

Модели и задачи Data Mining

- Data Mining – совокупность большого числа различных методов обнаружения знаний.
- В современной бизнес-аналитике принято выделять в Data Mining описательные (дескриптивные) и предсказательные модели.

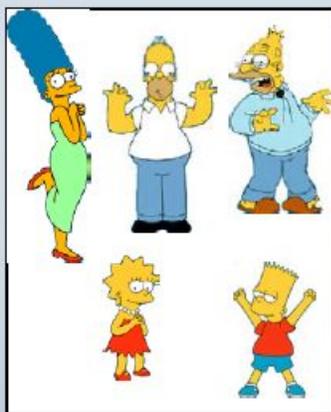


Кластерный анализ

1. **Кластерный анализ** предназначен для разбиения данных на поддающиеся интерпретации группы (1), таким образом, чтобы элементы, входящие в одну группу были максимально «схожи» (2), а элементы из разных групп были максимально «отличными» друг от друга (3).
2. **Кластерный анализ** – группа методов, используемых для классификации объектов или событий в относительно гомогенные (однородные) группы, которые называют кластерами (clusters).
3. Цель **кластеризации** - поиск существующих структур.

Задачи и методы кластер - анализа

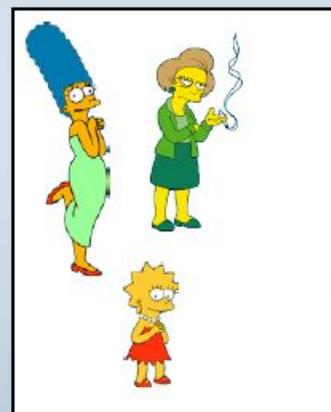
Кластеризация – это разбиение элементов некоторого множества на группы на основе их схожести. Задача кластеризации состоит в разбиении объектов из X на несколько подмножеств (кластеров), в которых объекты более схожи между собой, чем с объектами из других кластеров.



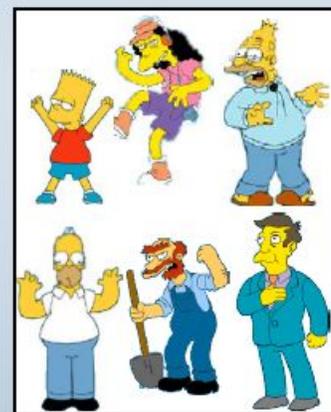
Семья



Сотрудники



Женщины



Мужчины

Лейблинг групп – то что нужно найти

Кластеризация достаточно субъективна и зависит от цели пользователя

- В **факторном анализе** группируются столбцы, т.е. цель – анализ структуры множества признаков и выявление обобщенных факторов.
- В **кластерном анализе** – группируются строки, т.е. цель – анализ структуры множества объектов.
- **Кластерный анализ** выполняет классификацию объектов.
- Каждый **объект** (респондент) – точка в **пространстве признаков**.
- Задача **кластерного анализа** – выделение «сгущений» точек, разбиение совокупности на однородные подмножества объектов (сегментация).

Кластерный анализ в теории



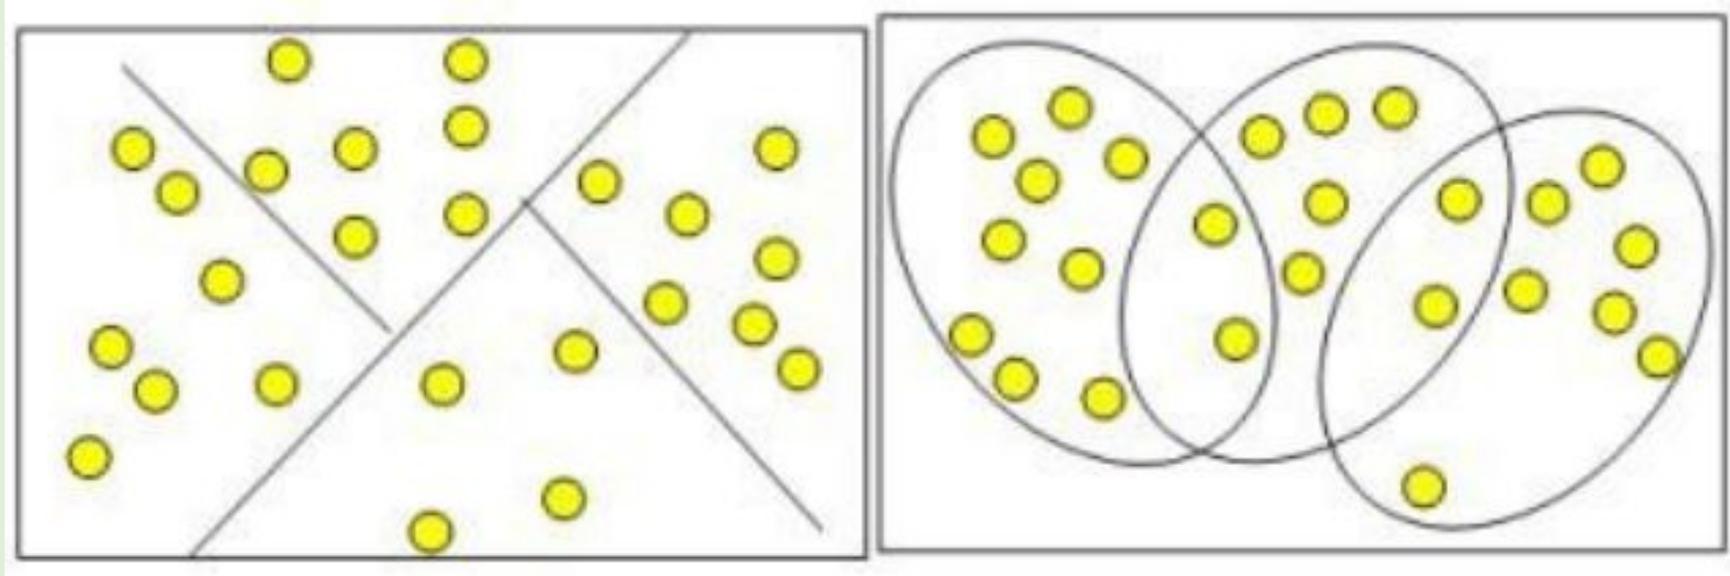
Кластерный анализ на практике

Как очертить границу кластеров?
Сколько их следует выделить?

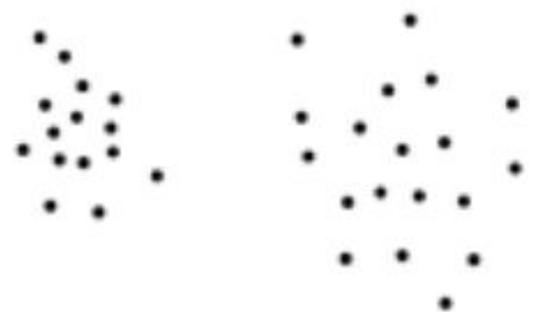


Типы кластерных структур

- Кластеры могут быть непересекающимися (non-overlapping), и пересекающимися (overlapping).



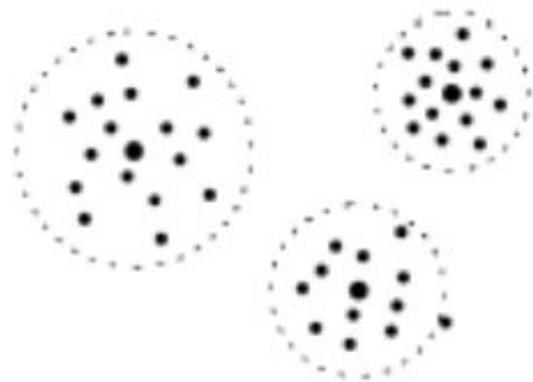
- Могут быть получены кластеры различной формы: длинными "цепочками", удлиненной формы, произвольной формы.
- Могут быть созданы кластеры определенных размеров (например, малых или крупных).



внутрикластерные расстояния, как правило,
меньше межкластерных



ленточные кластеры



кластеры с центром



кластеры могут соединяться перемычками



кластеры могут накладываться на разреженный фон из редко расположенных объектов



кластеры могут перекрываться



кластеры могут образовываться не по сходству, а по иным типам регулярностей



кластеры могут вообще отсутствовать

- Каждый метод кластеризации имеет свои ограничения и выделяет кластеры лишь некоторых типов.
- Понятие “тип кластерной структуры” зависит от метода и также не имеет формального определения.



Выделяют четыре основных метода анализа Big Data [1]:

- **Описательная аналитика (descriptive analytics)** — отвечает на вопрос «Что происходит?», анализирует данные, поступающие в реальном времени, и исторические данные.
- **Прогнозная или предикативная аналитика (predictive analytics)** — помогает спрогнозировать наиболее вероятное развитие событий на основе имеющихся данных.
- **Предписательная аналитика (prescriptive analytics)** — позволяет выявить проблемные точки в любой деятельности и рассчитать, при каком сценарии их можно избежать их в будущем.
- **Диагностическая аналитика (diagnostic analytics)** — помогает выявлять аномалии и случайные связи между событиями и действиями.

