

УДК 519.7

КЛАСТЕРИЗАЦИЯ НА ОСНОВЕ ПОИСКА ЦЕНТРОВ И УСРЕДНЯЮЩИЕ АГРЕГИРУЮЩИЕ ФУНКЦИИ

З. М. Шибзухов

Институт прикладной математики и автоматизации, филиал КБНЦ РАН, г. Нальчик
E-mail: szport@gmail.com

Предлагается новый метод поиска разбиения на кластеры конечного множества точек из \mathbb{R}^n , который основан на применении усредняющих агрегирующих функций и метод итерационного перевзвешивания для поиска центров кластеров.

Ключевые слова: агрегирующие функции, M-среднее, K-means, кластеризация

© Шибзухов З. М., 2017

MSC 68T05, 62H30

CENTER BASED CLUSTERING AND AVERAGING AGGREGATION FUNCTIONS

Z. M. Shibzukhov

Institute of Applied Mathematics and Automation, branch of KBSC RAS, Nalchick
E-mail: szport@gmail.com

We propose a new clustering method for partitioning of finite sets from \mathbb{R}^n , which is based on the application of averaging aggregating functions and an iterative re-weighting method for searching cluster centers.

Key words: aggregation function, M-average, K-means, clustering

© Shibzukhov Z. M., 2017

В основе одного классического метода для точного разбиения на кластеры лежит процедура поиска центров кластеров. Центр множества – это точка, от которой сумма расстояний до всех точек множества минимально. Разбиение на кластеры осуществляется по простому правилу: точка относится к кластеру, до центра которого расстояние минимально.

Пусть $\mathbf{S} \subset \mathbb{R}^n$ – открытое подмножество, $\mathbf{X} = \{\mathbf{x}_1, \dots, \mathbf{x}_N\} \subset \mathbf{S}$ – конечное множество, которое требуется разбить на K кластеров. Пусть $d: \mathbf{S} \times \mathbf{S} \rightarrow \mathbb{R}_+ \cup \{\infty\}$ – функция обобщенного расстояния между точками из \mathbf{S} , которая, по определению [1], удовлетворяет следующим требованиям:

- 1) $d_{\mathbf{c}}(\mathbf{x}) = d(\mathbf{x}, \mathbf{c})$ – строго выпуклая и дважды дифференцируемая на \mathbf{S} ;
- 2) $\lim_{\|\mathbf{x}\| \rightarrow \infty} d_{\mathbf{c}}(\mathbf{x}) = \infty$.

Пусть $\mathbf{C}_1, \dots, \mathbf{C}_K$ – некоторое разбиение множества \mathbf{X} на K кластеров, $y_j(\mathbf{x})$ – характеристическая функция j -го кластера, $1 \leq j \leq K$:

$$y_j(\mathbf{x}) = \begin{cases} 1, & \text{если } \mathbf{x} \in \mathbf{C}_j \\ 0, & \text{иначе.} \end{cases}$$

ОПРЕДЕЛЕНИЕ. Точка \mathbf{c}^* – центр конечного множества $\mathbf{C} \subset \mathbb{R}^n$, если

$$\mathcal{Q}(\mathbf{c}^*) = \min_{\mathbf{c} \in \mathbb{R}^n} \mathcal{Q}(\mathbf{c}), \tag{1}$$

где

$$\mathcal{Q}(\mathbf{c}) = \sum_{k=1}^N y_k d(\mathbf{x}_k, \mathbf{c}),$$

а $y_k = y(\mathbf{x}_k)$ – характеристическая функция \mathbf{C} .

Например:

- 1) в методе **K-means**

$$d(\mathbf{x}, \mathbf{c}) = \|\mathbf{x} - \mathbf{c}\|_2^2 = \sum_{i=1}^n (x_i - c_i)^2,$$

центр множества

$$\mathbf{c}^* = \frac{1}{|\mathbf{C}|} \sum_{k=1}^N \mathbf{x}_k.$$

- 2) в методе **K-medoid**

$$d(\mathbf{x}, \mathbf{c}) = \|\mathbf{x} - \mathbf{c}\|_1 = \sum_{i=1}^n |x_i - c_i|,$$

центр множества $\mathbf{c}^* = (c_1^*, \dots, c_n^*)$, где

$$c_i^* = \text{med}_{k=1, \dots, N} \{x_{ki}\},$$

а $\mathbf{x}_k = (x_{k1}, \dots, x_{kn})$.

