

УДК 621.396.969.35

В. К. Х о х л о в, Ю. Ю. Гу л и н

ВЫБОР ИНФОРМАТИВНЫХ ПРИЗНАКОВ В АВТОНОМНЫХ ИНФОРМАЦИОННЫХ СИСТЕМАХ С НЕЙРОСЕТЕВЫМИ ТРАКТАМИ ОБРАБОТКИ СИГНАЛОВ

Рассмотрены задачи выбора информативных признаков и сокращения их размерности в случае отсутствия априорной информации о математических ожиданиях параметров случайных сигналов. Предложены методы решения этих задач с использованием коэффициентов множественной начальной регрессии. На практическом примере проведено сравнение с методом дискриминантного анализа и методом главных компонент.

Специфическими свойствами автономных информационных систем ближней локации являются априорная неопределенность, существенная нестационарность случайных входных сигналов, ограниченное время обработки информации, отсутствие полной аналитической модели процессов. Случайные сигналы и помехи на входе имеют большой динамический диапазон амплитудных, частотных и временных характеристик. Информативные параметры сигналов часто являются нецентрированными случайными величинами, для которых математические ожидания априори неизвестны, и оценить их по нестационарной реализации не представляется возможным.

Отмеченные особенности сигналов на входе систем ближней локации затрудняют использование традиционных статистических методов, требующих вычисления и обработки центрированных параметров сигналов.

Снять ограничения, связанные с нестационарностью информативных параметров, позволяет переход в признаковое пространство, в котором каждая выборочная реализация отображается вектором, а ансамбль реализаций — областью. Для обработки информации в многомерном признаковом пространстве при отмеченных выше особенностях автономных информационных систем ближней локации необходимы эффективные методы выделения информативных признаков и обоснования решающих функций (разделяющих границ) в условиях априорной неопределенности в сложной помеховой обстановке. В этих

условиях важны сокращение времени на разработку систем и автоматизация процесса исследования.

Всем отмеченным требованиям удовлетворяет подход к созданию принципиально новых автономных информационных систем, основанный на обработке нецентрированных параметров сигналов и помех, на использовании в качестве априорной информации начальных моментов случайных процессов и на применении нейросетевых технологий для исследования и проектирования автономных информационных систем нового поколения. В работе [1] показано, что в этом случае наиболее удобно применение аппарата начальных регрессионных характеристик, который позволяет решать поставленные задачи в условиях вырожденности или плохой обусловленности данных при неизвестных математических ожиданиях и ковариационных матрицах.

Регрессионные методы выбора информативных признаков. В работе [1] показано, что в регрессионных алгоритмах при обнаружении сигналов необходимо вычислять квадраты ошибок множественных начальных регрессионных представлений (МНРП) вида

$$\sum_{i=1}^N \left(x_i - \sum_{\substack{k=1 \\ k \neq i}}^N \beta_{ik} x_k \right)^2, \text{ где } \beta_{ik} = -\frac{\Lambda_{ik}}{\Lambda_{ii}} \text{ — коэффициенты множественной начальной регрессии; } \Lambda_{ik}, \Lambda_{ii} \text{ — элементы матрицы, обратной матрице корреляционных (начальных) моментов; } x_k \text{ — оценки нецентрированных параметров сигналов; } N \text{ — размерность вектора информативных признаков. Коэффициенты множественной начальной регрессии (КМНР) рассчитываются исходя из условия минимума среднего значения квадрата ошибки МНРП:}$$

где $M[\cdot]$ — оператор математического ожидания.

$$\overline{\Psi_0^2} = M \left[\sum_{i=1}^N \left(x_i - \sum_{\substack{k=1 \\ k \neq i}}^N \beta_{ik} x_k \right)^2 \right], \quad (1)$$

где $M[\cdot]$ — оператор математического ожидания.

При обнаружении сигналов для учета влияния каждой m -й компоненты входного вектора в регрессионной модели необходимо при исключенной m -й компоненте найти среднее значение вида (1):

$$\overline{\Psi_m^2} = M \left[\sum_{i=1}^N \left(x_i - \sum_{\substack{k=1 \\ k \neq i, k \neq m}}^N \beta_{ik} x_k \right)^2 \right],$$

и величину его изменения

$$\Delta\Psi_m = \overline{\Psi_m^2} - \overline{\Psi_0^2} = \sum_{i=1}^N \left(-\beta_{im}^2 \overline{x_m^2} - 2 \sum_{\substack{k=1 \\ k \neq i, k \neq m}}^N K_{km} \beta_{ik} \beta_{im} + 2K_{im} \beta_{im} \right),$$

где $\overline{x_m^2}$ — среднее значение квадрата m -й компоненты входного вектора ($m \neq i$); K_{km} , K_{im} — элементы матрицы корреляционных (начальных) моментов; при этом чем больше изменение $\Delta\Psi_m$, тем предпочтительнее компонента. Таким образом, для всех m необходимо упорядочить по убыванию величины $\Delta\Psi_m$ и отбрасыванием $N - q$ последних значений сформировать вектор информативных признаков размерностью q , который в дальнейшем используется при исследовании нейросетевой системы обнаружения сигнала.