[1. Виды аналитики: описательная, прогнозная, предписывающая аналитика](#)

(projectpro.io)

Диагностическая аналитика

- **Диагностическая (diagnostic) аналитика** — форма расширенной аналитики, которая строится на основе описательной и анализирует данные для ответа на вопрос «Почему это произошло?», т.е. позволяет выявить факторы, оказывающие влияние на целевые параметры.
- **Диагностическая аналитика** позволяет изучить проблемы, определить слабые места и выявить цепочки событий.
- Методы **диагностической аналитики** в Loginom:
 - EM Кластеризация.
 - Кластеризация k-means, кластеризация g-means.
 - Кластеризация транзакций.

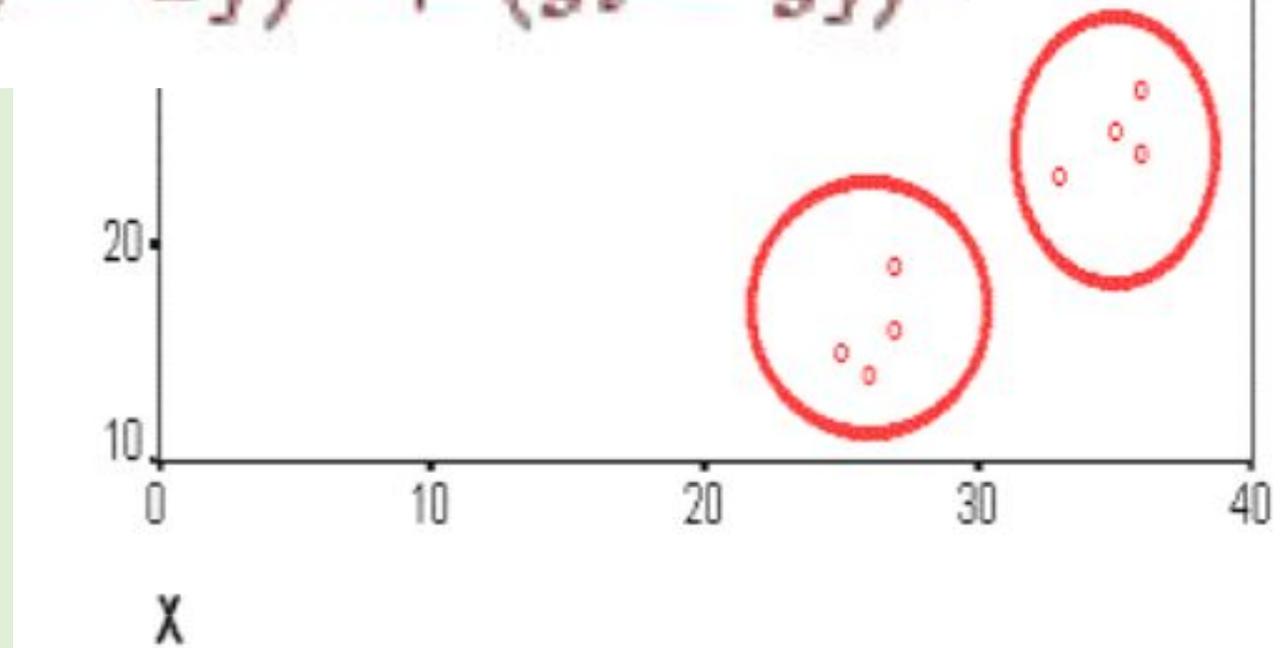
Меры сходства

- **Евклидово расстояние**: $\text{расстояние}(x, y) = \{\sum_i (x_i - y_i)^2\}^{1/2}$
- **Квадрат евклидова расстояния** чтобы придать большие веса более отдаленным друг от друга объектам $\text{расстояние}(x, y) = \sum_i (x_i - y_i)^2$
- **Манхэттенское расстояние** "хэмминговое" $\text{расстояние}(x, y) = \sum_i |x_i - y_i|$
- **Расстояние Чебышева** используют когда необходимо определить два объекта как "различные", если они отличаются по какому-то одному измерению: $\text{расстояние}(x, y) = \text{Максимум } |x_i - y_i|$
- **Степенное расстояние** для увеличения или уменьшения веса объектов при сильном отличии: $\text{расстояние}(x, y) = (\sum_i |x_i - y_i|^p)^{1/r}$
- **Процент несогласия** - расстояние вычисляется, если данные являются категориальными: $\text{расстояние}(x, y) = (\text{Количество } x_i \neq y_i) / i$

Номер	Признак X	Признак Y
1	27	19
2	11	46
3	4	7
4	25	15
5	36	27
6	35	25
7	10	43
8	11	44
9	36	24
10	26	14
11	9	45
12	33	23
13	27	16
14	10	4



$$D_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}$$



Мера близости вычисленная как **евклидово расстояние** между

- Когда осей (измерений) больше, чем две, расстояние рассчитывается как: сумма квадратов разницы координат из стольких слагаемых, сколько осей (измерений) присутствует.

$$D = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2 + (z_1 - z_2)^2}$$

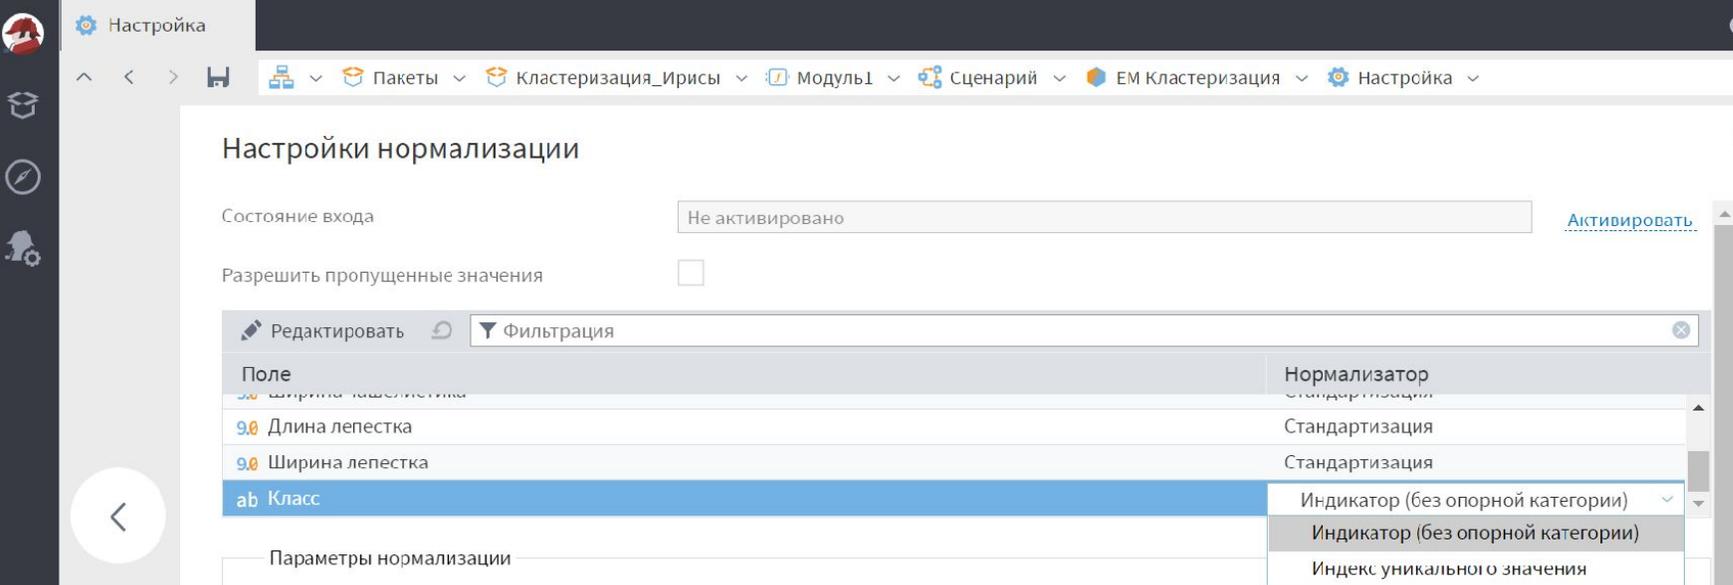
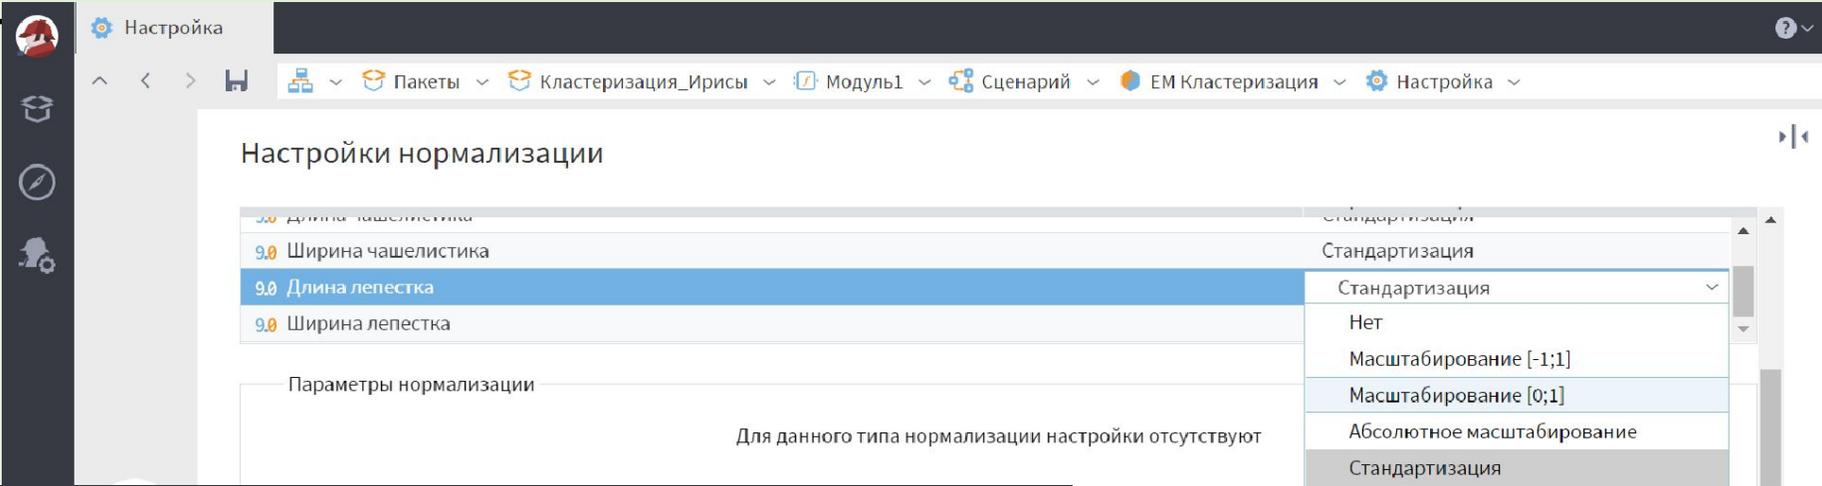
Кластер имеет следующие математические характеристики:

