

СИСТЕМА РАСПРЕДЕЛЕННОГО КЛАСТЕРНОГО АНАЛИЗА ОБЪЕКТОВ С ОДНОРОДНЫМИ ПРИЗНАКАМИ – МОДЕЛЬ И РЕАЛИЗАЦИЯ

V.Yanchukovsky@gmail.com

В статье описывается система распределённого кластерного анализа объектов с однородными признаками: основные требования, блоки и элементы, ее графоаналитическая и математическая модели. Математическая модель представлена в системе Пи-исчисления. Приводится ее программная реализация на языке Matlab. Для больших объемов данных предусмотрены параллельные вычисления. Представлены методы визуализации полученных результатов.

Ключевые слова: кластерный анализ, параллельные вычисления, вычислительный эксперимент, Пи-исчисление.

Введение. В последнее десятилетие, благодаря развитию сетевых технологий, наблюдается экспоненциальный рост количества доступной и обрабатываемой информации. В связи с этим относительно недавно появился термин Big Data [1], сочетающий в себе такие подходы, как кластерный анализ – многомерная статистическая процедура, выполняющая сбор данных, содержащих информацию о выборке объектов, и затем упорядочивающая объекты в сравнительно однородные группы [2], и параллельные вычисления - способ организации компьютерных вычислений, при котором программы разрабатываются как набор взаимодействующих вычислительных процессов, работающих параллельно (одновременно) [3]. Результатом совместного применения описанных выше методов является система распределенного кластерного анализа и её программная реализация.

Общее описание системы. Исходя из специфики методов кластерного анализа и параллельных вычислений сформулируем основные требования к системе:

1. Поскольку среди алгоритмов кластерного анализа нет какого-либо универсального, то, для повышения точности и эффективности, следует использовать несколько наиболее распространенных алгоритмов;

2. В случае если объем исходных данных будет значительным, для анализа результатов и восприятия их графического представления следует использовать метод понижения размерности для визуализации результатов получаемого разбиения и методы параллельных вычислений;

3. Некоторые распространенные алгоритмы требуют задавать количество кластеров как входной параметр, и в случае, когда, при предварительном анализе, пользователь не может сам оценить это количество, следует

использовать двухуровневую схему, когда на первом шаге менее точный алгоритм вычисляет количество кластеров, а более точный алгоритм на втором шаге производит окончательное разбиение;

4. Для более высокой эффективности анализа полученных результатов следует использовать несколько методов визуализации разбиений на кластеры, поскольку нет какого-либо одного универсального метода.

Исходя из всего вышеперечисленного, следует, что система будет включать следующие блоки:

- Блок алгоритмов кластерного анализа (K-means, FCM, иерархический, субтрактивный, ФОРЭЛ);
- Блок различных методов визуализации результатов в виде дендрограмм, силуэтов и графиков в координатах главных компонент;
- Блок двухуровневого кластерного анализа;
- Блок параллельных расчетов.

Для удобства формализации структуры системы и перехода к математической модели в системе пи-исчисления представим структуру в упрощенном виде как набор из основных конструкций – графоаналитически.

Пи-исчисление – математическая модель процессов, взаимосвязи которых изменяются. Основной вычислительный шаг – передача канала связи между двумя процессами; после этого получатель может использовать канал для дальнейшего взаимодействия с другими участвующими сторонами. Именно эта особенность исчисления делает его крайне удобным для моделирования систем, в которых доступные ресурсы изменяются с течением времени [4].

Примитивными сущностями пи-исчисления являются имена. Их бесконечно много, они лишены внутренней структуры. Имена записываются как символьные строки,

начинающиеся со строчной буквы: $x, y, \dots \in X$. Процесс P (выражение пи-исчисления) представляет собой одно из следующего списка [5]:

- 1) $c(x).P$ – входной префикс, получение данных x из канала c ;
- 2) $\bar{c}(y).P$ – выходной префикс, передача данных y по каналу c ;
- 3) $P \mid Q$ – параллельный запуск двух процессов;
- 4) $!P$ – репликация процесса;
- 5) $(vx)P$ – объявление канала и последующее выполнение процесса;
- 6) τ_P – внутреннее действие процесса;
- 7) 0 – пустой процесс.

