

## МЕТОД АВТОМАТИЧЕСКОЙ КЛАССИФИКАЦИИ НА БАЗЕ НЕЧЕТКОГО ОТНОШЕНИЯ СХОДСТВА

**Аннотация.** Для решения задачи автоматической классификации предлагается IFC-метод нечеткой кластеризации, в котором используются новые нечеткие логические операторы — пороговые треугольные нормы и конормы. Данный метод отличается от методов кластеризации на основе нечеткого отношения эквивалентности тем, что позволяет разрабатывать более быстрые алгоритмы построения кластеров. При этом не искажаются данные о связях между элементами исследуемого множества, что обеспечивает прозрачность интерпретации результатов исследований. Приведены примеры применения метода к некоторым известным задачам.

**Ключевые слова:** нечеткий кластер, классификация, кластерный анализ.

### ВВЕДЕНИЕ

После публикации фундаментальных работ Л. Заде [1], С. Тамуры и др. [2] при решении задач автоматической классификации часто используются методы нечеткой кластеризации, составной частью которых является операция транзитивного замыкания матрицы сходства рассматриваемого множества объектов. Результат этой операции — нечеткое отношение эквивалентности. Достоинство такого подхода состоит в том, что любое задаваемое порогом множество этого отношения представляет собой совокупность непересекающихся подмножеств или классов эквивалентности. Упорядоченное множество порогов позволяет определять, как влияет величина порога на количество и состав образуемых классов эквивалентности. Такой подход или его модификации используются как в случаях прямой экспертной оценки сходства, когда двойственное отношение несходства не является метрикой (например, в задаче распознавания портретов [2, 3]), так и в тех случаях, когда исходные данные представлены в виде матрицы расстояний между объектами [4].

Однако дополнение нечеткого отношения эквивалентности является ультраметрикой, свойства которой невозможно интерпретировать в некоторых прикладных задачах [5]. Другая проблема, возникающая при использовании в нечетком кластерном анализе операции транзитивного замыкания матрицы сходства для заданных  $N$  объектов, связана с большими вычислительными затратами (порядка  $O(N^4)$ ) для вычисления нечеткого отношения эквивалентности.

В настоящей статье для решения задачи автоматической классификации используется IFC-метод (Interpretable Fuzzy Clusterization) нечеткого кластерного анализа, в котором не используется операция транзитивного замыкания. При этом результаты анализа имеют наглядную интерпретацию, а в алгоритме анализа используется существенно меньшее количество операций. В разд. 1 приводится обоснование предлагаемого IFC-метода. В разд. 2 на основе данных из [2, 4] приведены результаты практического применения IFC-метода. Для нечетких множеств символы  $\bigcup$  и  $\bigcap$  применяются для нечетких операций объединения (max) и пересечения (min) этих множеств. Символ ■ означает конец доказательства леммы или теоремы.

### 1. IFC-МЕТОД НЕЧЕТКОГО КЛАСТЕРНОГО АНАЛИЗА

Задача разбиения множества на классы, или задача автоматической классификации, неформально формулируется как задача кластеризации следующим образом [6]: сгруппировать точки заданного множества в подмножества (называ-

емые кластерами) так, чтобы подобные (сходные) точки относились к одному и тому же подмножеству, а не подобные — к различным подмножествам. Подобие (сходство) определяется как рефлексивное и симметричное бинарное отношение на  $X$ . В дальнейшем для однозначности такое бинарное отношение будем называть отношением сходства. Э. Русини показал, что при таком подходе делается попытка установления изоморфизма неизоморфных структур, и предложил новый подход к решению задачи кластеризации [6], сущность которого состоит в аксиоматическом определении исходного понятия «нечеткий кластер» на основе нечеткого отношения сходства, а также разделении процедур кластеризации и процедур формирования исходных нечетких кластеров. Кроме того, в [6] на отношение нечеткого сходства налагаются ограничения, эквивалентные случаю, когда двойственное отношение несходства является метрикой либо псевдометрикой. Задача кластеризации решается на основе такого определения нечеткого кластера, а также применения дополнительных критериев к результирующей системе нечетких подмножеств, представляющих собой результат кластеризации. В данной работе в качестве дополнительного критерия используется связность исходных нечетких кластеров.

Пусть  $\tau = \tau(x, y)$  — нечеткое отношение сходства на конечном множестве  $X$ , т.е. рефлексивное и симметричное нечеткое бинарное отношение. Пусть также  $\hat{\tau}$  — матрица, задающая нечеткое отношение  $\tau$ . Дополнение нечеткого отношения сходства  $\rho(x, y) = 1 - \tau(x, y)$ ;  $x, y \in X$ , называется нечетким отношением несходства. Это отношение симметрично и антирефлексивно.