- центр,
- радиус,
- среднеквадратическое отклонение,
- размер кластера.

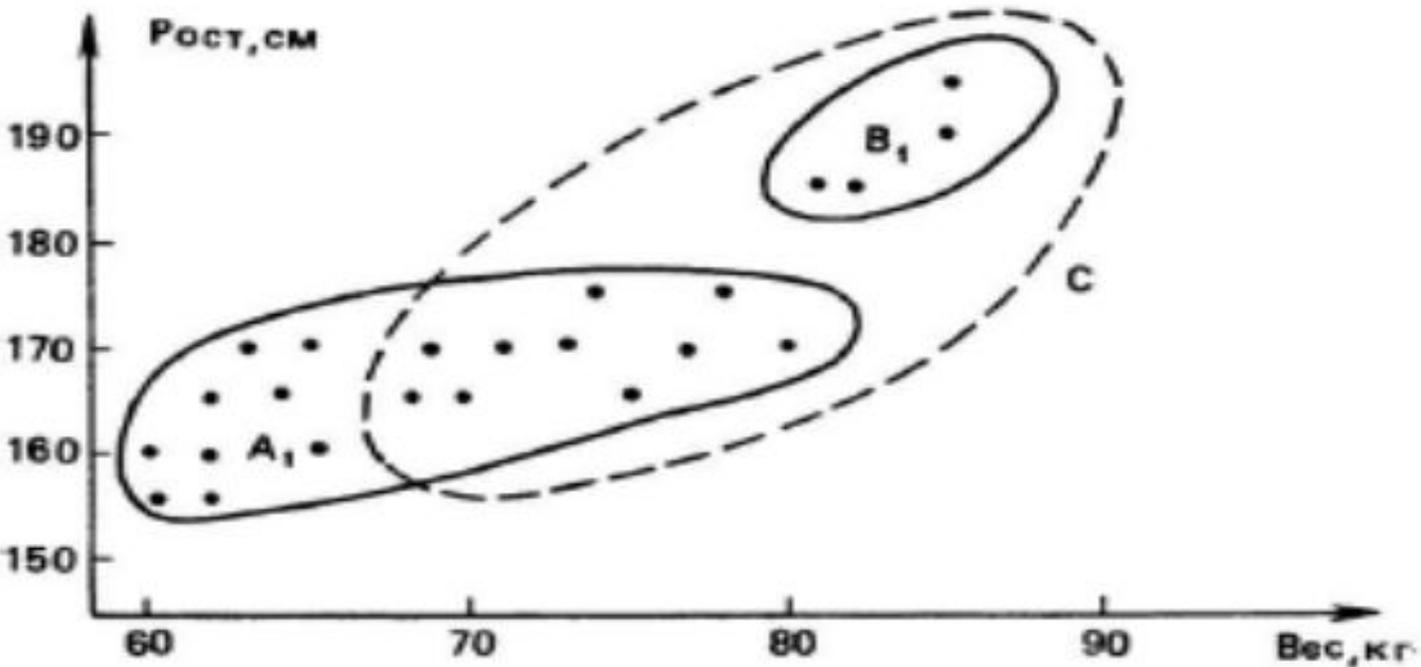
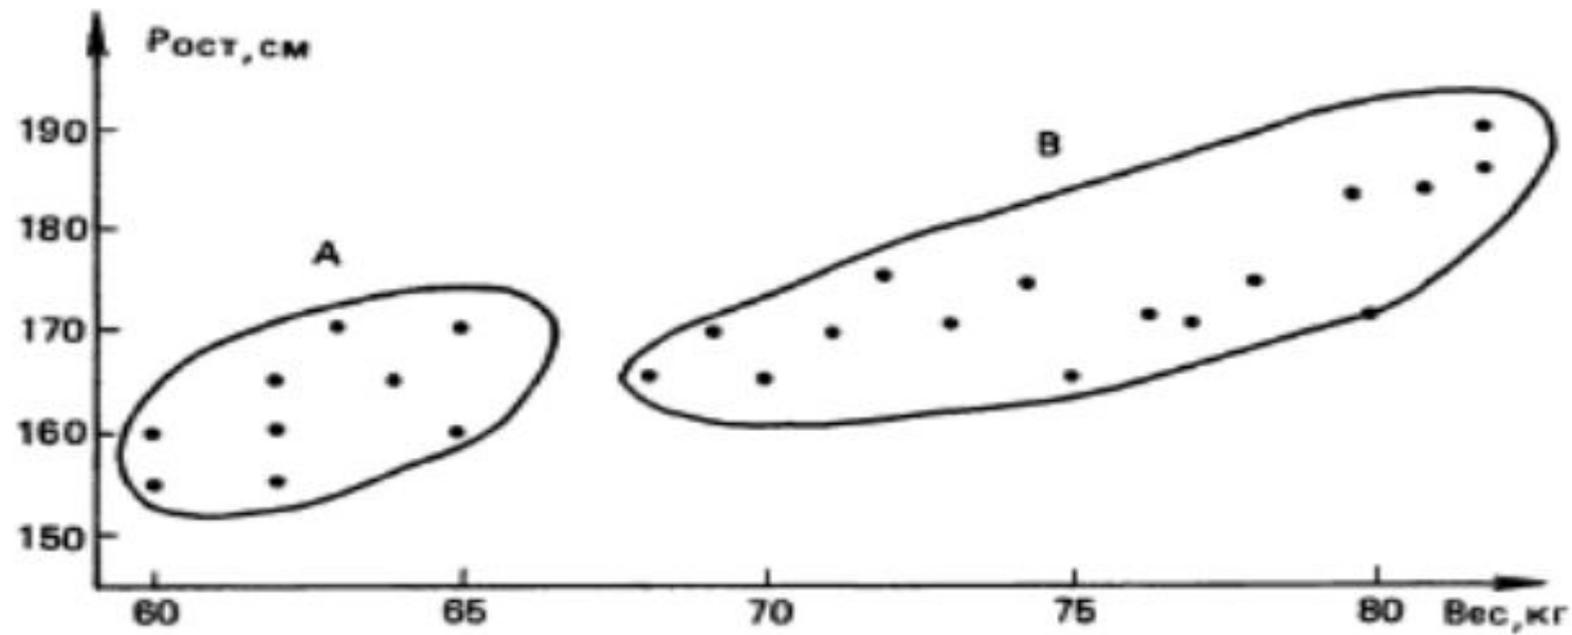
Центр кластера - это среднее геометрическое место точек в пространстве переменных.

Радиус кластера - максимальное расстояние точек от центра кластера.