На рис.1 представлена модель описанной системы в графоаналитическом виде. В данном случае все действия (задачи) представлены в виде процессов, переходы между действиями заменены на именованные потоки процесса, подсистемы заменены на блоки параллельного разделения, синхронизации и выбора, все блоки принадлежат одному из трех типов [5]:

- блок параллельного разделения, если из него выходит несколько потоков процесса;
- блок синхронизации, если в него входит несколько потоков процесса;
- блок выбора, если из него выходит несколько процессов.

Любой процесс можно представить, как набор из основных конструкций [5]. Процессы, показанные на рис. 1, могут быть представлены в терминах пи-исчисления следующим образом:

$$\begin{aligned}
 A &= !a(x).\tau_A.(\bar{b}\langle x \rangle.0 + \bar{i}\langle x \rangle.0); \\
 B &= !b(x).\tau_B.\bar{c}\langle x \rangle.0; \\
 C &= !c(x).\tau_C.\bar{d}\langle x \rangle.0; \\
 D &= !d(x).\tau_D.\bar{e}1\langle x \rangle.0; \\
 E &= e1(x).!2(x).\tau_E.\bar{f}1\langle x \rangle.0; \\
 F &= (!f1(x) \mid f2(x)).\tau_F.\bar{g}\langle x \rangle.0; \\
 G &= !g(x).\tau_G.\bar{h}\langle x \rangle.0; \\
 H &= !h(x).\tau_H.(\bar{a}\langle x \rangle.0 + 0); \\
 I &= !i(x).\tau_I.(\bar{d}2\langle x \rangle.0 + \bar{e}2\langle x \rangle.0 + \bar{f}2\langle x \rangle.0);
 \end{aligned}
 \tag{1}$$

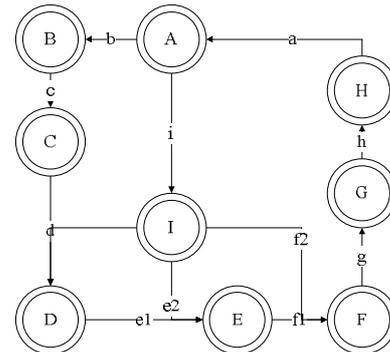


Рис. 1. Упрощенный вид структуры системы, где А – пользователь, В – смежная система формирования исходных данных, С – входные данные, D – блок параллельных вычислений, E – блок расчета, F – блок визуализации, G – выходные данные, H – процесс анализа данных, I – смежная система формирования управляющих параметров

Таким образом, вся модель системы может быть описана в виде следующих ниже выражений:

$$P = A \mid (B \mid C \mid I) \mid D \mid E \mid F \mid G \mid H \mid (A + 0)
 \tag{2}$$

Или, подставляя соответствующие выражения:

$$\begin{aligned}
 P &= !a(x).\tau_A.(\bar{b}\langle x \rangle.0 + \bar{i}\langle x \rangle.0) \mid (!b(x).\tau_B.\bar{c}\langle x \rangle.0 \mid \\
 & !c(x).\tau_C.\bar{d}\langle x \rangle.0 + !i(x).\tau_I.(\bar{d}2\langle x \rangle.0 + \bar{e}2\langle x \rangle.0 + \bar{f}2\langle x \rangle.0)) \mid \\
 & !d(x).\tau_D.\bar{e}1\langle x \rangle.0 \mid e1(x).!2(x).\tau_E.\bar{f}1\langle x \rangle.0 \mid (!f1(x) \mid f2(x)).\tau_F.\bar{g}\langle x \rangle.0 \mid \\
 & !g(x).\tau_G.\bar{h}\langle x \rangle.0 \mid (!a(x).\tau_A.(\bar{b}\langle x \rangle.0 + \bar{i}\langle x \rangle.0) + 0)
 \end{aligned}
 \tag{3}$$

В качестве элемента модели будем рассматривать процесс – совокупность взаимосвязанных действий, преобразующих входящие данные в исходящие.

Все элементы системы имеют общую концептуальную модель (рис. 2), за исключением двухуровневого элемента, который представляет собой синтез двух алгоритмов (рис. 3).