**Определение 1.**  $C_x$ -кластером назовем нечеткое подмножество  $C_x$  множества  $X$ ,  $x \in X$ , функция принадлежности которого определяется следующим образом:  $c_x(y) = \tau(x, y)$ ,  $y \in X$ .

В матричном представлении отношения сходства значения  $c_x(y)$  — строка матрицы сходства, отражающая сходство элемента  $x \in X$  со всеми элементами  $y \in X$ .

**Определение 2.** Нечетким отношением сходства уровня  $\alpha$ ,  $\alpha \in (0, 1]$ , назовем нечеткое отношение сходства  $\tau^{(\alpha)}$ , функция принадлежности которого  $\forall x, y \in X$  удовлетворяет следующим условиям:

$$\tau^{(\alpha)}(x, y) = \begin{cases} \tau(x, y), & \text{если } \tau(x, y) \geq \alpha, \\ 0, & \text{если } \tau(x, y) < \alpha. \end{cases} \quad (1)$$

Нетрудно видеть, что  $\tau^{(\alpha)}(x, y) \leq \tau(x, y)$ , т.е.  $\tau^{(\alpha)} \subseteq \tau$ .

**Определение 3.**  $C_x^{(\alpha)}$ -кластером назовем нечеткое подмножество  $C_x^{(\alpha)}$  множества  $X$ ,  $x \in X$ ,  $\alpha \in (0, 1]$ , функция принадлежности которого определяется следующим образом:  $c_x^{(\alpha)}(y) = \tau^{(\alpha)}(x, y)$ ,  $y \in X$ .

**Определение 4.** Нечетким отношением несходства уровня  $\delta$ ,  $\delta \in [0, 1)$ , назовем нечеткое отношение несходства  $\rho^{(\delta)}$ , функция принадлежности которого  $\forall x, y \in X$  удовлетворяет условиям

$$\rho^{(\delta)}(x, y) = \begin{cases} \rho(x, y), & \text{если } \rho(x, y) \leq \delta, \\ 1, & \text{если } \rho(x, y) > \delta. \end{cases} \quad (2)$$

Очевидно, что  $\rho^{(\delta)}(x, y) \geq \rho(x, y)$ , т.е.  $\rho^{(\delta)} \supseteq \rho$ . Если  $\delta = 1 - \alpha$ , то согласно (1), (2) следует, что  $\tau^{(\alpha)}(x, y) + \rho^{(\delta)}(x, y) = 1$ .

Треугольной нормой называется функция  $T : [0, 1] \times [0, 1] \rightarrow [0, 1]$ , удовлетворяющая условиям монотонности, ассоциативности и коммутативности, а также равенствам  $T(0, 0) = 0$ ,  $T(1, u) = u$  [7]. Треугольной конормой называется функция  $S : [0, 1] \times [0, 1] \rightarrow [0, 1]$ , удовлетворяющая условиям монотонности, ассоциативности и коммутативности, а также равенствам  $S(1, 1) = 1$ ,  $S(0, u) = u$  [7].

Для двойственных треугольных норм и конорм имеет место равенство [7]

$$T(u, v) + S(1-u, 1-v) = 1. \quad (3)$$

**Определение 5.** Пороговой треугольной нормой или треугольной нормой с порогом  $\alpha$ ,  $\alpha \in (0, 1]$ , назовем функцию

$$T^{(\alpha)}(u, v) = \begin{cases} T(u, v), & \text{если } T(u, v) \geq \alpha, \\ 0, & \text{если } T(u, v) < \alpha, \end{cases} \quad (4)$$

где  $T(u, v)$  — треугольная норма.

Функция  $T^{(\alpha)}$  удовлетворяет условиям монотонности, ассоциативности и коммутативности, а также равенству  $T^{(\alpha)}(0, 0) = 0$ ; если  $u \geq \alpha$ , то  $T^{(\alpha)}(1, u) = u$ , иначе  $T^{(\alpha)}(1, u) = 0$ . Кроме того,  $T^{(\alpha)}(u, v) \leq T(u, v)$ ; если  $\alpha_1 > \alpha_2$ , то  $T^{(\alpha_1)}(u, v) \leq T^{(\alpha_2)}(u, v)$ .

**Определение 6.** Пороговой треугольной конормой или треугольной коноромой с порогом  $\delta$ ,  $\delta \in [0, 1]$ , назовем функцию

$$S^{(\delta)}(u, v) = \begin{cases} S(u, v), & \text{если } S(u, v) \leq \delta, \\ 1, & \text{если } S(u, v) > \delta, \end{cases} \quad (5)$$

где  $S(u, v)$  — треугольная конорма.