При неоднородности единиц измерения признаков становится невозможно корректно рассчитать расстояния между точками. Существуют различные **способы нормирования исходных данных**, например: деление исходных данных на среднеквадратичное отклонение соотве



Результат зависит от нормировки признаков

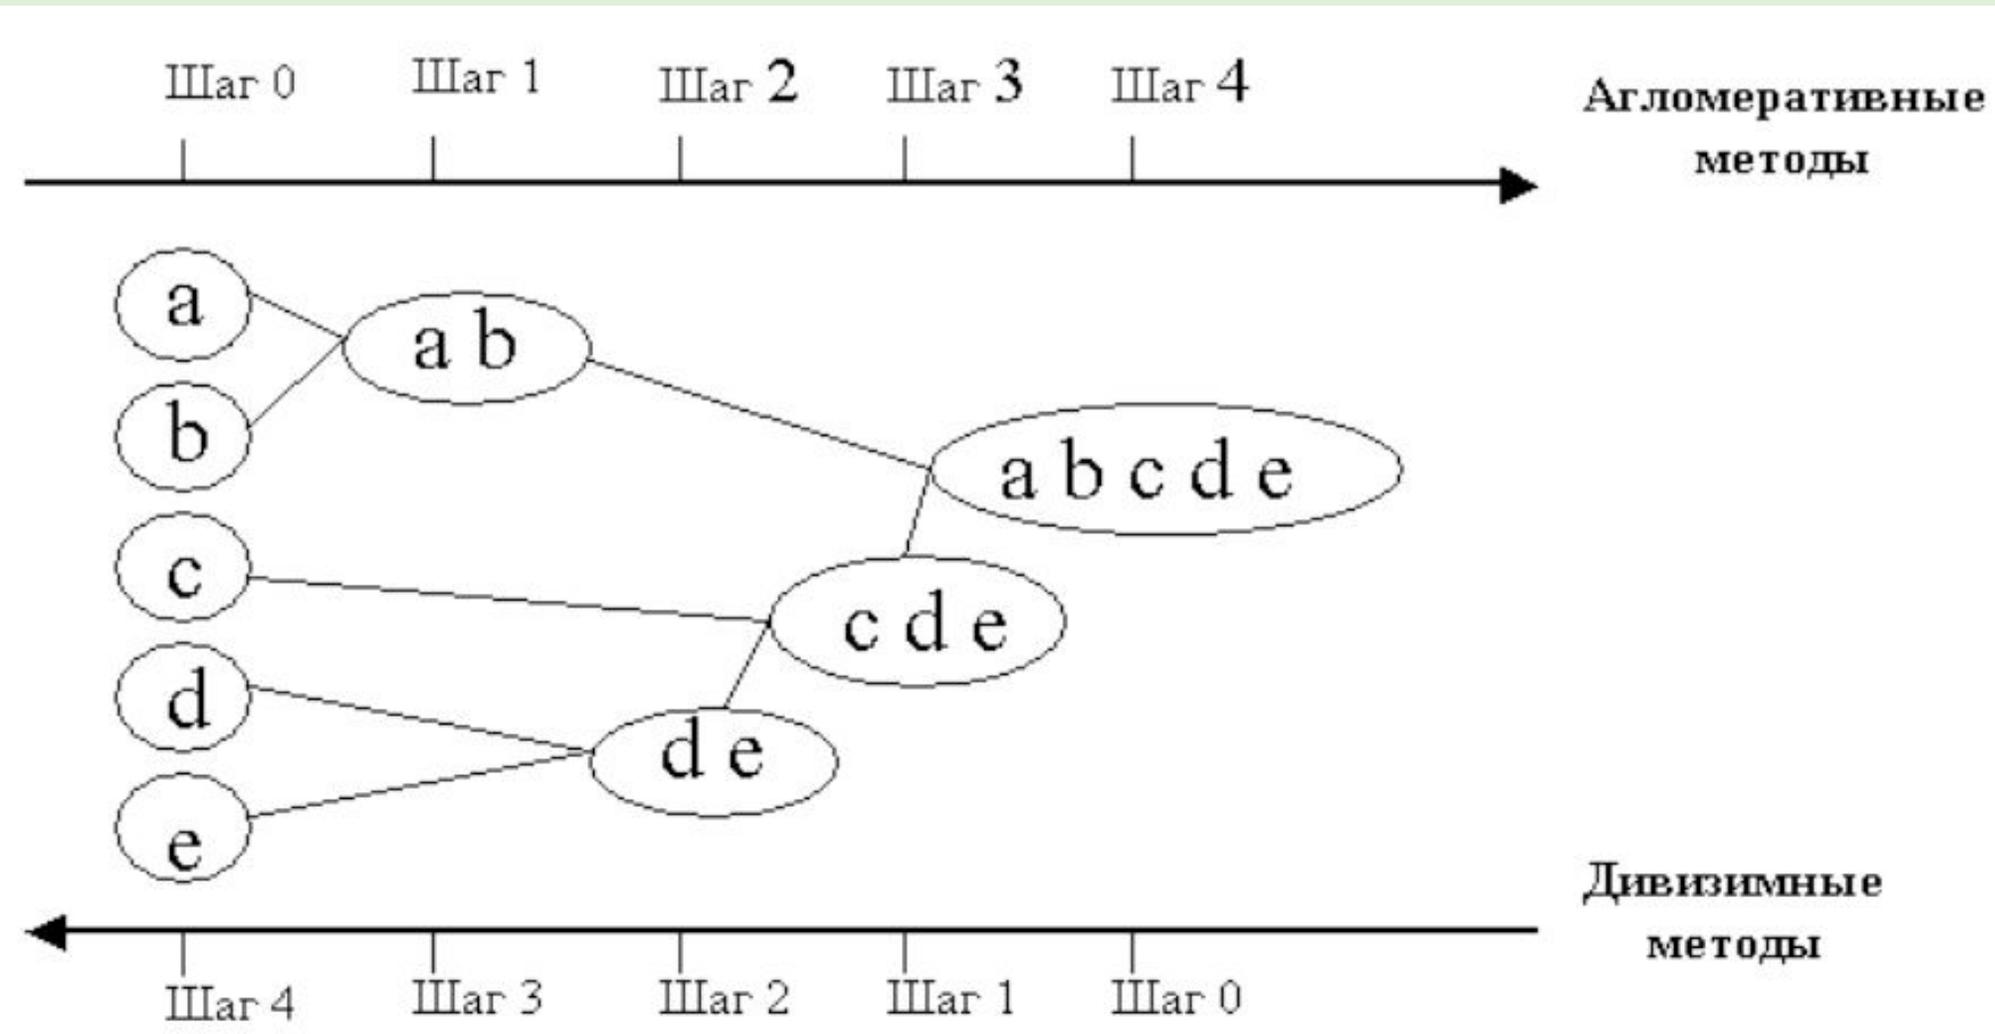


Расстояние между кластерами

- **Метод ближнего соседа.** Расстояние между двумя кластерами определяется расстоянием между двумя наиболее близкими объектами (ближайшими соседями) в различных кластерах.
- Метод наиболее **удаленных соседей** или полная связь.
- **Метод Варда** (Ward's method). В качестве расстояния между кластерами берется прирост суммы квадратов расстояний объектов до центров кластеров, получаемый в результате их объединения. Этот метод направлен на объединение близко расположенных кластеров и "стремится" создавать кластеры малого размера.
- **Метод невзвешенного попарного арифметического среднего.** В качестве расстояния между двумя кластерами берется среднее расстояние между всеми парами объектов в них.

Методы кластеризации: иерархические

Суть иерархической кластеризации состоит в последовательном объединении меньших кластеров в большие или разделении больших кластеров на меньшие.