При использовании множественной начальной регрессии алгоритмы обнаружения и распознавания соответственно имеют вид [1]

$$\frac{1}{2f_B S_0} \sum_{i=1}^N x_i^2 - \frac{1}{4} \sum_{i=1}^N \Lambda_{ii} \left(x_i - \sum_{\substack{k=1 \\ k \neq i}}^N \beta_{ik} x_k \right)^2 \geq \gamma_1, \quad (2)$$

$$- \frac{1}{4} \sum_{i=1}^N \Lambda_{ii}^c \left(x_i - \sum_{\substack{k=1 \\ k \neq i}}^N \beta_{ik}^c x_k \right)^2 + \frac{1}{4} \sum_{i=1}^N \Lambda_{ii}^n \left(x_i - \sum_{\substack{k=1 \\ k \neq i}}^N \beta_{ik}^n x_k \right)^2 \geq \gamma_2, \quad (3)$$

где S_0 — спектральная плотность шума в полосе $0 \dots f_B$; γ_1, γ_2 — пороговые уровни в алгоритмах обнаружения и распознавания соответственно; $\Lambda_{ii}^c, \Lambda_{ii}^n$ — элементы матриц, обратных матрицам корреляционных (начальных) моментов, для сигнала и помехи соответственно; $\beta_{ik}^c, \Lambda_{ii}^n$ — коэффициенты множественной начальной регрессии для сигнала и помехи соответственно.

При равенстве энергий сигнала и помехи регрессионный алгоритм распознавания можно представить в виде неравенства [1]

$$- \sum_{i=1}^N \Lambda_{ii}^c \left(x_i - \sum_{\substack{k=1 \\ k \neq i}}^N \beta_{ik}^c x_k \right)^2 + \sum_{i=1}^N \Lambda_{ii}^n \left(x_i - \sum_{\substack{k=1 \\ k \neq i}}^N \beta_{ik}^n x_k \right)^2 \geq 0. \quad (4)$$

Для вектора оценок параметров сигнала $\{x_1^c, x_2^c, \dots, x_N^c\}^T$ при усреднении неравенства (4) по области существования сигнала имеем

$$M \left[\left(x_i^c - \sum_{\substack{k=1 \\ k \neq i}}^N \beta_{ik}^c x_k^c \right)^2 \right] = \overline{\Psi_{0ci}^2}$$

— среднее значение квадрата ошибки МНРП для сигнала;

$$M \left[\left(x_i^c - \sum_{\substack{k=1 \\ k \neq i}}^N \beta_{ik}^n x_k^c \right)^2 \right] = \overline{\Psi_{0cni}^2}$$

— среднее значение квадрата ошибки МНРП для помехи при наличии на входе сигнала.

Учитывая, что $M \left[\left(x_i^n - \sum_{\substack{k=1 \\ k \neq i}}^N \beta_{ik}^n x_k^n \right)^2 \right] = \overline{\Psi_{0ni}^2}$ — среднее значение квадрата ошибки МНРП для помехи, из неравенства (4) получим

$$\sum_{i=1}^N \frac{\overline{\Psi_{0cni}^2}}{\overline{\Psi_{0ni}^2}} > N. \quad (5)$$

При распознавании сигналов на фоне помех и уменьшении размерности векторов входных реализаций из неравенства (5) следует, что необходимо отбирать те информативные параметры, для которых имеем

$$\gamma_i = \frac{\overline{\Psi_{0cni}^2}}{\overline{\Psi_{0ni}^2}} > 1, \quad (6)$$

что соответствует максимальному разному в пространстве линий регрессии сигналов и помех.

Критерий (6) также позволяет уменьшить размерность вектора информативных признаков при распознавании сигналов и помех. При этом для всех i необходимо упорядочить по убыванию величины γ_i и отбрасыванием $N - r$ последних значений сформировать вектор информативных признаков размерностью r .

Коэффициенты множественной начальной регрессии и средние квадраты ошибок МНРП можно получить путем обучения нейросети с разорванными прямыми связями и нулевыми смещениями нейронов

(рис. 1), на входы которой подан анализируемый вектор информативных признаков $\vec{X} = \{x_1, x_2, \dots, x_N\}^T$ [2]. Данная нейронная сеть содержит $m = N$ нейронов и осуществляет линейную обработку по алгоритму

$$g_i = \sum_{k=1}^N w_{ik}x_k, \quad w_{ii} = 0, \quad i = 1, \dots, m, \quad (7)$$

или (в матричном виде)

$$G = WX,$$

где $G = \{g_1, g_2, \dots, g_m\}^T$ — вектор сигналов на выходах нейронов; $W = w_{ik}$ — матрица весов размерности $m \times N$ с нулевыми диагональными элементами.