Функция  $S^{(\delta)}$  удовлетворяет условиям монотонности, ассоциативности и коммутативности, причем  $S^{(\delta)}(1, 1) = 1$ ; если  $u \leq \delta$ , то  $S^{(\delta)}(0, u) = u$ , иначе  $S^{(\delta)}(0, u) = 1$ . Очевидно, что  $S(u, v) \leq S^{(\delta)}(u, v)$ . Если  $\delta_1 > \delta_2$ , то  $S^{(\delta_1)}(u, v) \leq S^{(\delta_2)}(u, v)$ .

Нетрудно показать, что если  $T$  и  $S$  — двойственные треугольные нормы и конормы соответственно и  $\delta = 1 - \alpha$ , то пороговые треугольные норма (4) и конорма (5) также двойственные:  $T^{(\alpha)}(u, v) + S^{(\delta)}(1-u, 1-v) = 1$ .

В дальнейшем полагаем, что  $\delta = 1 - \alpha$ .

Для конормы Лукасевича [7]  $S_L(u, v) = \min_z (1, u+v)$  пороговая треугольная конорма (5) вычисляется следующим образом:

$$S_L^{(\delta)}(u, v) = \begin{cases} u+v & \text{если } u+v \leq \delta, \\ 1, & \text{если } u+v > \delta. \end{cases} \quad (6)$$

**Определение 7.** Функцию принадлежности

$$\rho(x, y) = \min_z S_L(\rho(x, z), \rho(z, y)), \quad x, y, z \in X,$$

нечеткого отношения несходства будем называть  $S_L$ -метрикой на  $X$ .

Иначе говоря,

$$S_L(\rho(x, z), \rho(z, y)) \geq S_L(\rho(x, y), \rho(y, z)) = \rho(x, y). \quad (7)$$

Симметричность и антирефлексивность функции принадлежности следует из определения отношения несходства  $\rho(x, y)$ . Обозначим функцию  $S_L(u, v)$  как  $u \oplus v$ , тогда из (7) получим аналог неравенства треугольника

$$\rho(x, z) \oplus \rho(z, y) \geq \rho(x, y). \quad (8)$$

**Теорема 1.** Пусть  $\rho(x, y)$  —  $S_L$ -метрика, тогда  $\rho^{(\delta)}(x, y)$  — метрика по пороговой треугольной конорме  $S_L^{(\delta)}$ .

**Доказательство.** Следует доказать, что если выполняется условие (8), то

$$S_L^{(\delta)}(\rho^{(\delta)}(x, z), \rho^{(\delta)}(z, y)) \geq S_L^{(\delta)}(\rho^{(\delta)}(x, y), \rho^{(\delta)}(y, z)) = \rho^{(\delta)}(x, y). \quad (9)$$

Рассмотрим возможные случаи.

1. Если  $\rho(x, z) + \rho(z, y) > \delta$ , то поскольку  $\rho(x, y) \leq \rho^{(\delta)}(x, y)$ , согласно (6)  $S_L^{(\delta)}(\rho^{(\delta)}(x, z), \rho^{(\delta)}(z, y)) = 1$ . Если  $\rho(x, y) \leq \delta$ , то  $\rho^{(\delta)}(x, y) = \rho(x, y)$  и условие (9) выполняется. Если  $\rho(x, y) > \delta$ , то  $\rho^{(\delta)}(x, y) = 1$  и условие (9) также выполняется.

2. Если  $\rho(x, z) + \rho(z, y) \leq \delta$ , то  $\rho(x, z) \leq \delta$  и  $\rho(z, y) \leq \delta$ ; согласно (8) имеем  $\rho(x, y) \leq \delta$ . Из (2) следует, что  $\rho^{(\delta)}(x, z) = \rho(x, z)$ ,  $\rho^{(\delta)}(z, y) = \rho(z, y)$ ,  $\rho^{(\delta)}(x, y) = \rho(x, y)$ , тогда  $S_L^{(\delta)}(\rho^{(\delta)}(x, z), \rho^{(\delta)}(z, y)) = S_L(\rho(x, z), \rho(z, y)) \geq \geq \rho(x, y) = \rho^{(\delta)}(x, y)$ . ■

Метрику, определяемую по пороговой треугольной конорме  $S_L^{(\delta)}$ , назовем  $S_L^{(\delta)}$ -метрикой.

Далее полагаем, что  $\rho(x, y)$  —  $S_L$ -метрика. Тогда согласно теореме 1 следует, что  $\rho^{(\delta)}(x, y)$  является  $S_L^{(\delta)}$ -метрикой.

