf{x}$ , где  $\mathbf{A} \in \mathcal{R}^{N \times N}$  –

матрица смешивания полного ранга – неизвестна. Задача состоит в восстановлении  $L$  ненаблюдаемых векторов  $\mathbf{x}$  (матрицы  $\mathbf{X}$ ) по  $L$  наблюдениям  $\mathbf{y}$  (по матрице  $\mathbf{Y} \in \mathfrak{R}^{L \times N}$ ) путем отыскания разделяющей матрицы  $\mathbf{W} = (\mathbf{w}_1, \dots, \mathbf{w}_N)^T \in \mathfrak{R}^{N \times N}$  и выполнения  $\mathbf{Y}\mathbf{W} = \mathbf{X}$ .

Для решения задачи ВСИ известные методы используют априорные предположения об источниках:

- их статистической независимости и негауссовости распределения (анализ независимых компонент *ICA*),
- некоррелированности и гауссовости распределения (анализ главных компонент *PCA*),
- разреженности (анализ разреженных компонент *SCA*),
- независимости составляющих сигналов источников в узкой полосе частот (анализ независимых компонент в поддиапазонах).

Для лучшего понимания задачи выделения скрытых источников рассмотрим пример. Представим, что в комнате одновременно разговаривают два человека. И имеются два микрофона, расположенных в разных местах. С микрофонов мы получаем две записи,  $y_1(t)$  и  $y_2(t)$  – амплитуды сигналов,  $t$  – время. Каждый сигнал  $y_1(t)$ ,  $y_2(t)$ , принятый с микрофона, представляет собой взвешенную сумму сигналов  $x_1(t)$  и  $x_2(t)$  порождаемых говорящими людьми. Теперь, для отдельно взятого момента времени, мы можем записать следующие соотношения:  $y_1(t) = a_{11}x_1(t) + a_{12}x_2(t)$ ;  $y_2(t) = a_{21}x_1(t) + a_{22}x_2(t)$ ; Коэффициенты  $a_{11}$ ,  $a_{12}$ ,  $a_{21}$ ,  $a_{22}$  – зависящие от расстояния между микрофонами и говорящими. Оказывается, что мы можем выделить сигналы скрытых источников (голоса отдельных людей), располагая только лишь сигналами смесей  $y_1(t)$  и  $y_2(t)$  и информацией о статистической независимости источников. Методы позволяющие сделать это, разработаны в рамках направления ВСИ.

**Анализ главных компонент.** В рамках анализа главных компонент разделяющее преобразование сигналов смесей  $\mathbf{y}$  в  $\mathbf{x}^*$  осуществляется следующим образом:

$$\mathbf{x}^* = \mathbf{V}^T \mathbf{y}, \mathbf{W} = \mathbf{V}^T. \quad (1)$$

Здесь  $\mathbf{V}$  – матрица собственных векторов ковариационной матрицы  $\mathbf{C} = E\{\mathbf{Y}^T \mathbf{Y}\}$  исходных данных (сигналов смесей), получаемая с использованием ее разложения по собственным значениям:

$$\mathbf{C} = \mathbf{V} \mathbf{D} \mathbf{V}^T, \quad (2)$$

$\mathbf{D}$  – матрица собственных значений. *PCA* ориентирует оси в направлении максимальной дисперсии. Так, первый главный компонент  $x_1^* = \mathbf{v}_1^T \mathbf{y}$  определяет нормализованную линейную комбинацию тех компонентов исходных векторов, которые дают наибольшее среднее значение дисперсии [3]. Недостатками анализа главных компонент является то, что выделение скрытых источников с его помощью возможно только в случае, когда сигналы источников имеют нормальное распределение и не коррелированы.

Анализ **независимых компонент**. Базовым для анализа независимых компонент [1, 3] является предположение о том, что сигналы источников имеют распределение, отличное от нормального, и являются статистически независимыми. Случайные переменные  $x_i$  являются взаимно независимыми, если совместная плотность вероятности  $f(x_1, x_2, \dots, x_N)$  может быть представлена в виде произведения маргинальных плотностей вероятности  $f_i(x_i)$  [2]:

$$f(x_1, x_2, \dots, x_N) = f_1(x_1) f_2(x_2) \dots f_N(x_N). \quad (3)$$

Используя дифференциальную энтропию  $H$

$$h[f] = - \int_{-\infty}^{\infty} f(x) \log f(x) dx, \quad (4)$$

взаимную информацию  $I$  между  $N$  случайными переменными  $x_i$ ,  $i = 1, \dots, N$  определяют как [2]:

$$I(x_1, x_2, \dots, x_N) = \sum_{i=1, N} H(x_i) - H(\mathbf{x}). \quad (5)$$

Для независимых сигналов взаимная информация равна нулю [2, 3], так как

$$h(X_1, \dots, X_n) = \sum_{i=1}^n h(X_i | X_1, \dots, X_{i-1}) \leq \sum h(X_i) \quad (6)$$