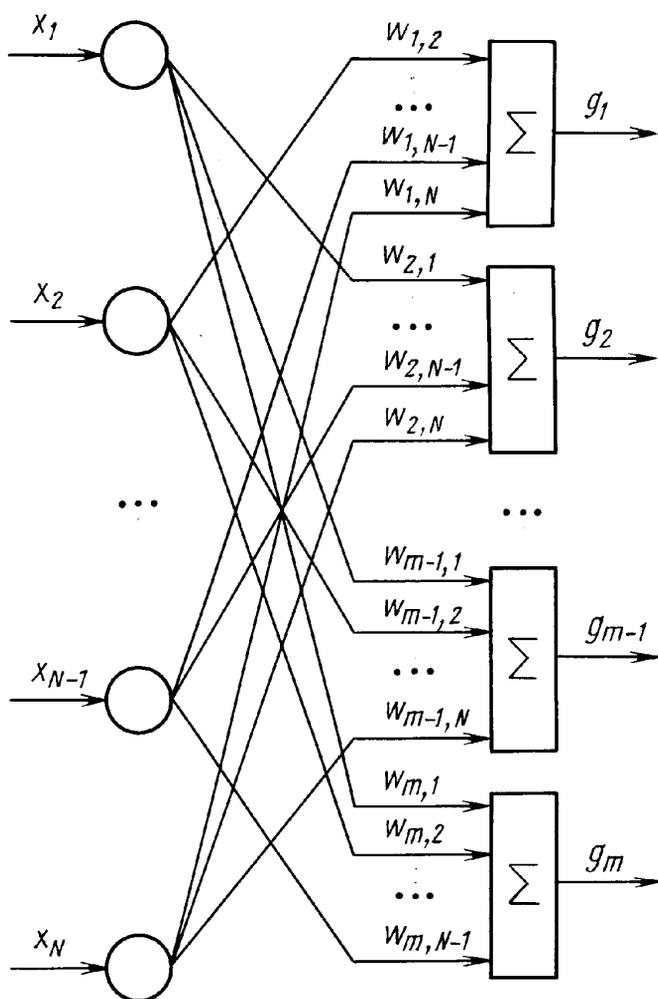


Рис. 1. Нейронная сеть с разорванными прямыми связями, реализующая алгоритм (7)

Если на выходе каждого i -го нейрона потребовать восстановления i -го входного признака с минимальным средним значением

$$\overline{\Psi_0^2} = M [\Psi_0^T \Psi_0] = M [(G - WX)^T (G - WX)],$$

то, дифференцируя $\overline{\Psi_0^2}$ по W и приравнявая производную нулю, для положительно определенной и симметричной матрицы начальных корреляционных моментов K получим

$$w_{ik} = -\frac{\Lambda_{ik}}{\Lambda_{ii}}, \quad (8)$$

где $\Lambda = K^{-1}$.

Как следует из равенства (8), весовые коэффициенты w_{ik} в рассматриваемом случае являются коэффициентами начальной регрессии.

Вычисляя условные плотности распределения вероятностей для нормально распределенных векторов, можно показать [1], что λ_{ii} — элементы матриц, обратных матрицам ковариационных (центральных) моментов, представляющие собой величины, обратно пропорциональные остаточным дисперсиям множественных регрессионных представлений $D_i^{\text{ост}} = 1/\lambda_{ii}$. Аналогично можно показать, что Λ_{ii} в неравенстве (2) — это величина, обратная среднему значению квадрата ошибки МНРП i -й компоненты ($\overline{\Psi_{0i}^2}$).

Для упрощения вычисления неравенств (2), (3) и реализации систем принятия решения на элементах дискретно-аналоговой техники область принятия решения можно формировать, вычисляя неравенства

$$\sum_{i=1}^N x_i - \sum_{i=1}^N K_i \left| x_i - \sum_{\substack{k=1 \\ k \neq i}}^N \beta_{ik} x_k \right| \geq U_c, \quad (9)$$

$$- \sum_{i=1}^N K_i^c \left| x_i - \sum_{\substack{k=1 \\ k \neq i}}^N \beta_{ik}^c x_k \right| + \sum_{i=1}^N K_i^{\text{п}} \left| x_i - \sum_{\substack{k=1 \\ k \neq i}}^N \beta_{ik}^{\text{п}} x_k \right| \geq U_{\text{п}}, \quad (10)$$

где K_i , K_i^c , $K_i^{\text{п}}$ — весовые коэффициенты регрессионных алгоритмов обнаружения и распознавания; U_c , $U_{\text{п}}$ — пороговые уровни в алгоритмах обнаружения и распознавания соответственно.

Данные регрессионные алгоритмы имеют геометрический смысл: они формируют область принятия решения ограничением расстояния от линии начальной регрессии [1]. Алгоритмы, имеющие геометрический смысл, могут применяться независимо от закона распределения входного вектора [3].