**Определение 8.** Расстоянием на множестве нечетких кластеров  $\mathbf{C} = \{C_x | x \in X\}$  назовем функцию  $d : \mathbf{C} \times \mathbf{C} \rightarrow [0, 1]$  такую, что

$$d(C_x, C_y) = \min_z S_L(1 - c_x(z), 1 - c_y(z)), \quad x, y \in X, \quad (10)$$

где  $S_L(u, v)$  — конорма Лукасевича.

Очевидно, что функция  $d$  — симметрична и антирефлексивна. Из (10) получаем

$$S_L(1 - c_x(z), 1 - c_y(z)) \geq S_L(1 - c_x(y), 1 - c_y(y)) = 1 - c_x(y) = \rho(x, y),$$

т.е. аналог неравенства треугольника. Таким образом, расстояние между кластерами определено как расстояние между ядрами этих кластеров:  $d(C_x, C_y) = \rho(x, y)$ .

Пусть  $\xi(x) = C_x$ ,  $\xi^{-1}(C_x) = x$ ,  $x \in X$ ,  $C_x \in \mathbf{C}$ . Очевидно, что биекция  $\xi$  между метрическим пространством  $(X, \rho)$  и метрическим пространством  $(\mathbf{C}, d)$  является изометрией. Обозначим  $\mathbf{C}^{(\alpha)} = \{C_x^{(\alpha)} | x \in X\}$ . Определим биективное отображение  $\xi_\alpha : X \rightarrow \mathbf{C}^{(\alpha)}$  следующим образом:  $\xi_\alpha(x) = C_x^{(\alpha)}$   $\forall x \in X$  и обратное отображение  $\xi_\alpha^{-1}(C_x^{(\alpha)}) = x$   $\forall C_x^{(\alpha)} \in \mathbf{C}^{(\alpha)}$ .

Положим  $d(C_x^{(\alpha)}, C_y^{(\alpha)}) = \rho^{(\delta)}(x, y)$ ,  $C_x^{(\alpha)}, C_y^{(\alpha)} \in \mathbf{C}^{(\alpha)}$ , где  $\rho^{(\delta)}(x, y)$  —  $S_L^{(\delta)}$ -метрика. Тогда биекция  $\xi_\alpha$  между метрическим пространством  $(X, \rho^{(\delta)})$  и метрическим пространством  $(\mathbf{C}^{(\alpha)}, d)$  является изометрией. Таким образом, на основе введения новых нечетких логических операторов — пороговых треугольных норм и конорм — на множестве  $\mathbf{C}^{(\alpha)}$  определена метрика, т.е. расстояние между двумя произвольными кластерами  $C_x^{(\alpha)}, C_y^{(\alpha)} \in \mathbf{C}^{(\alpha)}$  равно расстоянию  $\rho^{(\delta)}(x, y)$  между ядрами этих кластеров. Задание метрики на множестве кластеров  $\mathbf{C}^{(\alpha)}$  дает новые возможности для исследования структуры множества  $X$ .

**Определение 9.** Кластеры  $C_x^{(\alpha)}, C_y^{(\alpha)} \in \mathbf{C}^{(\alpha)}$ ,  $x, y \in X$ , назовем соседними, если  $y \in \text{supp } C_x^{(\alpha)}$ ,  $x \in \text{supp } C_y^{(\alpha)}$ .

Для соседних кластеров согласно (1), (2)  $\tau^{(\alpha)}(x, y) = \tau(x, y) \geq \alpha$  и  $\rho^{(\delta)}(x, y) = \rho(x, y) \leq \delta$ . Следовательно,  $d(C_x^{(\alpha)}, C_y^{(\alpha)}) = \rho^{(\delta)}(x, y) \leq \delta$ . Если кластеры  $C_x^{(\alpha)}$ ,  $C_y^{(\alpha)}$  не являются соседними, то  $\tau^{(\alpha)}(x, y) = 0$ ,  $\rho^{(\delta)}(x, y) = 1$ ,  $d(C_x^{(\alpha)}, C_y^{(\alpha)}) = 1$ .

**Определение 10.**  $\delta$ -окрестностью кластера  $C_x^{(\alpha)}$  назовем множество кластеров  $\mathbf{O}_x = \{C_y^{(\alpha)} | y \in \text{supp } C_x^{(\alpha)}, y \neq x\}$ .

Если  $\mathbf{O}_x \neq \emptyset$ , то  $\forall C_y^{(\alpha)} \in \mathbf{O}_x$  имеем  $\rho^{(\delta)}(x, y) \leq \delta$ . Следовательно, любой из этих кластеров является соседним с кластером  $C_x^{(\alpha)}$ .