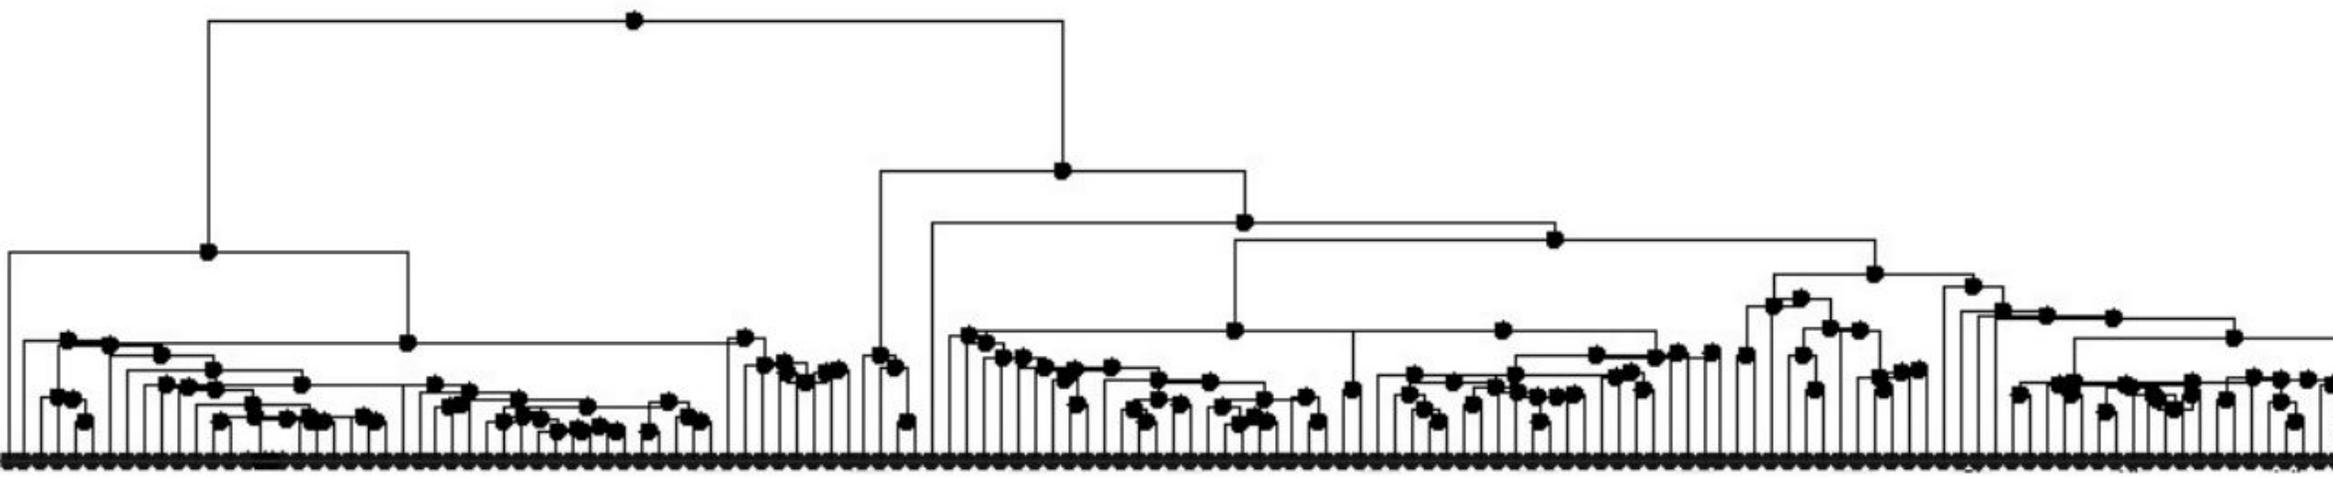


- **Иерархические методы кластерного анализа** используются при небольших объемах наборов данных.
- Преимуществом иерархических методов кластеризации является их **наглядность**.
- Иерархические алгоритмы связаны с построением **дендрограмм**, которые являются результатом иерархического кластерного анализа.
- **Дендрограмма** описывает близость отдельных точек и кластеров друг к другу, представляет в графическом виде последовательность объединения (разделения) кластеров.
- **Дендрограмму** также называют древовидной схемой, деревом объединения кластеров, деревом иерархической структуры.

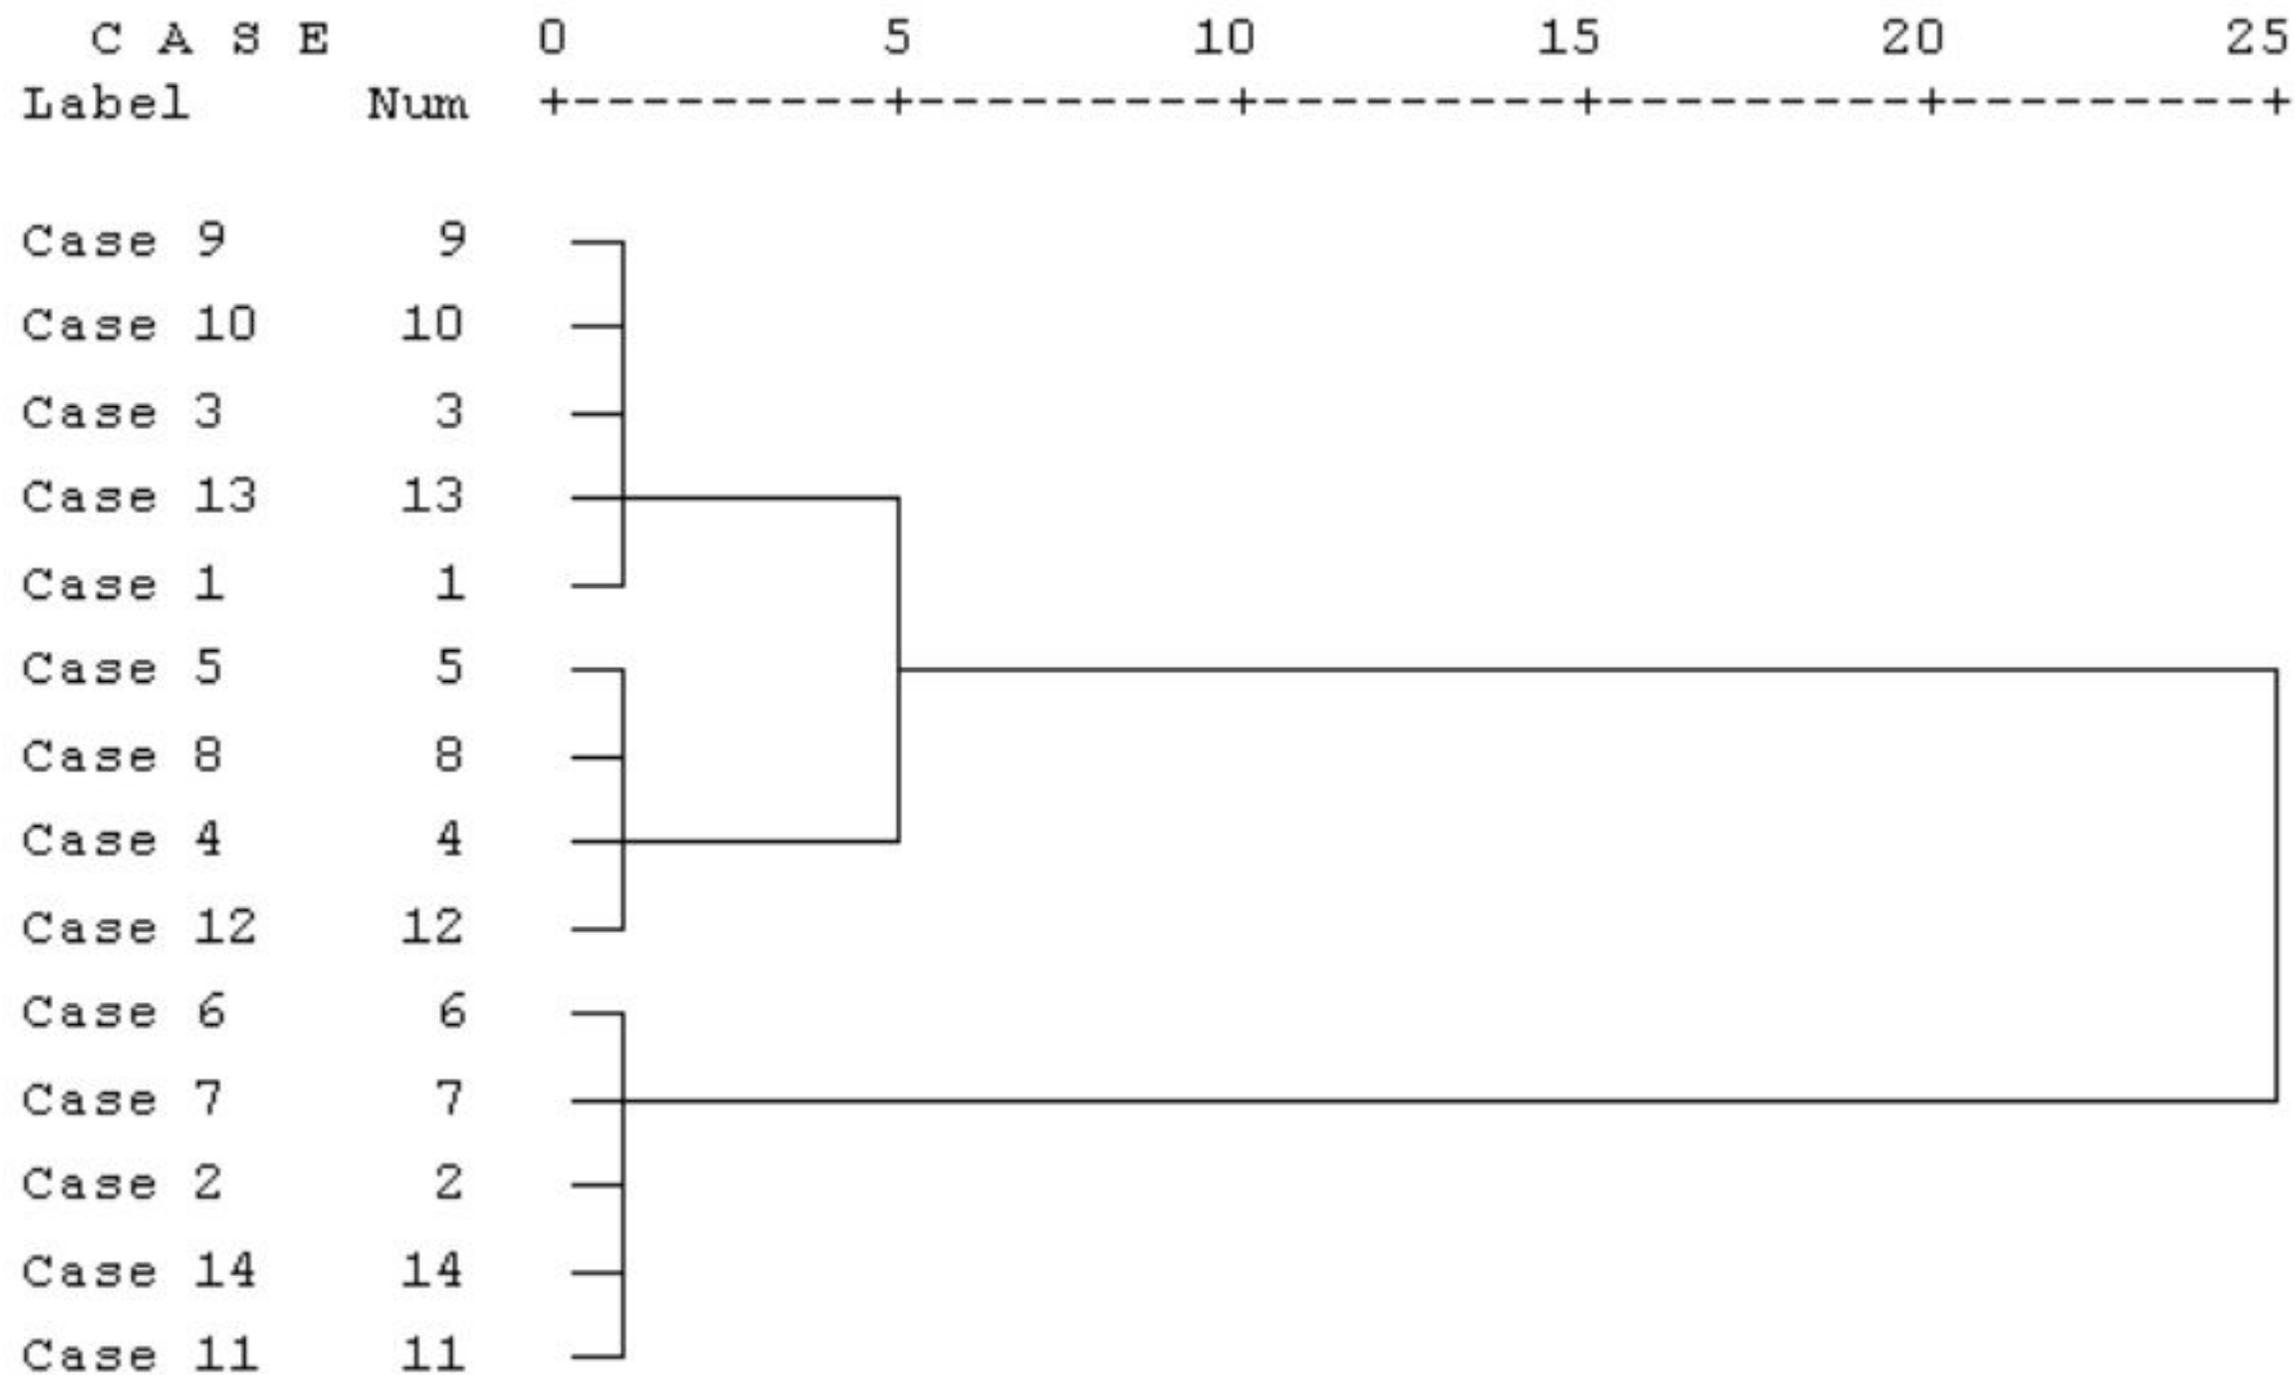
#	9.0 Длина чашелисти...	9.0 Ширина чашелистика	9.0 Длина лепест...	9.0 Ширина лепест...	ab Класс
48	4,60	3,20	1,40	0,20	Iris-setosa
49	5,30	3,70	1,50	0,20	Iris-setosa
50	5,00	3,30	1,40	0,20	Iris-setosa
51	7,00	3,20	4,70	1,40	Iris-versicolor
150	6,40	3,20	4,50	1,50	Iris-versicolor