При раскрытии модулей в выражениях (9) и (10) можно перейти к нейрореподобным структурам, реализующим эти алгоритмы [2].

Например, при $N = 2$ алгоритм работы регрессионной системы обнаружения будет иметь вид [1]

$$ax_1 + bx_2 - K|x_2 - \beta_{21}x_1| \geq U_{\text{п}}, \quad (11)$$

где K , a и b — весовые коэффициенты. Выбором коэффициентов a , b и K можно задавать положение линейных границ области принятия решения относительно линии регрессии:

$$x_2 - \beta_{21}x_1 = 0.$$

Это эквивалентно изменению положения разделяющей поверхности при использовании модели нейронной сети.

Алгоритм, соответствующий неравенству (11), можно заменить эквивалентной системой неравенств

$$\begin{aligned} x_1(a + K\beta_{21}) + x_2(b - K) &\geq U_{\text{п}}, & x_2 - \beta_{21}x_1 &> 0, \\ x_1(a - K\beta_{21}) + x_2(b + K) &\geq U_{\text{п}}, & x_2 - \beta_{21}x_1 &< 0 \end{aligned} \quad (12)$$

и реализовать с помощью двухслойной нейронной сети с пороговыми активационными функциями, где первый слой реализует неравенства (12), а второй слой, состоящий из одного нейрона, — элемент И (рис. 2). Параметры сети следующие: матрица весов 1-го слоя

$$W = \begin{bmatrix} w_{11} & w_{12} \\ w_{21} & w_{22} \end{bmatrix} = \begin{bmatrix} a + K\beta_{21} & a - K\beta_{21} \\ b - K & b + K \end{bmatrix},$$

вектор порогов 1-го слоя

$$\Pi = \begin{bmatrix} \pi_1 \\ \pi_2 \end{bmatrix} = \begin{bmatrix} -U_{\text{п}} \\ -U_{\text{п}} \end{bmatrix},$$

вектор весов 2-го слоя

$$S = \begin{bmatrix} s_1 \\ s_2 \end{bmatrix} = \begin{bmatrix} 0,5 \\ 0,5 \end{bmatrix},$$

порог 2-го слоя $0,5 < s_0 < 1$.

Недостаток регрессионного подхода заключается в необходимости оптимизации параметров алгоритмов (коэффициентов K_i), что при большой размерности входного вектора значительно усложняет решение задачи. Нейросетевая структура позволяет выделить более сложные зависимости, нежели те, которые выражаются коэффициентами регрессии.

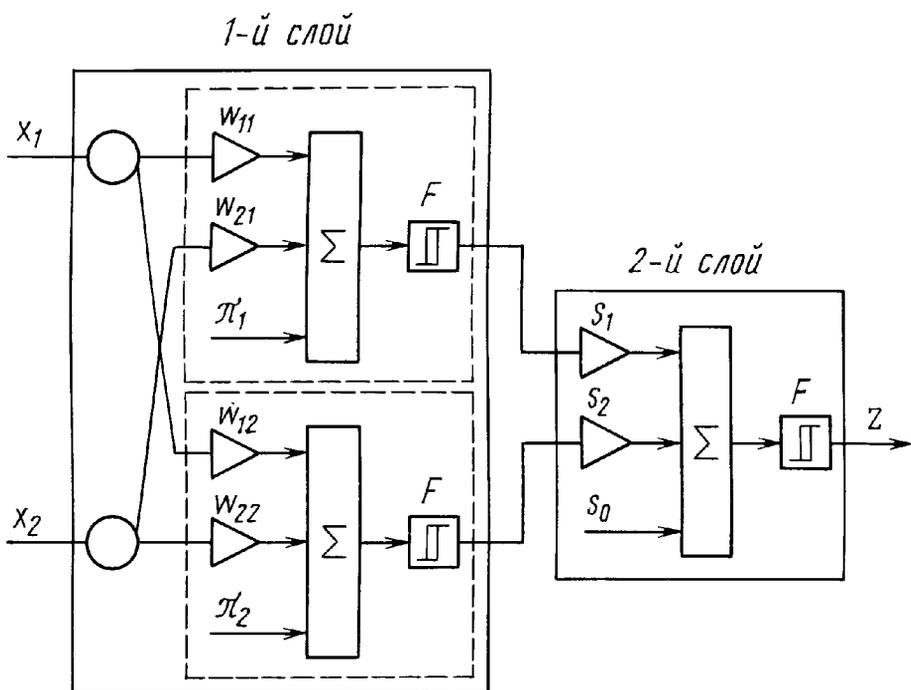


Рис. 2. Двухслойная нейронная сеть, реализующая алгоритм (12)

Существующие регрессионные системы учитывают только парную корреляцию двух соседних отсчетов входного вектора признаков. Нейросетевые системы позволяют учесть корреляцию трех и более отсчетов входного вектора, улучшив тем самым качество алгоритмов обработки.