**Определение 11.** Кластеры  $C_x^{(\alpha)}, C_y^{(\alpha)} \in \mathbf{C}^{(\alpha)}$ ,  $x, y \in X$ , назовем смежными, если  $\bigcap (C_x^{(\alpha)}, C_y^{(\alpha)}) \neq \emptyset$ , а  $\rho^{(\delta)}(x, y) = 1$ .

Для смежных кластеров существует хотя бы один общий соседний кластер  $C_z^{(\alpha)}$  такой, что  $z \in \bigcap (\text{supp } C_x^{(\alpha)}, \text{supp } C_y^{(\alpha)})$ . Если  $\bigcap (C_x^{(\alpha)}, C_y^{(\alpha)}) \neq \emptyset$ , то эти кластеры либо соседние, либо смежные.

**Определение 12.** Кластеры  $C_x^{(\alpha)}, C_y^{(\alpha)} \in \mathbf{C}^{(\alpha)}$  назовем связанными, если существует такая совокупность кластеров  $C_x^{(\alpha)} = C_{z_0}^{(\alpha)}, C_{z_1}^{(\alpha)}, C_{z_2}^{(\alpha)}, \dots, C_{z_{n-1}}^{(\alpha)}, C_{z_n}^{(\alpha)} = C_y^{(\alpha)}$ , что  $\bigcap (C_{z_0}^{(\alpha)}, C_{z_1}^{(\alpha)}) \neq \emptyset, \bigcap (C_{z_1}^{(\alpha)}, C_{z_2}^{(\alpha)}) \neq \emptyset, \dots, \bigcap (C_{z_{n-1}}^{(\alpha)}, C_{z_n}^{(\alpha)}) \neq \emptyset; C_{z_i}^{(\alpha)} \in \mathbf{C}^{(\alpha)}, i \in \{0, \dots, n\}$ .

Очевидно, что соседние и смежные кластеры являются связанными. Однако связанные кластеры не являются в общем случае соседними или смежными.

**Теорема 2.** Между связанными кластерами  $C_x^{(\alpha)}, C_y^{(\alpha)} \in \mathbf{C}^{(\alpha)}$  существует путь, проходящий через соседние кластеры.

Поскольку для любых соседних кластеров  $C_x^{(\alpha)}, C_y^{(\alpha)} \in \mathbf{C}^{(\alpha)}$  имеет место  $d(C_x^{(\alpha)}, C_y^{(\alpha)}) = \rho^{(\delta)}(x, y) \leq \delta$ , то назовем такой путь  $\delta$ -связным.

**Доказательство.** Пусть  $n = 1$  (см. определение 12), тогда  $\bigcap (C_x^{(\alpha)}, C_y^{(\alpha)}) \neq \emptyset$ . Кластеры  $C_x^{(\alpha)}, C_y^{(\alpha)}$  могут быть соседними или смежными. В первом случае  $\rho^{(\delta)}(x, y) \leq \delta$ . Во втором случае существует общий соседний кластер  $C_z^{(\alpha)}$  такой, что  $C_z^{(\alpha)} \in \mathbf{O}_x$  и  $C_z^{(\alpha)} \in \mathbf{O}_y$ ,  $z \in \text{supp } C_x^{(\alpha)}, z \in \text{supp } C_y^{(\alpha)}$ . Иначе говоря,  $\rho^{(\delta)}(x, z) \leq \delta, \rho^{(\delta)}(z, y) \leq \delta$  и путь между кластерами  $C_x^{(\alpha)}, C_y^{(\alpha)}$  —  $\delta$ -связный.

Пусть кластеры  $C_x^{(\alpha)} = C_{z_0}^{(\alpha)}$  и  $C_{z_{k-1}}^{(\alpha)}$  связаны,  $C_{z_k}^{(\alpha)} = C_y^{(\alpha)}, k < n$ , тогда аналогично доказывается существование  $\delta$ -связного пути между кластерами  $C_{z_{k-1}}^{(\alpha)}$  и  $C_{z_k}^{(\alpha)}$ , т.е. кластеры  $C_x^{(\alpha)}, C_y^{(\alpha)}$  связаны. По индукции следует существование  $\delta$ -связного пути для  $k = n$ . ■

Если между двумя кластерами не существует  $\delta$ -связного пути, то эти кластеры назовем несвязанными.

**Определение 13.** Связным предклассом назовем множество кластеров  $\{C_x^{(\alpha)}\}$ , в котором любые два кластера связаны.

Другими словами, между любыми двумя элементами связного предкласса существует  $\delta$ -связный путь. Очевидно, что множество кластеров  $\mathbf{O}_x$  представляет связный предкласс.

**Определение 14.** Связным классом или  $\Delta$ -кластером назовем максимальный предкласс.

Обозначим мощность  $|X| = N$ .