Таблица

Форма



- Существует **проблема определения числа кластеров**. Иногда можно априорно определить это число. Однако в большинстве случаев число кластеров определяется в процессе агломерации/разделения множества объектов.
- Процессу группировки объектов в иерархическом кластерном анализе соответствует **постепенное возрастание коэффициента** в протоколе объединения.
- **Скачкообразное увеличение** значения коэффициента объединения можно определить как переход от сильно связанного к слабо связанному состоянию объектов.
- **Оптимальным** считается количество кластеров, равное разности количества наблюдений и количества шагов до скачкообразного увеличения коэффициента.



Итеративные методы. Алгоритм k -средних (k-means)

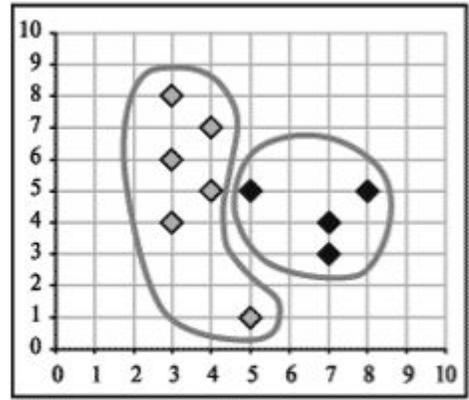
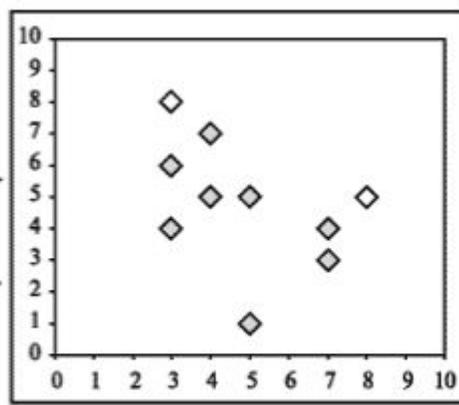
- Наиболее распространен среди **неиерархических методов** алгоритм **k -средних**, также называемый быстрым кластерным анализом.
- В отличие от иерархических методов, которые не требуют предварительных предположений относительно числа кластеров, для метода **k -means** необходимо иметь гипотезу о наиболее вероятном количестве кластеров.
- Алгоритм **k -средних** строит **k** кластеров, расположенных на возможно больших расстояниях друг от друга.
- Выбор числа **k** может базироваться на результатах предшествующих исследований, теоретических соображениях или интуиции.

K-средних

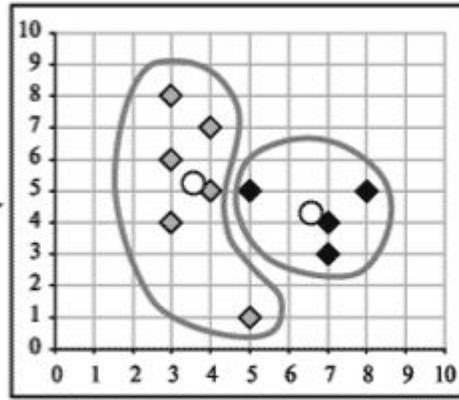
- Выбор начальных центроидов может осуществляться следующим образом:
 - выбор k -наблюдений для максимизации начального расстояния;
 - случайный выбор k -наблюдений;
 - выбор первых k -наблюдений.
- В результате каждый объект назначен определенному кластеру.
- Вычисляются центры кластеров, которыми затем и далее считаются координатные средние кластеров. **Объекты опять перераспределяются.**
- Процесс вычисления центров и перераспределения объектов продолжается до тех пор, пока не выполнено одно из условий:
 - кластерные центры стабилизировались, т.е. все наблюдения принадлежат кластеру, которому принадлежали до текущей итерации;

$K=2$
Произвольный выбор
 k объектов как
исходных центров
кластеров

Назначение каждого объекта
наиболее подходящему
(похожему) кластеру

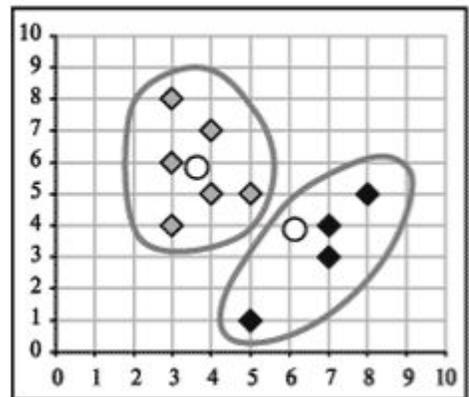


Пересчет
кластерных
центров
(по координатных
средних)

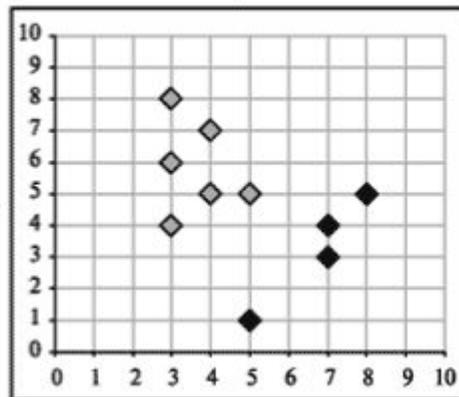


Перераспределение
объектов

Перераспределение
объектов



Пересчет
кластерных
центров
(по координатных
средних)



Достоинства алгоритма k - средних:

- простота использования;
- быстрота использования;
- понятность и прозрачность.

Недостатки алгоритма k -средних:

- алгоритм чувствителен к выбросам, искажающим среднее.

Для решения этой проблемы -
модификация алгоритм k -
медианы;

- алгоритм может медленно работать на больших базах данных.