Представим данную модель в терминах пи-исчисления:

$$\begin{aligned}
 A &= !a(x).\tau_A.\bar{b}\langle x \rangle.0; \\
 B &= !b(x).\tau_B.\bar{c}\langle x \rangle.0; \\
 C &= !c(x).\tau_C.\bar{d}\langle x \rangle.0; \\
 D &= !d(x).\tau_D.\bar{a}\langle x \rangle.0;
 \end{aligned}
 \tag{4}$$

Таким образом, данный элемент может быть записан в виде:

$$P = A \mid B \mid C \mid D \mid (A + 0)
 \tag{5}$$

$$P = !a(x).\tau_A.\bar{b}\langle x \rangle.0 \mid !b(x).\tau_B.\bar{c}\langle x \rangle.0 \mid !c(x).\tau_C.\bar{d}\langle x \rangle.0 \mid !d(x).\tau_D.\bar{a}\langle x \rangle.0 \mid (!a(x).\tau_A.\bar{b}\langle x \rangle.0 + 0) \tag{6}$$

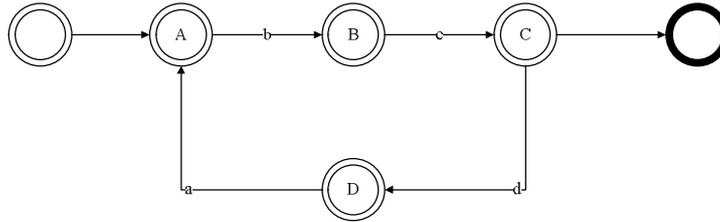


Рис. 2. Концептуальная модель элемента Системы распределенного кластерного анализа, где А – процесс изменения, В – процесс кластерного анализа, С - визуализация, D – блок принятия решений

Поскольку двухуровневый элемент состоит из двух процессов, упрощенная графоаналитическая модель примет следующий вид (рис. 4):

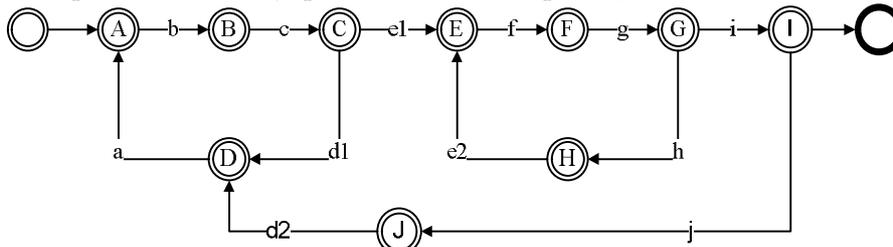


Рис. 3. Упрощенная графоаналитическая модель двухуровневого элемента, где А – процесс изменения, В – субтрактивный процесс, С - входные данные, D – блок обратной связи, Е – процесс изменения, F – процесс k-means, G- выходные данные, H – блок обратной связи, I – блок визуализации, J – пользователь

Представим модель в терминах пи-исчисления:

$$\begin{aligned} A &= !a(x).\tau_A.\bar{b}\langle x \rangle.0; \\ B &= !b(x).\tau_B.\bar{c}\langle x \rangle.0; \\ C &= !c(x).\tau_C.(\bar{d}1\langle x \rangle.0 + \bar{e}1\langle x \rangle.0); \\ D &= d1(x).!d2(x)\tau_D.\bar{a}\langle x \rangle.0; \\ E &= e1(x).!e2(x)\tau_E.\bar{f}\langle x \rangle.0; \\ F &= !f(x).\tau_F.\bar{g}\langle x \rangle.0; \\ G &= !g(x).\tau_G.(\bar{i}\langle x \rangle.0 + \bar{h}\langle x \rangle.0); \\ H &= !h(x).\tau_H.\bar{e}2\langle x \rangle.0; \\ I &= !i(x).\tau_I.\bar{j}\langle x \rangle.0; \\ J &= !j(x).\tau_J.\bar{d}2\langle x \rangle.0; \end{aligned} \tag{7}$$

Таким образом, данный элемент может быть записан в виде:

$$P = A \mid B \mid C \mid ((D + 0) + E) \mid F \mid G \mid (H \mid (E + 0) + I) \mid J \mid (D + 0) \tag{8}$$