**Теорема 3.** Множество  $\Delta$ -кластеров  $\Sigma = \{\Delta_j\}_{j=1}^m$ ,  $2 \leq m \leq N$ , представляет собой разбиение множества  $\mathbf{C}^{(\alpha)}$ .

**Доказательство.** Предположим, что  $\Delta$ -кластеры пересекаются, т.е.  $\bigcap (\Delta_i, \Delta_j) \neq \emptyset, i \neq j, i, j \in \{1, \dots, m\}$ . Тогда существует кластер  $C_z^{(\alpha)} \in \bigcap (\Delta_i, \Delta_j)$  и кластеры  $\Delta_i, \Delta_j$  оказываются связанными, т.е. не являются максимальными предклассами, что противоречит определению 14. Обозначим  $|\Delta_j| = k_j, j = 1, m$ .

Если  $k_j = 1$ , то кластер  $\Delta_j$  содержит только один элемент. Так как  $\forall C_x^{(\alpha)} \in \mathbf{C}^{(\alpha)}$   $\exists \Delta_j \in \Sigma$  и  $\forall \Delta_j \in \Sigma \exists C_x^{(\alpha)} \in \mathbf{C}^{(\alpha)}$ , то  $\bigcup_{j=1}^m \Delta_j = \mathbf{C}^{(\alpha)}$  и  $\sum_{j=1}^m k_j = N$ . ■

Очевидно, что при фиксированном пороге  $\alpha = 1 - \delta$  построение множества  $\Delta$ -кластеров  $\Sigma = \{\Delta_i\}_{i=1}^m$ ,  $2 \leq m \leq N$ , представляет решение задачи автоматической классификации множества объектов  $X$ . Характеристическое свойство  $\Delta$ -кластеров состоит в наличии  $\delta$ -связного пути между любыми элементами одного и того же кластера и отсутствии такого пути между элементами различных кластеров.

Опишем один из возможных вариантов алгоритма IFC-метода нечеткой кластеризации при фиксированной системе порогов. Пусть теперь  $X = \{x_i\}_{i=1}^N$  — множество объектов и задано нечеткое отношение  $\tau$ , представленное матрицей сходства  $\hat{\tau} = (\tau(x_i, x_j))_{i=1, j=1}^{N, N}$ . Находим пару объектов с минимальным значением сходства  $\alpha_{\min} > 0$  и вычисляем значения порогов  $\alpha = \{\alpha_k\}_{k=1}^p$ ;  $\alpha_1 > \dots > \alpha_k > \dots > \alpha_p$ ;  $\alpha_k = \alpha_{\min} + k(1 - \alpha_{\min}) / p$ ,  $k = 1, 2, \dots, p$ . Представим алгоритм анализа кластерной структуры множества  $X = \{x_i\}_{i=1}^N$  для фиксированного значения  $\alpha = \alpha_k$  и матрицы сходства  $\hat{\tau}$ .

1. Для значения порога  $\alpha_k$  строится множество кластеров  $\{C_{x_i}^{(\alpha_k)}\}_{i=1}^N$ .

2. Вычисляется совокупность мощностей носителей каждого кластера.

3. Определяется кластер с максимальной мощностью носителя. Если таких кластеров несколько, то берется любой из них. Далее на основе объединения носителей связанных кластеров строится множество  $\Delta$ -кластеров.

Отметим, что на этапах 2 и 3 можно вычислять мощность кластеров  $\{C_{x_i}^{(\alpha_k)}\}_{i=1}^N$ ,  $\Delta$ -кластеров и их носителей. Эта информация может быть полезной при содержательной интерпретации результатов, а также для приближенного решения задачи автоматической классификации при большом объеме исходных данных в конкретных приложениях. Вычислительная сложность алгоритма не превышает  $O(N^2)$ .

## 2. ПРИМЕРЫ ПРАКТИЧЕСКОГО ПРИМЕНЕНИЯ

На рис. 1 приведены кластеры, полученные в результате применения IFC-метода для набора точек на плоскости (см. [4, табл. 7.3]) при выборе  $\alpha = 0,6$ . Функция принадлежности нечеткого отношения сходства  $\tau$  для точек  $x_i, x_j$  вычисляется на основе нормировки евклидового расстояния  $d(x_i, x_j)$  делением на максимальное значение расстояния

$$\tau(x_i, x_j) = 1 - d(x_i, x_j) / \max_{i, j \in 1, N} d(x_i, x_j). \quad (11)$$

Этот набор данных аппроксимируется кластерами эллипсовидной формы, которые могут быть получены как известным методом Fuzzy C-Means, так и методом, содержащим операцию транзитивного замыкания [4].