Возможным решением данной
проблемы является

Проверка качества кластеризации

- После получения результатов кластерного анализа методом **k-средних** следует проверить правильность кластеризации (т.е. оценить, насколько кластеры отличаются друг от друга).
- Для этого рассчитываются **средние значения** для каждого кластера.
- При хорошей кластеризации должны быть получены **сильно отличающиеся средние** для всех измерений или хотя бы большей их части.

Алгоритм g-means

- Недостаток k-means - отсутствие ясного критерия для выбора оптимального числа кластеров.
- **G-means** - популярный алгоритм кластеризации с **автоматическим выбором числа кластеров**.
- Предположение - обрабатываемые данные подчиняются **распределению Гаусса** (нормальному **распределению**).
- Алгоритм итеративный: на каждом шаге с помощью k-means строится модель с определенным числом кластеров.

Обычно **g-means** начинает работу с небольшого значения $k=1$.

- На каждой итерации увеличение k производится за счет разбиения кластеров, в которых данные не соответствуют гауссовскому распределению.

Нормальное распределение

Для нормального распределения количество значений, отличающиеся от среднего на число, меньшее чем одно стандартное отклонение, составляют 68,27 % выборок.



Ирисы Фишера

Таблица 7.1

№	Длина чашелистника	Ширина чашелистника	Длина лепестка	Ширина лепестка	Класс
1	5,1	3,5	1,4	0,2	<i>Iris setosa</i>
2	4,9	3,0	1,4	0,2	<i>Iris setosa</i>
3	4,7	3,2	1,3	0,2	<i>Iris setosa</i>
4	4,6	3,1	1,5	0,2	<i>Iris setosa</i>
5	5,0	3,6	1,4	0,2	<i>Iris setosa</i>
51	7,0	3,2	4,7	1,4	<i>Iris versicolor</i>
52	6,4	3,2	4,5	1,5	<i>Iris versicolor</i>
53	6,9	3,1	4,9	1,5	<i>Iris versicolor</i>
54	5,5	2,3	4,0	1,3	<i>Iris versicolor</i>
55	6,5	2,8	4,6	1,5	<i>Iris versicolor</i>
101	6,3	3,3	6,0	2,5	<i>Iris virginica</i>
102	5,8	2,7	5,1	1,9	<i>Iris virginica</i>
103	7,1	3,0	5,9	2,1	<i>Iris virginica</i>
104	6,3	2,9	5,6	1,8	<i>Iris virginica</i>
105	6,5	3,0	5,8	2,2	<i>Iris virginica</i>

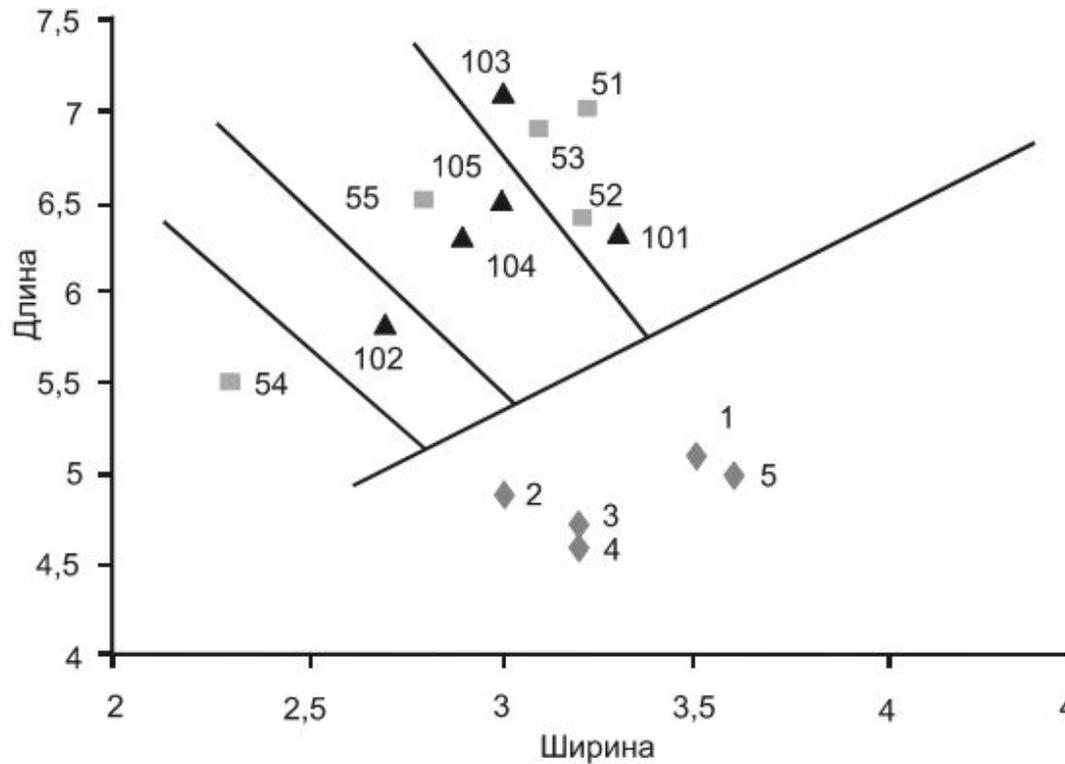


Рис. 7.1. Разделение ирисов на кластеры линиями

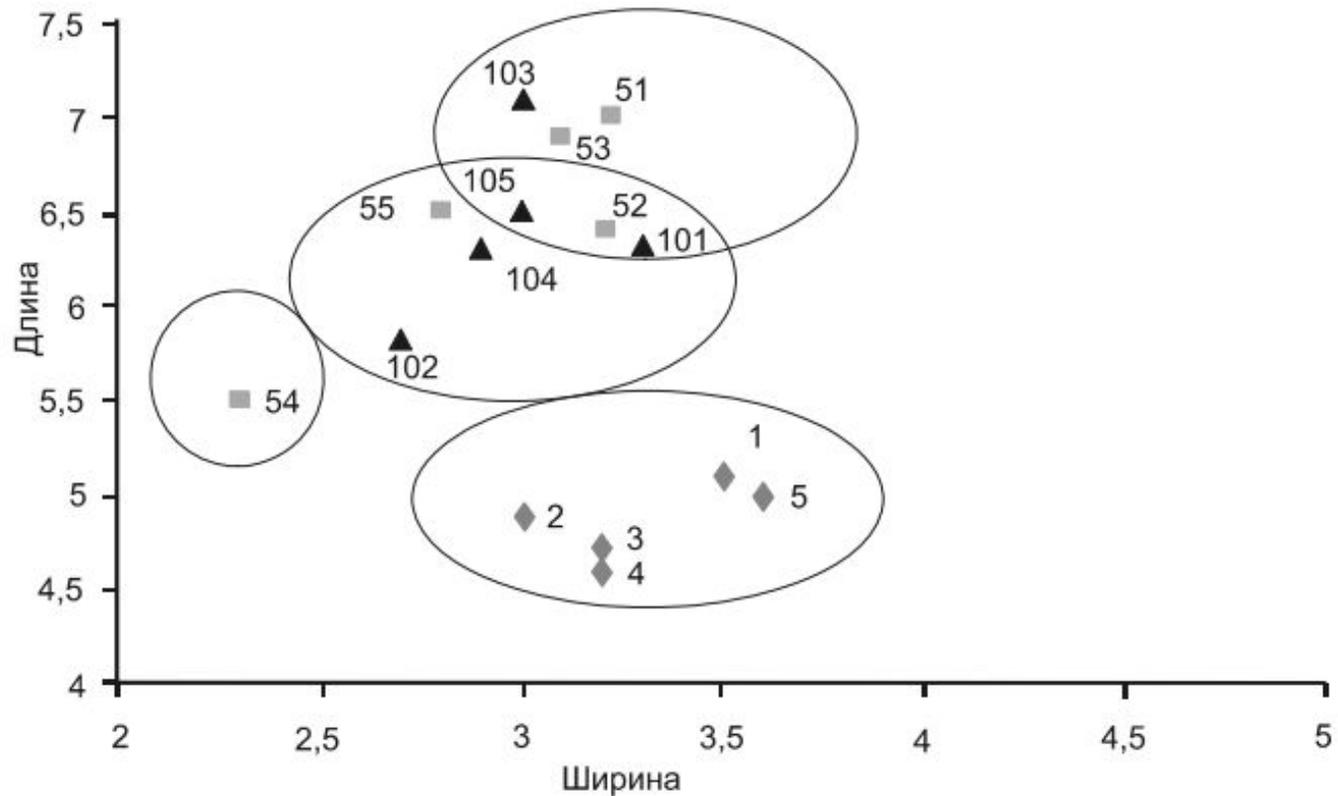


Рис. 7.2. Разделение ирисов на кластеры с использованием Венских диаграмм



Фильтрация | Значимость | Сравнение

#	Метка кластера	Поддержка	Длина чашелист...	Ширина чашели...	Длина лепес...
1	Итого	100%	66	61	
2	Кластер 2	37%	53	55	
3	Кластер 0	33%	61	57	
4	Кластер 1	29%	69	52	



Атрибут	Итого	Кластер 2	Кл
Значимость	66	53	
Минимум	4,30	4,90	
Максимум	7,90	6,70	
Среднее	5,84	5,83	
Сумма	876,50	326,70	
Стандартное от...	0,83	0,42	
Размах	3,60	1,80	
Пропуски	0	0	
Значения	150	56	
Количество вн...			