и равенство выполняется только для независимых  $x_1, x_2, \dots, x_N$ . Для *некоррелированных* случайных переменных  $x_1, x_2, \dots, x_N$  взаимная информация выражается через неэнтропию следующим образом [2]:

$$I(x_1, x_2, \dots, x_N) = J(\mathbf{x}) - \sum_{i=1, N} J(x_i), \quad (7)$$

$$J(\mathbf{x}) = H(\mathbf{x}_{gavss}) - H(\mathbf{x}), \quad (8)$$

где  $J(\mathbf{x})$  – неэнтропия,  $\mathbf{x}_{gavss}$  – случайная переменная с нормальным законом распределения и такой же ковариационной матрицей, как и  $\mathbf{x}$ . В работе [5] предложена ЦФ, основанная на неэнтропии. Поскольку при вычислении неэнтропии возникает необходимость оценивать  $f_i(x_i)$ , что трудоемко и не всегда дает достаточную точность, предложено [5] использовать аппроксимацию неэнтропии:

$$J(x) \approx [E\{G(x)\} - E\{G(v)\}]^2, \quad (9)$$

где  $E$  – оператор матожидания,  $G$  – некоторая неквадратичная функция,  $x$  – нормированная центрированная (стандартизованная) случайная переменная,  $v$  – стандартизованная случайная переменная с нормальным распределением. Метод анализа независимых компонент, использующий ЦФ, основанную на неэнтропии называется *FastICA*. Аппроксимация неэнтропии (9) дает следующую целевую функцию для ICA оценивания:

$$J_G(\mathbf{w}) = [E\{G(\mathbf{w}^T \mathbf{y})\} - E\{G(\mathbf{v})\}]^2; \quad (10)$$

где  $\mathbf{w}$  есть  $m$  - мерный вектор такой что  $E\{(\mathbf{w}^T \mathbf{y})^2\} = 1$ ; Максимизируя функцию  $J_G$ : определяют первую независимую компоненту  $x_i^* = \mathbf{w}^T \mathbf{y}$ .

**Сравнение функционирования PCA и ICA.** Рассмотрим пример работы алгоритмов *ICA* и *PCA*. Пусть имеются две равномерно распределенные статистически независимые случайные переменные  $x_1$  и  $x_2$ . Их совместное распределение изображено на рис. А.2а. Совместное распределение смесей  $y_1$  и  $y_2$ , полученных путем умножения  $x_1$  и  $x_2$  на матрицу смешивания  $\mathbf{A}$ , представлен на рис. А.2б. Подадим смеси  $y_1$  и  $y_2$  на вход алгоритмов *ICA* и *PCA*. Рассмотрим результат работы алгоритма *PCA* (рис. А.2в). Видно, что при изменении переменной  $x_1^*$  матожидание переменной  $x_2^*$  не меняется – это значит, что переменные декоррелированы. При этом, распределение величины  $x_2^*$  зависит от того, какое значение приняла  $x_1^*$ :  $f(x_2^* | x_1^*) = f(x_2^*)$ . Это значит, что переменные статистически независимы. Полученное совместное распределение далеко от исходного (рис. А.2а), т.е. смесь разделена неверно. Это происходит потому, что исходное для разделения источников с помощью *PCA* предположение о нормальном распределении источников в данном случае не соблюдается.