или:

$$\begin{aligned} P &= !a(x).\tau_A.\bar{b}\langle x \rangle.0 \mid !b(x).\tau_B.\bar{c}\langle x \rangle.0 \mid !c(x).\tau_C.(\bar{d}1\langle x \rangle.0 + \bar{e}1\langle x \rangle.0) \mid \\ &((d1(x).!d2(x)\tau_D.\bar{a}\langle x \rangle.0 + 0) + e1(x).!e2(x)\tau_E.\bar{f}\langle x \rangle.0) \mid \\ &!f(x).\tau_F.\bar{g}\langle x \rangle.0 \mid !g(x).\tau_G.(\bar{i}\langle x \rangle.0 + \bar{h}\langle x \rangle.0) \mid (!h(x).\tau_H.\bar{e}2\langle x \rangle.0) \mid \\ &(e1(x).!e2(x)\tau_E.\bar{f}\langle x \rangle.0 + 0) + !i(x).\tau_I.\bar{j}\langle x \rangle.0) \mid \\ &!j(x).\tau_J.\bar{d}2\langle x \rangle.0 \mid (d1(x).!d2(x)\tau_D.\bar{a}\langle x \rangle.0 + 0) \end{aligned} \tag{9}$$

Графоаналитическая модель блока представлена в следующем виде (рис.4): параллельных вычислений может быть

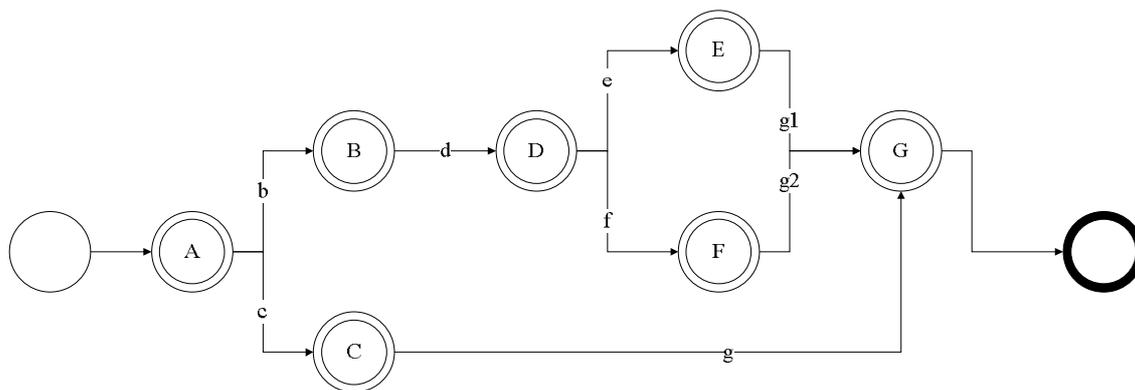


Рис.4. Графоаналитическая модель блока параллельных вычислений, где А – смежная система формирования исходных данных, В – процесс запуска параллельного режима, С – исходные данные, D – процесс разбиения данных на параллельные процессы, E,F – параллельные процессы, G – блок визуализации

Представим эту модель в терминах пи-исчисления:

$$\begin{aligned}
 A &= a(x).\tau_A.(\bar{b}\langle x \rangle.0 + \bar{c}\langle x \rangle.0); \\
 B &= b(x).\tau_B.\bar{d}\langle x \rangle.0; \\
 C &= c(x).\tau_C.\bar{g}\langle x \rangle.0; \\
 D &= d(x).\tau_D.(\bar{e}\langle x \rangle.0 | \bar{f}\langle x \rangle.0); \\
 G &= g(x).(!g1(x) | g2(x)).\tau_G.0; \\
 E &= !e(x).\tau_E.\bar{g}1\langle x \rangle.0; \\
 F &= !f(x).\tau_F.\bar{g}2\langle x \rangle.0;
 \end{aligned}
 \tag{10}$$

Таким образом, данный элемент может быть записан в виде:

$$P = A | (B + C) | D | (E | F) | (G + 0)
 \tag{11}$$

Или:

$$\begin{aligned}
 P &= a(x).\tau_A.(\bar{b}\langle x \rangle.0 + \bar{c}\langle x \rangle.0) | d(x).\tau_D.(\bar{e}\langle x \rangle.0 | \bar{f}\langle x \rangle.0) | \\
 &(!e(x).\tau_E.\bar{g}1\langle x \rangle.0 | !f(x).\tau_F.\bar{g}2\langle x \rangle.0) | (g(x).(!g1(x) | g2(x)).\tau_G.0 + 0)
 \end{aligned}
 \tag{12}$$

На основе разработанных моделей системы распределенного кластерного анализа представим следующую общую структуру (рис.5).