Условия, наложенные на d обеспечивают существование и единственность центра.

В более общем случае функцию расстояния можно записать в следующей форме:

$$d(\mathbf{x}, \mathbf{c}) = g\left(\sum_{i=1}^n h(x_i - c_i)\right),$$

где h — функция расстояния на \mathbb{R} , g — монотонная строго возрастающая функция. Например:

$$1) d(\mathbf{x}, \mathbf{c}) = \|\mathbf{x} - \mathbf{c}\|_p^p = \sum_{i=1}^n |x_i - c_i|^p, \quad p \geq 1;$$

$$2) d(\mathbf{x}, \mathbf{c}) = \|\mathbf{x} - \mathbf{c}\|_p = \left(\sum_{i=1}^n |x_i - c_i|^p \right)^{1/p}, \quad p \geq 1.$$

Детерминированные характеристические функции кластеров, которые полностью задаются своими центрами, обычно определяются следующим образом:

$$y_j(\mathbf{x}) = \begin{cases} 1, & \text{если } j = \arg \min_{j=1, \dots, K} d(\mathbf{x}, \mathbf{c}_j) \\ 0, & \text{иначе} \end{cases} \quad (2)$$

Т.е. точка относится к тому кластеру, к которому она ближе всего.

Задачу поиска кластеров, следуя [1], можно сформулировать как задачу оптимизации:

$$\mathbf{c}_1^*, \dots, \mathbf{c}_K^* = \arg \min_{\mathbf{c}_1, \dots, \mathbf{c}_K} \mathcal{Q}(\mathbf{c}_1, \dots, \mathbf{c}_K), \quad (3)$$

где

$$\mathcal{Q}(\mathbf{c}_1, \dots, \mathbf{c}_K) = \sum_{k=1}^N v_k D(\mathbf{x}_k), \quad (4)$$

$$D(\mathbf{x}) = \min_{1 \leq j \leq K} d(\mathbf{x}, \mathbf{c}_j), \quad (5)$$

величина $v_k \geq 0$ и отражает значимость k -ой точки, $v_1 + \dots + v_N = 1$. Если $v_k = \frac{1}{N}$, а $d(\mathbf{x}, \mathbf{c}) = \|\mathbf{x} - \mathbf{c}\|_2^2$, то данная задача оптимизации лежит в основе стандартного алгоритма **K-Means**.

Так как

$$\text{grad}_{\mathbf{c}_j} \mathcal{Q} = \sum_{k \in \mathbf{I}_j} v_k \text{grad}_{\mathbf{c}_j} d_k(\mathbf{c}),$$

где $d_k(\mathbf{c}_j) = d(\mathbf{x}_k, \mathbf{c}_j)$, $y_{kj} = y_j(\mathbf{x}_k)$, $\mathbf{I}_j = \{k: \mathbf{x}_k \in \mathbf{C}_j\}$, то центр j -ого кластера является решением следующей задачи оптимизации:

$$\mathbf{c}_j = \arg \min_{\mathbf{c}} \sum_{k \in \mathbf{I}_j} v_k d_k(\mathbf{c}).$$

Классический алгоритм кластеризации на основе поиска центров кластеров **HCD**¹ представляет собой итерационный процесс уточнения положения центров $\mathbf{c}_1, \dots, \mathbf{c}_K$. Он представляет собой разновидность алгоритмов спуска по альтернативным направлениям, которые представляют группы переменных, соответствующих центрам кластеров $\mathbf{c}_1, \dots, \mathbf{c}_K$.