Классические методы выбора информативных признаков. Для сравнения с методом на основе КМНР (без использования оценок математических ожиданий) рассмотрим метод главных компонент и метод дискриминантного анализа.

В методах главных компонент и дискриминантного анализа используются центральные моменты случайных величин, вычисление которых невозможно при неизвестных математических ожиданиях (большом динамическом диапазоне параметров). Кроме того, при вырожденности данных с помощью метода главных компонент отбрасываются собственные векторы, соответствующие малым (в силу вырожденности) собственным значениям ковариационной матрицы.

При дискриминантном анализе для формирования критериев разделимости классов используются матрицы рассеяния внутри классов (SW) и между классами (SB). Для анализа разделимости классов применяются критерии J_1 и J_4 [4, 5]:

$$J_1 = \text{tr} (SW^{-1}SB), \quad J_4 = \frac{\text{tr} (SB)}{\text{tr} (SW)}.$$

Критерий J_1 инвариантен относительно любого невырожденного линейного преобразования, критерий J_4 зависит от системы координат. Одно из важных преимуществ этих критериев заключается в том, что эти критерии можно использовать также при наличии многих классов. Необходимо только обобщить определение матриц рассеяния. Однако при увеличении числа классов эти критерии, как и любые другие, все менее точно позволяют определить разделимость классов. Поэтому оптимально использовать только парную классификацию. В качестве критерия разделимости двух классов использовалось также расстояние Бхатачария μ :

$$\mu \left(\frac{1}{2} \right) = \frac{1}{8} (\bar{m}_1 - \bar{m}_2)^T \left(\frac{C_1 + C_2}{2} \right)^{-1} (\bar{m}_1 + \bar{m}_2) + \frac{1}{2} \ln \frac{\left| \frac{1}{2} (C_1 + C_2) \right|}{|C_1|^{\frac{1}{2}} |C_2|^{\frac{1}{2}}},$$

где \bar{m}_1, \bar{m}_2 — векторы средних значений выборок каждого класса; C_1, C_2 — ковариационные матрицы.

В теории распознавания образов для сокращения размерности векторов признаков часто используется разложение Карунена–Люэва [5–8]. Его дискретный аналог — метод главных компонент.

В методе главных компонент используются центральные (ковариационные) моменты случайных отсчетов сигналов и предполагается нахождение собственных векторов и собственных значений по заданной ковариационной матрице.

Экспериментальные исследования. В качестве примера рассмотрим выбор информативных признаков применительно к задаче распознавания акустических сигналов аэродинамических объектов (самолета и вертолета). Исходными данными служили записи акустических сигналов самолета и вертолета, полученные в естественных условиях и подвергнутые обработке фильтром высоких частот с частотой среза 200 Гц для подавления шума ветра.

Выбор длины реализации осуществлялся из следующих соображений. Поскольку время принятия решения устройства ограничено и составляет 0,5 с (это связано со спецификой задач ближней локации), то положим, что устройство тратит 0,4 с на накопление данных и 0,1 с непосредственно на процедуру принятия решения. Тогда при частоте дискретизации $F = 10$ кГц сигнала на входе имеем $N = 4000$ отсчетов. Для удобства дальнейшей обработки примем $N = 4096$ отсчетов.

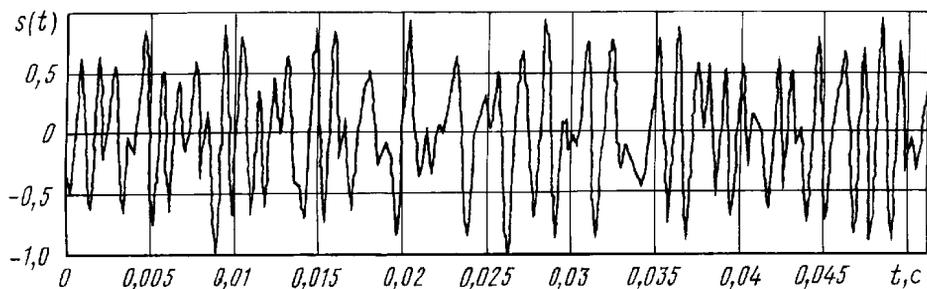


Рис. 3. Реализация акустического сигнала самолета

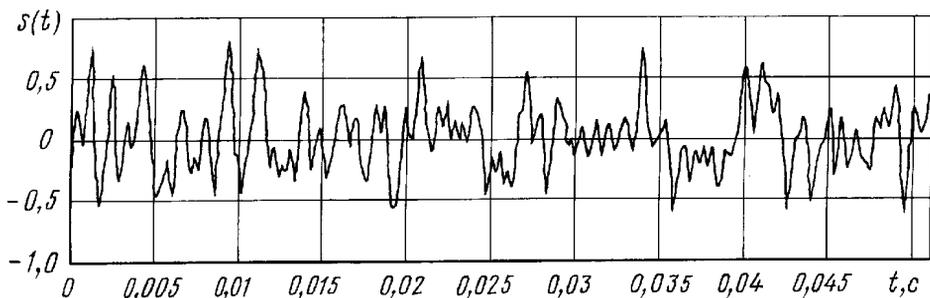


Рис. 4. Реализация акустического сигнала вертолета

На рис. 3, 4 приведены реализации акустических сигналов самолета и вертолета.