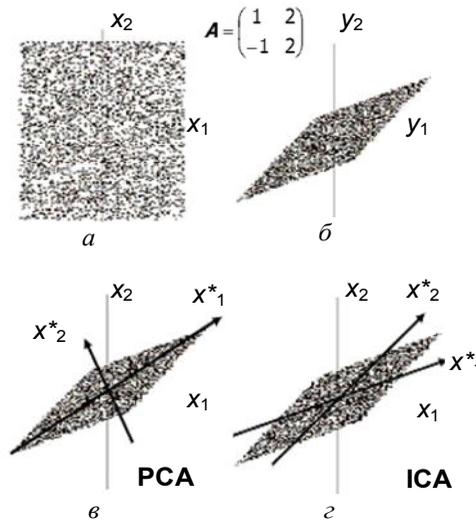


Рис. А.2. Пример разделения смесей методами PCA и ICA. Совместное распределение: а – независимых случайных переменных  $x_1$  и  $x_2$ ; б – смесей  $y_1$  и  $y_2$ ; в – PCA оценок  $x_1^*$  и  $x_2^*$ ; з – ICA оценок  $x_1^*$  и  $x_2^*$

Рассмотрим результат работы алгоритма *ICA* (рис. А.2з). Видно, что при изменении переменной  $x_1^*$  не меняется не только матожидание переменной  $x_2^*$ , но и ее распределение. Это значит, что переменные – статистически независимы, так как распределение величины  $x_2^*$  не зависит от того, какое

значение приняла  $x_1^*$ :  $f(x_2^*|x_1^*)=f(x_2^*)$ . Совместное распределение переменных  $x_1^*$  и  $x_2^*$  совпадает с исходным (рис. А.2а), задача ВСИ решена.

**Алгоритм анализа независимых компонент [7]**

Шаг 1: Выбрать начальный вектор весов  $w$ ,

Шаг 2:  $w^* = E \{x G(w^T x)\} - E \{G'(w^T x)\}w$ ,

Шаг 3:  $w = w^* / \|w^*\|$ ,

Шаг 4: Если сходимость не достигнута, то перейти к шагу 2.

**Экспериментальное исследование.** В качестве исходных данных использовались результаты измерения спектров радионуклидов (гамма-излучающих элементов) спектрометрическим трактом, включающим детекторы типа *NaJ(Tl)* 63×63 и ПРС «Вектор». Измеряемый спектр представлял собой вектор из  $L=256$  чисел, каждое из которых – количество гамма-квантов, обладающих определенной энергией в диапазоне 120...2000 КэВ. В эксперименте спектр источников излучения  $Cs^{137}$  и  $K^{40}$  фиксировался одновременно тремя детекторами, расположенными на различных расстояниях от источников. Отметим, что помимо скрытого источника  $K^{40}$ , данный гамма - излучающий элемент присутствует также и в фоновом излучении. Измеренные спектры представлены на рис.1. Спектры были поданы на вход алгоритма анализа независимых компонент. Результаты работы алгоритма (выделенные скрытые источники  $Cs^{137}$  и  $K^{40}$ ) представлены на рис.2. Компонент 1 соответствует источнику  $Cs^{137}$ , компонент 2 соответствует источнику  $K^{40}$ .

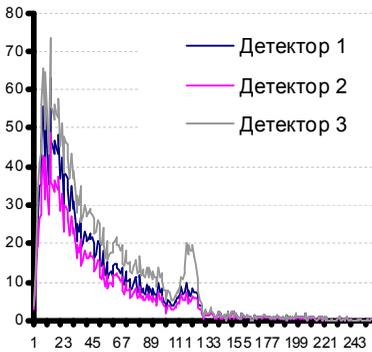


Рис.1. Спектры смесей.

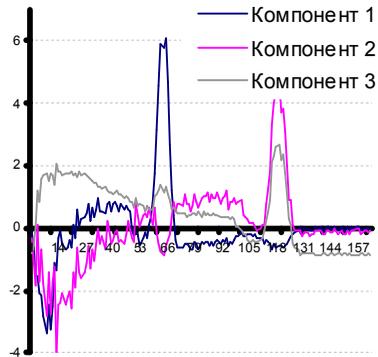


Рис.2. Выделенные независимые компоненты.

Отметим, что предложенный метод выделения скрытых источников не требует измерения фона и не требует априорного знания об отклике детектора, а количество выделяемых скрытых источников зависит только от числа детекторов.

### Исследование зависимости ОСШ от уровня мешающего сигнала.

Цель эксперимента – исследовать точность восстановления полезного сигнала из смеси двух сигналов при возрастании уровня мешающего сигнала (УМС). Эксперимент даст возможность понять, ухудшает ли возрастающий уровень мешающего сигнала характеристики восстановления для методов *PCA* и *ICA*.