¹HCD = **H**ard **C**lustering with **D**istance-like functions

```

procedure HCD( $\{\mathbf{x}_1, \dots, \mathbf{x}_N\}, \{\mathbf{c}_1^0, \dots, \mathbf{c}_K^0\}$ )
   $t \leftarrow 0$ 
   $\mathbf{c}_1, \dots, \mathbf{c}_K \leftarrow \mathbf{c}_1^0, \dots, \mathbf{c}_K^0$ 
  repeat
    for all  $j = 1, \dots, K$  do
       $\mathbf{I}_j = \{k: y_j(\mathbf{x}_k) = 1\}$ 
       $\mathbf{c}_j \leftarrow \arg \min_{\mathbf{c}} \sum_{k \in \mathbf{I}_j} v_k d_k(\mathbf{c}),$ 
    end for
     $t \leftarrow t + 1$ 
  until положения центров не стабилизируются
  return  $\mathbf{c}_1, \dots, \mathbf{c}_K$ 
end procedure

```

Рассмотрим случай, когда $d(\mathbf{x}, \mathbf{c}) = \rho(\|\mathbf{x} - \mathbf{c}\|)$, где $\|\cdot\|$ – Евклидова норма. В этом случае алгоритм HCD можно свести к цепочке взвешенных версий K-Means на базе следующего соотношения:

$$\text{grad} \rho(\|\mathbf{x} - \mathbf{c}\|) = \rho'(\|\mathbf{x} - \mathbf{c}\|) \text{grad} \|\mathbf{x} - \mathbf{c}\| = \frac{\rho'(\|\mathbf{x} - \mathbf{c}\|)}{\|\mathbf{x} - \mathbf{c}\|} \text{grad} \frac{1}{2} \|\mathbf{x} - \mathbf{c}\|^2.$$

Применяя метод итеративного перевзвешивания для поиска центров кластеров, приходим к алгоритму IR-KMeans.²

Рассмотрим обобщения этой постановки задачи, исходя из факта, что min и взвешенное среднее арифметическое являются примерами усредняющих агрегирующих функций [2, 3]. Значительный класс таких функций – это M-средние. Будем строить эти обобщения, по следующей схеме [4].

Пусть $\rho(r, s) = g(h(r) - h(s))$, где $g(r)$ – выпуклая функция, а $h(s)$ – строго монотонная. Определим M-среднее, как решение следующей задачи:

$$M_\rho\{r_1, \dots, r_m\} = \arg \min_s \left\{ \sum_{j=1}^m \rho(r_j, s) \right\}.$$

Если $\rho(\cdot, r)$ – строго выпуклая дважды дифференцируемая функция, то M_ρ – дифференцируемая усредняющая агрегирующая функция [5, 6]. Большинство известных функций для вычисления эмпирического среднего можно представить как M-среднее.

Если существует $\rho_{ss}(r, s)$ и $\rho_{sr}(r, s)$, то

$$\frac{\partial M_\rho\{r_1, \dots, r_m\}}{\partial r_j} = \frac{-\rho_{sr}''(r_j, \bar{r})}{\rho_{ss}''(r_1, \bar{r}) + \dots + \rho_{ss}''(r_m, \bar{r})},$$

где $\bar{r} = M_\rho\{r_1, \dots, r_m\}$. В частности, если $\rho(r, s) = g(r - s)$, то имеет место соотношение:

$$\sum_{j=1}^m \frac{\partial M_\rho\{r_1, \dots, r_m\}}{\partial r_j} = 1.$$

Рассмотрим *первое* обобщение путем замены взвешенного среднего арифметического на M_ρ :

$$\mathcal{Q}(\mathbf{c}_1, \dots, \mathbf{c}_K) = M_\rho\{D(\mathbf{x}_1), \dots, D(\mathbf{x}_N)\}. \quad (6)$$

²IR-K-Means = Iteratively Reweighted K-Means.

Градиент \mathcal{Q} по \mathbf{c}_j ($1 \leq j \leq K$) имеет вид:

$$\text{grad}_{\mathbf{c}_j} \mathcal{Q} = \sum_{k \in \mathbf{I}_j} \frac{\partial M_\rho \{D(\mathbf{x}_1), \dots, D(\mathbf{x}_N)\}}{\partial r_k} \text{grad}_{\mathbf{c}_j} d_k(\mathbf{c}_j),$$

где $\mathbf{I}_j = \{k: y_{kj} = 1\}$.