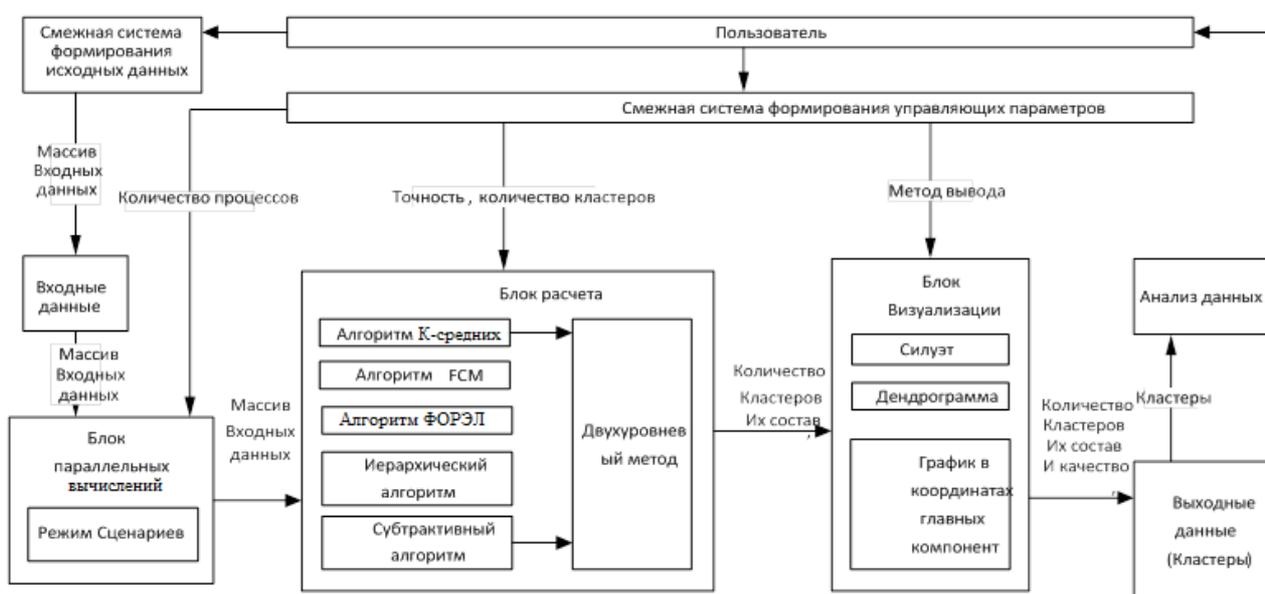


Рис. 5. Структура системы распределенного кластерного анализа

Все блоки служат для достижения общей цели системы. Цель блока распараллеливания - ускорение получения выходных данных системы. Цель блока расчёта – формирование выходных кластеров. В зависимости от выбранного метода достигается необходимая точность в определенной предметной области. Цель блока визуализации – представление выходных данных в удобной для пользователя форме. Для этого используется несколько различных методов, в совокупности позволяющих предоставить наиболее полную информацию о полученных результатах.

В блоке визуализации использованы следующие методы визуализации:

- График на основе главных компонент.
- График силуэтов кластеров.
- График дендрограмм.

Их возможности по визуализации отображены в табл. 1.

Таблица 1

Блок визуализации

График	Качество	Состав	Количество
Дендрограмма	+	+	-
График Силуэта	+	-	+
График главных компонент	-	+	+

Основные методы визуализации, используемые в системе распределенного кластерного анализа, такие как дендрограмма и силуэты, дают неполное представление о получаемых классах. Силуэты позволяют оценить качество кластеров, но не их состав[6]. Дендрограмма в свою очередь представляет собой дерево, то есть граф без циклов, построенный по матрице мер близости, и позволяет изобразить взаимные связи между объектами из заданного множества[7]. Помимо этого, в случае, когда объекты кластеризации имеют более двух признаков, для удобства восприятия и визуализации необходимо понижать размерность данных. С этой целью реализован метод главных компонент[8] и визуализация кластеров, полученных в результате его применения[9].