В данном эксперименте смеси были сформированы путем умножения матрицы сигналов источников на смешивающую матрицу **A**. Сигналы источников представлены: первый – цезий 137, второй – калий 40; УМС изменялся с 5 до  $10^5$ .

Из смеси методами *PCA*, *ICA* выделялся сигнал цезия-137 и вычислялось соответствующее ОСШ. Зависимость отношения сигнал-шум ОСШ от УМС при отсутствующем аддитивном собственном шуме приведена на рис. 3.

Для *PCA* ОСШ сначала возрастает с ростом УМС, а затем постоянно. Это связано с тем, что *PCA* ориентирует оси новой системы координат по направлению максимальной дисперсии. В случае, когда амплитуды источников сравнимы, выбор направления максимальной дисперсии чувствителен к соотношению амплитуд источников сигнала. Соответственно, при изменении УМС с 10 до  $10^3$  ОСШ растет. В случае же, когда амплитуда одного из источников намного превышает амплитуду другого, направление максимальной дисперсии определяется максимальной амплитудой, поэтому для УМС с  $10^3$  до  $10^5$  ОСШ постоянно.

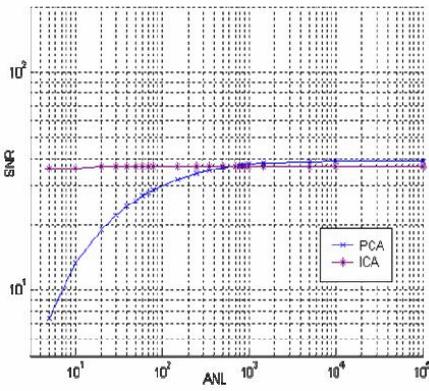


Рис. 3. Зависимость ОСШ= $f$ (УМС) при УСШК=0

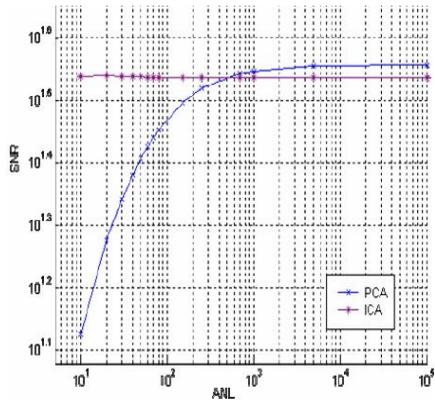


Рис.4. Зависимость ОСШ= $f$ (УМС) при УСШК=0.2

Для алгоритма *ICA* ОСШ не зависит от УМС. Это связано с тем, что *ICA* использует априорное предположение о независимости источников. При одновременном увеличении амплитуды одной из компонент в обеих составляющих смеси взаимная информация между смесями не меняется, и

ОСШ не зависит от УМС одного из источников (при неизменном УМС второго источника). Зависимость  $ОСШ=f(УМС)$  при наличии в смесях собственного шума приведена на рис. 4. Видно, что сохраняются описанные выше тенденции поведения характеристики  $ОСШ=f(УМС)$  для случая отсутствия шума.

1. *P. Comon*. Independent component analysis: a new concept // *Signal Processing*. – 1994. – 36. – pp. 287-314.
2. *A. Hyvarinen, E. Oja*. Independent Component Analysis: Algorithms and Applications // *Neural Networks*. – 2000. – 13(4-5). – pp. 411-430.
3. *A. Chichocki, S. Amari*. Adaptive Blind Signal and Image Processing. – Wiley. – 2002. – 586 P.
4. *J.F. Cardoso*. Infomax and maximum likelihood for source separation // *IEEE Letters on Signal Processing*. – 1997. – 4. – pp. 112-114.
5. *A. Hyvarinen*. New approximation of differential entropy for Independent Component Analysis and Projection Pursuit // *In Advances in Neural Information Processing Systems*. – MIT Press. – 1998. – 10. – pp. 273-279.
6. *A. Hyvarinen*. Fast and robust fixed-point algorithms for Independent Component Analysis // *IEEE Trans. On Neural Networks*. – 1999. – 10(3). – pp. 626-634.
7. *A. Hyvarinen, E. Oja*. A Fast Fixed-Point Algorithm for Independent Component Analysis. // *Neural Computation*. – 1997. – 9. – pp. 1483-1492.