Для решения задачи поиска центров, минимизирующих (6) можно построить процедуру спуска по альтернативным направлениям – градиентам $\text{grad}_{\mathbf{c}_j} \mathcal{Q}$.

procedure IR-HCD-M1($\{\mathbf{x}_1, \dots, \mathbf{x}_N\}, \{\mathbf{c}_1^0, \dots, \mathbf{c}_K^0\}$)

$t \leftarrow 0$

$\mathbf{c}_1, \dots, \mathbf{c}_K \leftarrow \mathbf{c}_1^0, \dots, \mathbf{c}_K^0$

repeat

for all $j = 1, \dots, K$ **do**

for all $k \in \mathbf{I}_j$ **do**

$$v_k = \frac{\partial M_\rho \{D(\mathbf{x}_1), \dots, D(\mathbf{x}_N)\}}{\partial r_k}$$

end for

$$\mathbf{c}_j \leftarrow \arg \min_{\mathbf{c}} \sum_{k \in \mathbf{I}_j} v_k d_k(\mathbf{c})$$

end for

$t \leftarrow t + 1$

until положения центров не стабилизируются

return $\mathbf{c}_1, \dots, \mathbf{c}_K$

end procedure

По окончании работы алгоритма получаются веса точек v_1^*, \dots, v_N^* (т.к. множества $\mathbf{I}_1, \dots, \mathbf{I}_K$ не пересекаются; в противном случае детерминированное разбиение на кластеры невозможно). В случае, когда $\rho(r, s) = g(r - s)$, их можно интерпретировать как степени важности точек $\mathbf{x}_1, \dots, \mathbf{x}_N$. Найденные центры также являются решением задачи (3)–(5) с весами v_1^*, \dots, v_N^* .

Рассмотрим *второе* обобщение задачи (4), когда

$$D(\mathbf{x}) = M_{\rho_C} \{d(\mathbf{x}, \mathbf{c}_1), \dots, d(\mathbf{x}, \mathbf{c}_K)\}$$

т.е. тогда

$$\mathcal{Q}(\mathbf{c}_1, \dots, \mathbf{c}_K) = \sum_{k=1}^N v_k M_{\rho_C} \{d_k(\mathbf{c}_1), \dots, d_k(\mathbf{c}_K)\}. \quad (7)$$

Градиент \mathcal{Q} по \mathbf{c}_j ($1 \leq j \leq K$) имеет вид:

$$\text{grad}_{\mathbf{c}_j} \mathcal{Q} = \sum_{k=1}^N v_k \frac{\partial M_{\rho_C} \{d_{k1}, \dots, d_{kK}\}}{\partial r_j} \text{grad}_{\mathbf{c}_j} d_k(\mathbf{c}_j),$$

где $d_{kj} = d(\mathbf{x}_k, \mathbf{c}_j)$.

Для решения задачи можно построить алгоритм IR-HCD-M2 – новый вариант процедуры итерационного перевзвешивания:

```

procedure IR-HCD-M2( $\{\mathbf{x}_1, \dots, \mathbf{x}_N\}$ ,  $\{\mathbf{c}_1^0, \dots, \mathbf{c}_K^0\}$ )
   $t \leftarrow 0$ 
   $\mathbf{c}_1, \dots, \mathbf{c}_K \leftarrow \mathbf{c}_1^0, \dots, \mathbf{c}_K^0$ 
  repeat
    for all  $k = 1, \dots, N$  do
       $v_{k1}, \dots, v_{kK} = \text{grad}M_{\rho_C}\{d_k(\mathbf{c}_1), \dots, d_k(\mathbf{c}_K)\}$ 
    end for
    for all  $j = 1, \dots, K$  do
       $\mathbf{c}_j \leftarrow \arg \min_{\mathbf{c}} \sum_{k=1}^N v_k v_{kj} d_k(\mathbf{c})$ 
    end for
     $t \leftarrow t + 1$ 
  until положения центров не стабилизируются
  return  $\mathbf{c}_1, \dots, \mathbf{c}_K$ 
end procedure