На рис. 5, 6 приведены периодограммные оценки Уэлча спектральных плотностей мощности (СПМ) акустических сигналов.

Анализовались следующие признаки реализации акустического сигнала: длительности τ интервалов между нулями, отсчеты огибающей E , распределение G_τ длительностей интервалов между нулями (гистограммная оценка), отсчеты оценки СПМ.

Была проведена оценка обусловленности матриц корреляционных моментов выбранных информативных признаков. Показано, что матрицы корреляционных моментов интервалов между нулями имеют порядок обусловленности $1,0 \cdot 10^{23}$, поэтому далее они не рассматривались.

На рис. 7 приведены значения $\gamma_i = \frac{\Psi_{0спi}^2}{\Psi_{0pi}^2}$, определенные на основе КМНР по 100 реализациям акустических сигналов каждого класса. В качестве помехи принят сигнал самолета. Согласно рис. 7 можно сделать вывод, что наиболее информативными с точки зрения разделимости классов являются отсчеты спектра сигналов самолета и вертолета, так как в соответствии с критерием (6) они обеспечивают наибольшее отличие частного γ_i от единицы.

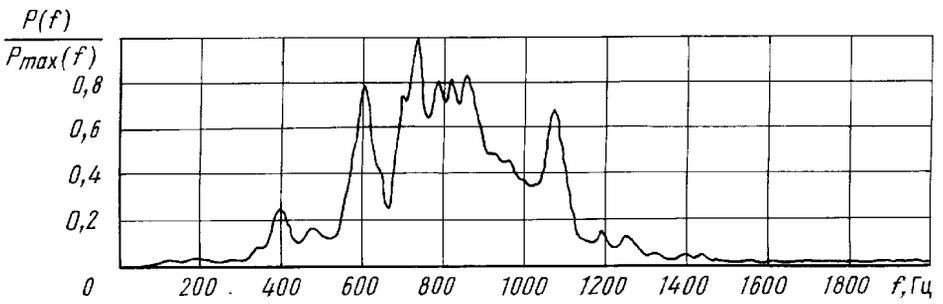


Рис. 5. Оценка СПМ акустического сигнала самолета

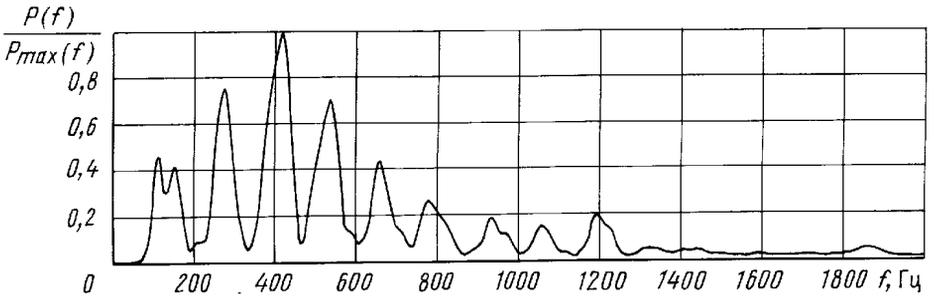


Рис. 6. Оценка СПМ акустического сигнала вертолета

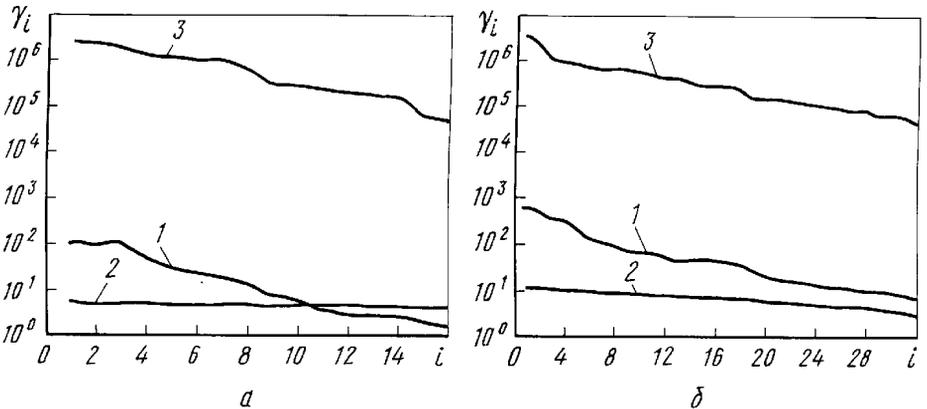


Рис. 7. Значения γ_i , вычисленные при $N = 16$ (а) и $N = 32$ (б) для гистограммы распределения длительностей интервалов между нулями (1), отсчетов огибающей (2), отсчетов локальных экстремумов СПМ (3)

Результаты вычисления критериев дискриминантного анализа для выборок из 100 реализаций каждого класса представлены в таблице. Из таблицы видно, что наилучшая разделяемость классов достигается при использовании в качестве информативного признака отсчетов спектра сигналов самолета и вертолета.