Программная реализация. На основе разработанной формальной модели системы распределенного кластерного анализа, в среде MATLAB разработан программный комплекс[10]. В системе MATLAB созданы основные формы графического приложения, представленные на рис.6:

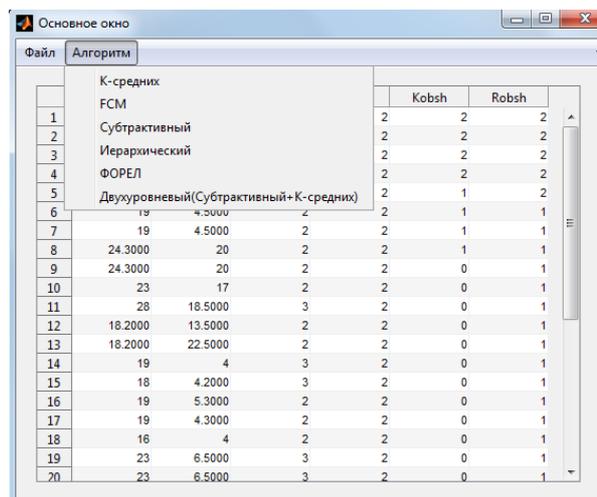


Рис. 6. Главная форма программного комплекса кластерного анализа

Параллельные вычисления в программном комплексе для встроенных алгоритмов реализованы на основе сценариев – последовательного набора команд встроенного языка программирования MATLAB, записанных в специализированном исполняемом файле сценариев – m-файле.

Для параллельной версии алгоритма ФОРЭЛ[11], ввиду того, что он генерирует разное число классов в разных задачах, выбран режим `spmd` («одна программа — много данных») [12]. Параллельная версия двухуровневого метода кластерного анализа реализована в режиме `parfor` (параллельный цикл `for`). Такой выбор обусловлен тем, что позволяет минимизировать изменения, вносимые в последовательный вариант программы.

Для иерархического кластерного анализа удобным средством визуализации результатов является функция `dendrogram`, которая выводит дерево дендрограммы (рис.5). Для всех использованных автором методов кластерного анализа можно посчитать величину силуэта и вывести его график (рис.7).

Для удобства визуализации результатов кластеризации в координатах главных компонент используется встроенная в MATLAB функция `gscatter`. Она реализует график рассеяния двух переменных – двух главных компонент, образующих двумерную систему координат, сгруппированных по значениям третьей переменной – массиву номеров классов, которым принадлежат объекты исходной выборки в соответствии с тем или иным алгоритмом (рис. 8).