#	Метка кластера	Поддержка	Длина чашелист...	Ширина чашели...	Длина лепес...
1	Итого	100%	63	52	
2	Кластер 0	67%	32	29	
3	Кластер 1	33%	58	53	



Атрибут	Итого	Кластер 0	Кластер 1
Значимость	63	32	58
Минимум	4,30	4,90	4,30
Максимум	7,90	7,90	7,90
Среднее	5,84	6,26	5,42
Сумма	876,50	626,20	876,50
Стандартное от...	0,83	0,66	0,94
Размах	3,60	3,00	3,60
Пропуски	0	0	0
Значения	150	100	150
Количество ун...			

Максимальное ожидание EM-алгоритм

- EM (Expectation maximization - максимальное правдоподобие) – популярный алгоритм кластеризации.
- В основе идеи EM-алгоритма лежит предположение, что любое наблюдение принадлежит ко всем кластерам, но с разной вероятностью. Формируются два дополнительных столбца: *Номер кластера* и *Вероятность принадлежности*.
- Объект должен быть отнесен к тому кластеру, для которого **вероятность принадлежности выше**.

#	12 Номер кластера	90 Вероятность принадлежности	90 Длина ...	90 Ширин...	90 Длина л...	90 Ширина лепест...	ab Класс
69	2	0,83	6,20	2,20	4,50	1,50	Iris-versicolor
70	2	1,00	5,60	2,50	3,90	1,10	Iris-versicolor
71	0	0,91	5,90	3,20	4,80	1,80	Iris-versicolor
72	2	1,00	6,10	2,80	4,00	1,30	Iris-versicolor
73	2	0,70	6,30	2,50	4,90	1,50	Iris-versicolor
74	2	0,98	6,10	2,80	4,70	1,20	Iris-versicolor
75	2	1,00	6,40	2,90	4,30	1,30	Iris-versicolor

- **Главным достоинством** EM-алгоритма является простота исполнения.

Алгоритм может оптимизировать не только параметры модели, но и делать предположения относительно значений отсутствующих данных.

Это делает EM отличным методом для кластеризации и создания моделей с параметрами. Зная кластеры и параметры модели можно предполагать, что содержит кластер и куда стоит отнести новые данные.

- EM-алгоритм имеет свои **недостатки**:
 1. С ростом количества итераций падает производительность алгоритма.
 2. EM не всегда находит оптимальные параметры и может застрять в локальном оптимуме, так и не найдя глобальный.

Фильтрация Среднее Сравнение

#	Метка кластера	Поддержка	Длина чашелист...	Ширина чашели...	Длина лепес...
1	Кластер 2	33%	5,01	3,42	
2	Итого	100%	5,84	3,05	
3	Кластер 0	33%	5,94	2,76	
4	Кластер 1	34%	6,57	2,98	



Атрибут	Итого	Кластер 2
Значимость	64	59
Минимум	4,30	4,30
Максимум	7,90	5,80
Среднее	5,84	5,01
Сумма	876,50	250,30
Стандартное от...	0,83	0,35
Размах	3,60	1,50
Пропуски	0	0
Значения	150	50
Количество ун...		

Кластеризации больших массивов категориальных данных

- Алгоритмы, основанные на *парном вычислении расстояний* (k-means и аналоги) эффективны в основном на числовых данных. Их производительность на массивах записей с большим количеством нечисловых факторов неудовлетворительная.
- На каждой итерации алгоритма требуется попарно сравнивать объекты между собой, а итераций может быть очень много. Для таблиц с миллионами записей и тысячами полей это неприменимо.

Требований к алгоритмам кластеризации номинальных (качественных) данных

- Минимально возможное количество «сканирований» таблицы базы данных;
- Работа в ограниченном объеме оперативной памяти компьютера;
- Работу алгоритма можно прервать с сохранением промежуточных результатов, чтобы продолжить вычисления позже;
- Алгоритм должен работать, когда объекты из базы данных могут извлекаться только в режиме однонаправленного курсора (т.е. в режиме навигации по записям).

Алгоритм CLOPE (кластеризация с наклоном)

- CLOPE (**C**lustering with **sLOPE**) предложен в 2002 году группой китайских ученых.
- Транзакция - некоторый произвольный набор объектов.
- Задача кластеризации - получение такого разбиения всего множества транзакций, чтобы похожие транзакции оказались в одном кластере, а отличающиеся друг от друга — в разных кластерах.
- В основе алгоритма идея максимизации глобальной функции стоимости, которая повышает близость транзакций в кластерах при помощи увеличения параметра **кластерной гистограммы**.

Математическое описание алгоритма

Каждый элемент C_i называется *кластером*, n — количество транзакций, A — длина транзакции, k — число кластеров.

При этом задан параметр r - коэффициент отталкивания.

Характеристики кластера C_j :

$D(C_j)$ — множество уникальных объектов в кластере C_j ;

$Occ(i, C_j)$ — количество вхождений объекта i в кластер C_j ;

$S(C_j) = \sum_{i \in D(C_j)} Occ(i, C_j) = \sum_{t_i \in C_j} |t_i|$ — общее количество объектов в кластере C_j ;

$W(C_j) = |D(C_j)|$ — **ширина** кластера;

$H(C_j) = S(C_j) / W(C_j)$ — **высота** кластера.

При использовании метода CLOPE количество кластеров подбирается автоматически и зависит от коэффициента отталкивания — параметра, определяющего уровень сходства транзакций внутри кластера. Коэффициент отталкивания задается пользователем: чем больше данный параметр, тем ниже уровень сходства транзакций и, как следствие, большее количество кластеров будет создано.

Формула для вычисления глобального критерия — функции стоимости текущей кластеризации $C = \{C_1, \dots, C_k\}$, обозначаемой, как $Profit(C)$:

$$Profit(C) = \frac{\sum_{i=1}^k H(C_i) \times |C_i|}{\sum_{i=1}^k |C_i|} = \frac{\sum_{i=1}^k \frac{S(C_i)}{W(C_i)^r} \times |C_i|}{\sum_{i=1}^k |C_i|}$$

Для построения начального распределения транзакций по кластерам необходимо сделать первый проход по таблице (фаза инициализации). Во время нее для каждой транзакции выбирается кластер таким образом, чтобы функция $Profit(C)$ была максимальной.

Далее происходят "уточняющие" проходы (фаза итерации), где для каждой транзакции производится попытка перемещения в другой кластер так, чтобы $Profit(C) \rightarrow max$.

Если больше не существует перемещений транзакций, увеличивающих глобальную стоимость $Profit(C)$, то действие алгоритма заканчивается.

Разность между стоимостью кластеризации $Profit(C)$ после перемещения транзакции t_n с кластера C_i на кластер C_j и стоимостью кластеризации непосредственно до этого перемещения называется ценой перемещения транзакции. Цена перемещения t_n с кластера C_i на кластер C_j складывается из двух величин:

- $Cost^-(C_i, t_n) = \frac{(S(C_i) - length(t_n)) * (|C_i| - 1)}{W(C_i \setminus t_n)^r} - \frac{S(C_i) * |C_i|}{W(C_i)^r}$ — цена удаления транзакции t_n из кластера C_i .

- $Cost^+(C_j, t_n) = \frac{(S(C_j) + length(t_n)) * (|C_j| + 1)}{W(C_j \cup t_n)^r} - \frac{S(C_j) * |C_j|}{W(C_j)^r}$ — цена добавления транзакции t_n на кластер C_j .

ЗАКЛЮЧЕНИЕ В этой статье предлагается новый алгоритм категориальной кластеризации данных, называемый CLOPE, основанный на интуитивной идее увеличения отношения высоты к ширине кластерной гистограммы.

Идея обобщается с помощью **параметра отталкивания**, который контролирует плотность транзакций в кластере и, следовательно, результирующее количество кластеров.

Простая идея, лежащая в основе CLOPE, делает его быстрым, масштабируемым и экономящим память при кластеризации больших разреженных транзакционных баз данных с большими размерами.

Наши эксперименты показывают, что CLOPE довольно эффективен при поиске интересных кластеров, даже если в нем явно не указана какая-либо метрика межкластерного различия.

Более того, CLOPE не очень чувствителен к порядку данных и не требует большого знания предметной области для управления количеством кластеров.

Эти функции делают CLOPE хорошим алгоритмом кластеризации, а также предварительной обработки для интеллектуального анализа транзакционных данных, таких как данные о рыночной корзине и данные об использовании Интернета.

Описательная аналитика и Кластеризация

- **Кластеризация транзакционных данных** имеет много общего с анализом ассоциаций: выявляют скрытые зависимости в наборах данных.
- **Кластеризация** дает общий взгляд на совокупность данных, **ассоциативный анализ** находит конкретные зависимости между атрибутами.
- **Ассоциативные правила** сразу пригодны для использования, тогда как кластеризация чаще всего используется как первая стадия анализа.