Критерий	Признак ($N = 16$)			Признак ($N = 32$)		
	J_1	J_4	μ	J_1	J_4	μ
Гистограмма распределения G_T	159,83	5,46	22,79	327,12	1,42	49,48
Отсчеты огибающей E	0,91	0,02	0,97	1,22	0,01	2,89
Отсчеты СПМ	78,97	7,00	34,04	136,42	5,64	67,46

Таким образом, дискриминантный анализ и метод на основе КМНР показали, что наилучшим признаком с точки зрения делимости классов следует признать отсчеты огибающей спектров сигналов, соответствующие локальным экстремумам спектра.

На рис. 8–10 приведены графики упорядоченных значений $\Delta\Psi'_m = \Delta\Psi_m / \sum_{m=1}^N \Delta\Psi_m$ для рассматриваемых информативных признаков; для сравнения приведены графики относительных долей дисперсии $q_m = \lambda_m / \sum_{m=1}^N \lambda_m$ ковариационных матриц информативных признаков, рассчитанных по методу главных компонент.

Сравнение графиков $\Delta\Psi'_m$ и q_m показывает, что область существенного уменьшения значений $\Delta\Psi'_m$ совпадает с областью значительного уменьшения относительных долей дисперсии.

С помощью двух рассмотренных методов уменьшения размерности получены идентичные результаты. В методе главных компонент элементы входного вектора упорядочиваются по убыванию их дисперсий (собственных чисел ковариационной матрицы). Отбрасываются те элементы входного вектора, влияние которых на суммарную дисперсию

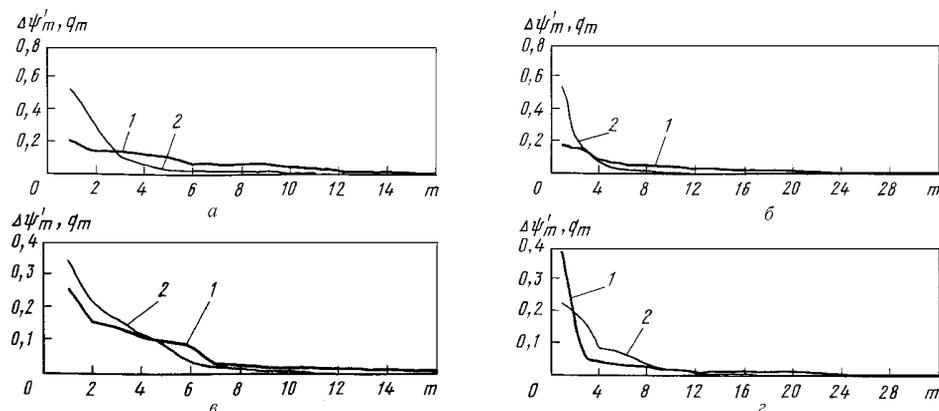


Рис. 8. Графики Ψ'_m (1) и q_m (2) распределения длительностей интервалов между нулями для сигналов самолета (а, б) и вертолета (в, г)

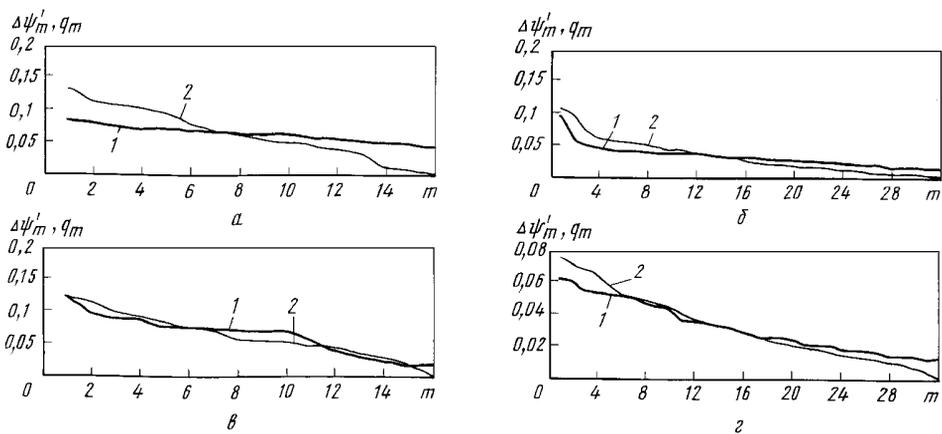


Рис. 9. Графики Ψ'_m (1) и q_m (2) отсчетов огибающей для сигналов самолета (а, б) и вертолета (в, з)