На рис. 2 приведен набор данных, состоящий из 40 точек, размещенных на двух концентрических окружностях [4, табл. 7.12]. Метод Fuzzy C-Means не достигает результата для такого набора данных, поэтому в [4] для получения разбиения, состоящего из точек, лежащих на одной и той же окружности, применяется операция транзитивного замыкания. Используем функцию принадлежности нечеткого отношения сходства (11) на базе IFC-метода и получаем такое разбиение для значения  $\alpha = 0,8$ .

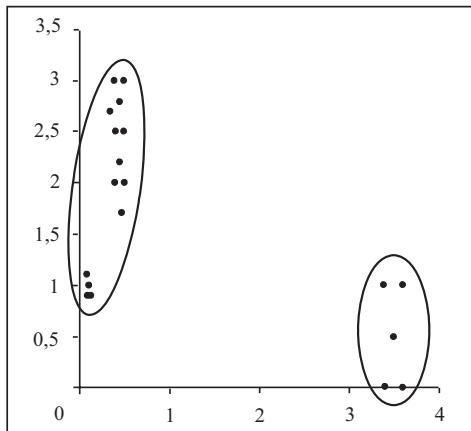


Рис. 1

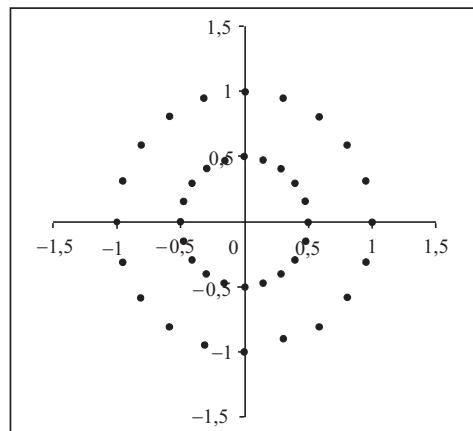


Рис. 2

**Таблица 1**

	Ch1_A	Ch1_B	Ch1_C	Gm_C	P1_B	P1_A	Ch2_B	Ch2_A	Ch2_C	P1_C	P2_B	Ch3_C	P2_A	Ch3_B	P2_C	Ch3_A
Ch1_A	1															
Ch1_B	0	1														
Ch1_C	0	0	1													
Gm_C	0	0	0,4	1												
P1_B	0	0,8	0	0	1											
P1_A	0,5	0	0,2	0,2	0	1										
Ch2_B	0	0,8	0	0	0,4	0	1									
Ch2_A	0,4	0,2	0,2	0,5	0	0,8	0	1								
Ch2_C	0	0,4	0	0,8	0,4	0,2	0,4	0	1							
P1_C	0	0	0,2	0,2	0	0	0,2	0	0,2	1						
P2_B	0	0,5	0,2	0,2	0	0	0,8	0	0,4	0,2	1					
Ch3_C	0	0	0,2	0,8	0	0	0	0	0,4	0,8	0	1				
P2_A	0,8	0	0,2	0,4	0	0,4	0	0,4	0	0	0	0	1			
Ch3_B	0	0,8	0	0,2	0,4	0	0,8	0	0,2	0,2	0,6	0	0	1		
P2_C	0	0	0,4	0,8	0	0,2	0	0	0,2	0	0	0,2	0,2	0	1	
Ch3_A	0,6	0	0	0,2	0,4	0,8	0	0,4	0	0	0	0,4	0,2	0	1	

Представим результаты использования IFC-метода в задаче распознавания портретов, принадлежащих одной и той же семье. Отметим, что эта задача существенным образом отличается от сформулированной выше неформальной постановки задачи кластеризации. Согласно неформальному определению кластеры должны содержать только сходные элементы, в то время как классы эквивалентности в задаче распознавания портретов кроме сходных содержат и несходные элементы (портреты), поскольку члены семьи могут не иметь сходства между собой. Данные по сходству 16 портретов, приведенные в табл. 1, взяты из работы [2]. Семья А состоит из двух родителей (Parent) и трех детей (Child): P1\_A, P2\_A, Ch1\_A, Ch2\_A, Ch3\_A; семья В имеет следующих представителей: P1\_B, P2\_B, Ch1\_B, Ch2\_B, Ch3\_B; в семью С входит еще и бабушка (Grandmother): P1\_C, P2\_C, Ch1\_C, Ch2\_C, Ch3\_C, Gm\_C.

В табл. 2 приведены результаты обработки данных для  $\alpha = 0,6$ . Прямоугольником выделены полученные данные для каждой отдельной семьи. Согласно табл. 2 семьи А и В распознаются безошибочно, однако в семью С не включен один ребенок (Ch1\_C), поскольку для данного порога этот элемент матрицы оказывается изолированным, т.е. не сходным с другими элементами матрицы. Такой результат классификации полностью совпадает с результатами в [2], однако при этом не используется операция транзитивного замыкания.