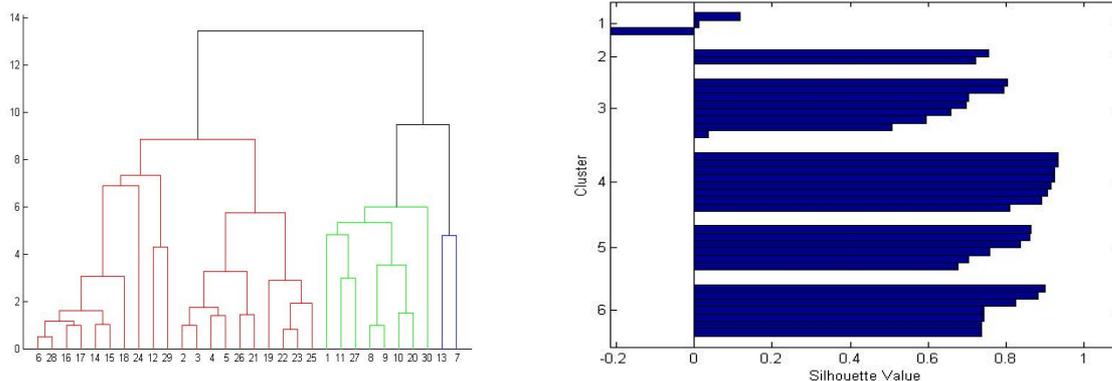


Рис. 7. График дендрограммы и график силуэтов кластеров

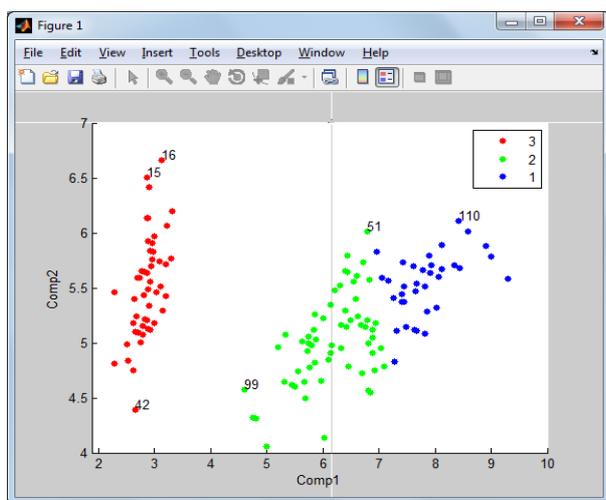


Рис. 8. Визуализация результатов с использованием главных компонент

Заключение. Представленная формальная модель и программная реализация системы распределенного кластерного анализа была апробирована на группе изделий машиностроительного производства – комплексных деталях [13, 14] и наблюдениям по концентрациям некоторых газов в атмосфере за несколько лет – результатам трехлетнего мониторинга содержания газов SO_2 и CO в воздушной атмосфере центрального района г. Санкт-Петербурга [15].

Результаты работы характеризуют разработанную систему как универсальную систему кластерного анализа, которая может быть использована во многих отраслях.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Черняк Леонид. Большие Данные – новая теория и практика (рус.) // Открытые системы. СУБД. М.: Открытые системы, 2011. № 10. С.18–26.
2. Айвазян С. А., Бухштабер В. М., Енюков И. С., Мешалкин Л. Д. Прикладная статистика: Классификация и снижение размерности. М.: Финансы и статистика, 1989. 607 с.

3. Воеводин В. В., Воеводин Вл. В. Параллельные вычисления. СПб: БХВ-Петербург, 2002. 608 с.
4. Milner R. Communicating and Mobile Systems: the π -Calculus. Cambridge University Press. 1999, 159 p.
5. Parrow J. An Introduction to the π -Calculus, chapter 8, pages 479–543. Handbook of Process Algebra. Elsevier, 2001.
6. Rouseeuw P. J. Silhouettes: a graphical aid to the interpretation and validation of cluster analysis. // Journal of Computational and Applied Mathematics. Vol. 20. №. 1. 1987. Pp. 53–65.
7. Жамбю М. Иерархический кластер-анализ и соответствия. М.: Финансы и статистика, 1988. 345 с.
8. Jolliffe I.T. Principal Component Analysis, Series: Springer Series in Statistics, 2nd ed., Springer, NY, 2002. №XXIX, 487 p. 28 .
9. Зиновьев А. Ю., Визуализация многомерных данных, Красноярск // Изд. КГТУ, 2000. 180 с.
10. Янчуковский В.Н., Сосинская С.С. Программный комплекс «Система распределенного кластерного анализа», свидетельство о регистрации в реестре программ для ЭВМ №2016615937 от 02 июня 2016 г.
11. Загоруйко Н.Г. Прикладные методы анализа данных и знаний. // Новосибирск: Издательство Института математики, 1999. 270 с.
12. Parallel Computing Toolbox™ 5 User's Guide // The MathWorks, Inc. Natick, 2007, 730 p.
13. Соколовский А. П. «Автоматизация технологических процессов механической обработки металлов», Автомат. и телемех., 1938, № 3. С.117–139.
14. Митрофанов С.П. Научная организация машиностроительного производства. 2-е изд., доп. и перераб. Л. : Машиностроение, 1976. 712 с.

15. Янчуковский В.Н., Сосинская С.С., Козловский А.С., Челибанов В.П. MATLAB с применением параллельных вычислений // Вестник БГТУ им. В.Г. Шухова. Двухуровневый кластерный анализ в среде Шухова. №5. 2014. С. 201–205.

Yanchukovskiy V.N.

MODEL AND IMPLEMENTATION OF HOMOGENEOUS ATTRIBUTES OBJECTS DISTRIBUTED CLUSTER ANALYSIS SYSTEM

Homogeneous attributes objects distributed cluster analysis system described: basic requirements, blocks and elements, its graphoanalytical and mathematical models. The mathematical model is represented in the Pi-calculus. Its software implementation in Matlab is given. In case of big data, parallel computing is provided. Methods for visualizing the results are presented.

Key words: *cluster analysis, parallel computing, computational experiment, PI-calculus.*

Янчуковский Владислав Николаевич, старший преподаватель кафедры вычислительной техники.

Иркутский национальный исследовательский технический университет

Адрес: Россия, 664074, г. Иркутск, ул. Лермонтова 83.

E-mail: V.Yanchukovsky@gmail.com