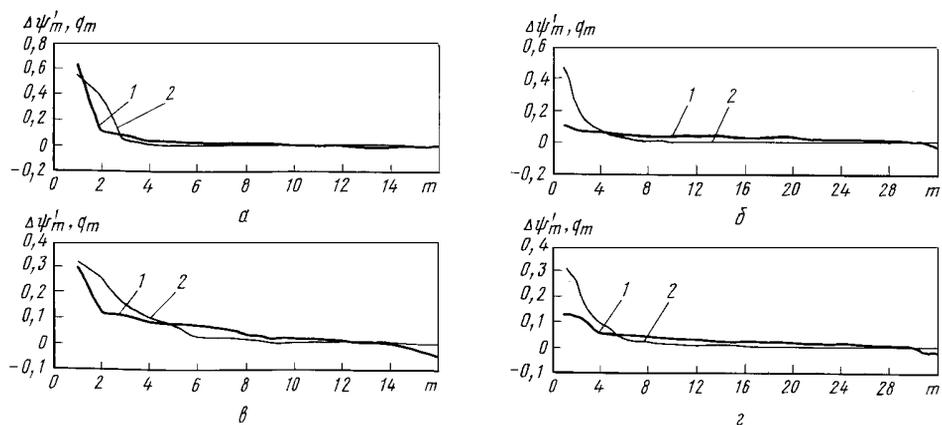


Рис. 10. Графики Ψ'_m (1) и q_m (2) отсчетов спектра, соответствующих локальным экстремумам, для сигналов самолета (а, б) и вертолета (в, з)

минимально. Аналогичным образом в методе, использующем КМНР, элементы входного вектора упорядочиваются по убыванию значений $\Delta\Psi_m$. Отбрасываются те элементы входного вектора, для которых эта величина, соответствующая их влиянию на регрессионное представление, минимальна.

Заключение. С помощью рассмотренных методов выбора информативных признаков получены сходные результаты. Это позволяет сделать вывод о возможности применения методов на основе КМНР в условиях плохой обусловленности данных, априорной неопределенности, при неизвестных математических ожиданиях, так как данная методика оперирует начальными моментами случайных величин. Кроме того, использование КМНР связано с меньшими вычислительными затратами.

СПИСОК ЛИТЕРАТУРЫ

1. М у с ь я к о в М. П., Х о х л о в В. К. Регрессионные системы обнаружения и распознавания случайных сигналов в ближней локации. – М.: ЦНИИЭКТР, 1988. – 171 с.
2. Х о х л о в В. К., Г р о м о в а Е. В. Сокращение размерности векторов входных реализаций в нейросетевых трактах обработки сигналов систем ближней локации // Вестник МГТУ им. Н.Э. Баумана. Сер. “Приборостроение”. – 1999. – № 4. – С. 41–48.
3. Л е в и н Б. Р. Теоретические основы статистической радиотехники. – М.: Сов. радио, 1976. – 288 с.
4. Д у д а Р., Х а р т П. Распознавание образов и анализ сцен / Под ред. В.Л. Стефанюка. – М.: Мир, 1976. – 230 с.
5. Ф у к у н а г а К. Введение в статистическую теорию распознавания образов. – М.: Наука, 1979. – 368 с.
6. А й в а з я н С. А., Б е ж а е в а З. И., С т а р о в е р о в О. В. Классификация многомерных наблюдений. – М.: Статистика, 1974. – 240 с.
7. К и с е л е в Н. В. Методы построения систем распознавания и классификации негауссовых сигналов. – Л.: Изд-во ЛГУ, 1986. – 188 с.
8. У и л к с С. Математическая статистика / Под ред. Ю.В. Линника. – М.: Мир, 1979. – 632 с.

Статья поступила в редакцию 25.12.2002

Валерий Константинович Хохлов родился в 1941 г., окончил в 1964 г. МВТУ им. Н.Э. Баумана. Д-р техн. наук, профессор, заведующий кафедрой “Автономные информационные и управляющие системы” МГТУ им. Н.Э. Баумана. Автор 150 научных работ в области обработки сигналов в автономных информационных и управляющих системах.



V.K. Khokhlov (b. 1941) graduated from the Bauman Moscow Higher Technical School in 1964. D.Sc. (Eng.), professor, head of “Autonomous Information and Control Systems” department of the Bauman Moscow State Technical University. Author of 150 publications in the field of signal processing in autonomous information and control systems.

Юрий Юрьевич Гулин родился в 1977 г., окончил в 2001 г. МГТУ им. Н.Э. Баумана. Аспирант кафедры “Автономные информационные и управляющие системы” МГТУ им. Н.Э. Баумана. Специализируется в области распознавания акустических сигналов.



Yu.Yu. Gulin (b. 1977) graduated from the Bauman Moscow State Technical University in 2001. Post-graduate of “Autonomous Information and Control Systems” department of the Bauman Moscow State Technical University. Specializes in the field of acoustic signal identification.