Поскольку IFC-метод связи между элементами не изменяет, то можно проводить дальнейшие исследования. В частности, при снижении порога нечеткий

**Таблица 2**

	P1_A	P2_A	Ch1_A	Ch2_A	Ch3_A	P1_B	P2_B	Ch1_B	Ch2_B	Ch3_B	Gm_C	P1_C	P2_C	Ch1_C	Ch2_C	Ch3_C
P1_A	1	0	0	0,8	0,8	0	0	0	0	0	0	0	0	0	0	0
P2_A	0	1	0,8	0	0	0	0	0	0	0	0	0	0	0	0	0
Ch1_A	0	0,8	1	0	0,6	0	0	0	0	0	0	0	0	0	0	0
Ch2_A	0,8	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0
Ch3_A	0,8	0	0,6	0	1	0	0	0	0	0	0	0	0	0	0	0
P1_B	0	0	0	0	0	1	0	0,8	0	0	0	0	0	0	0	0
P2_B	0	0	0	0	0	0	1	0	0,8	0,6	0	0	0	0	0	0
Ch1_B	0	0	0	0	0	0,8	0	1	0,8	0,8	0	0	0	0	0	0
Ch2_B	0	0	0	0	0	0	0,8	0,8	1	0,8	0	0	0	0	0	0
Ch3_B	0	0	0	0	0	0	0,6	0,8	0,8	1	0	0	0	0	0	0
Gm_C	0	0	0	0	0	0	0	0	0	0	1	0	0,8	0(0,4)	0,8	0,8
P1_C	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0,8
P2_C	0	0	0	0	0	0	0	0	0	0	0,8	0	1	0(0,4)	0	0
Ch1_C	0	0	0	0	0	0	0	0	0	0	0(0,4)	0	0(0,4)	1	0	0
Ch2_C	0	0	0	0	0	0	0	0	0	0	0,8	0	0	0	1	0
Ch3_C	0	0	0	0	0	0	0	0	0	0	0,8	0	0	0	0	1

клuster  $C_{Ch1\_C}^{(0,4)}$  оказывается связанным с семьей С (курсивные цифры в табл. 2).

Значит, состав всех семей определяется правильно. Такую дополнительную процедуру поиска «ближайшего» класса эквивалентности можно использовать для классификации изолированных элементов. Результат классификации оказывается более адекватным, чем при использовании операции  $\max - \min$  транзитивного замыкания [2], а полученная классификация легко интерпретируется.

## ЗАКЛЮЧЕНИЕ

Решение и интерпретация результатов предложенного подхода к автоматической классификации на основе IFC-метода базируется на введении нечетких логических операторов — пороговых треугольных норм и конорм. Данный метод отличается от методов, основанных на нечетком отношении эквивалентности, поскольку позволяет разрабатывать более быстрые алгоритмы построения классов, так как не используется операция транзитивного замыкания. Кроме того, не искаются данные о связях между элементами исходного множества, что обеспечивает прозрачность интерпретации получаемых результатов и позволяет уточнять их при дальнейших исследованиях структуры классов.

Возможное направление дальнейших исследований: вопросы адекватности результатов автоматической классификации в тех случаях, когда нечеткое отношение сходства задается на основе характеристик классифицируемых объектов, измеренных в различных количественных и качественных шкалах.

## СПИСОК ЛИТЕРАТУРЫ

1. Zadeh L. A. Similarity relations and fuzzy ordering // Information Sciences. — 1971. — 3. — P. 177–200.
2. Tamura S., Higuchi S., Tanaka K. Pattern classification based on fuzzy relations // IEEE Trans. Systems, Man and Cybernetics. — 1971. — SMC-1. — P. 61–66.
3. Yang M.-S., Shih H.-M. Cluster analysis based on fuzzy relations // Fuzzy Sets and Systems. — 2001. — 120. — P. 197–212.
4. Барсегян А.А., Куприянов М.С., Степаненко В.В. и др. Методы и модели анализа данных: OLAP и Data Mining. — СПб.: БХВ-Петербург, 2004. — 336 с.
5. Кофман А. Введение в теорию нечетких множеств. — М.: Радио и связь, 1982. — 432 с.
6. Руспини Э.Г. Последние достижения в нечетком кластер-анализе / Нечеткие множества и теория возможностей. Последние достижения. — М.: Радио и связь, 1986. — С. 114–132.
7. Нечеткие множества в моделях управления и искусственного интеллекта / Под ред. Д.А. Постполова. — М.: Наука, 1986. — 312 с.

Поступила 06.05.2015