```

Заметим, что если $\rho(r, s) = g(r - s)$, то $v_{k1}, \dots, v_{kK} \geq 0$ и $v_{k1} + \dots + v_{kK} = 1$. Тогда величины v_{k1}, \dots, v_{kK} можно интерпретировать как степени принадлежности \mathbf{x}_k к классам с метками $1, \dots, K$, соответственно. Это позволяет построить нечеткую кластеризацию конечного множества $\mathbf{x}_1, \dots, \mathbf{x}_N$. При этом, нечеткая функция принадлежности к кластерам строится на основе выбранной дифференцируемой усредняющей функции M_ρ следующим образом:

$$y_1(\mathbf{x}), \dots, y_K(\mathbf{x}) = \text{grad}M_\rho\{d(\mathbf{x}, \mathbf{c}_1), \dots, d(\mathbf{x}, \mathbf{c}_K)\}.$$

Если $d(\mathbf{x}, \mathbf{c}) = \rho(\|\mathbf{x} - \mathbf{c}\|^2)$, то тогда алгоритм IR-HCM превращается в аналог IR-K-Means, в котором веса

$$v_{kj} = \frac{\partial M_\rho\{d_{k1}, \dots, d_{kK}\}}{\partial r_j} \frac{\rho'(\|\mathbf{x}_k - \mathbf{c}_j\|)}{\|\mathbf{x}_k - \mathbf{c}_j\|},$$

где $d_{kj} = d(\mathbf{x}_k, \mathbf{c}_j)$.

Предложенная здесь метод поиска центров кластеров обобщает подход, рассмотренный в [1], когда в качестве усредняющих функций выступают функции среднего по Колмогорову:

$$M^h\{z_1, \dots, z_K\} = h^{-1}\left(\frac{1}{N} \sum_{j=1}^K h(z_j)\right),$$

где h – взаимно обратная монотонная функция. Т.е. алгоритм IR-HCM обобщает естественным образом алгоритм SKM [1]. Там же было показано, что путем выбора соответствующей функции h можно построить уже известные алгоритмы кластеризации, как такие FCM [7], EM [8], DA [9], Bergman Soft Clustering [10].

Объединим теперь оба этих способа. Теперь задача поиска центров имеет вид:

$$\mathbf{c}_1^*, \dots, \mathbf{c}_K^* = \arg \min_{\mathbf{c}_1, \dots, \mathbf{c}_K} \mathcal{Q}(\mathbf{c}_1, \dots, \mathbf{c}_K), \quad (8)$$

где

$$\mathcal{Q}(\mathbf{c}_1, \dots, \mathbf{c}_K) = M_\rho\{D(\mathbf{x}_1), \dots, D(\mathbf{x}_N)\}, \quad (9)$$

$$D(\mathbf{x}) = M_{\rho_C}\{d(\mathbf{x}, \mathbf{c}_1), \dots, d(\mathbf{x}, \mathbf{c}_K)\}, \quad (10)$$

Градиент \mathcal{Q} по \mathbf{c}_j ($1 \leq j \leq K$) имеет вид:

$$\text{grad}_{\mathbf{c}_j} \mathcal{Q} = \sum_{k=1}^N \frac{\partial M_\rho \{d_{1j}, \dots, d_{Nj}\}}{\partial r_k} \frac{\partial M_{\rho_C} \{d_{k1}, \dots, d_{kK}\}}{\partial r_j} \text{grad}_{\mathbf{c}_j} d(\mathbf{x}_k, \mathbf{c}_j),$$

где $d_{kj} = d(\mathbf{x}_k, \mathbf{c}_j)$.

```

procedure IR-HCD-MM( $\{\mathbf{x}_1, \dots, \mathbf{x}_N\}$ ,  $\{\mathbf{c}_1^0, \dots, \mathbf{c}_K^0\}$ )
   $t \leftarrow 0$ 
   $\mathbf{c}_1, \dots, \mathbf{c}_K \leftarrow \mathbf{c}_1^0, \dots, \mathbf{c}_K^0$ 
  repeat
    for all  $k = 1, \dots, N$  do
       $v_{k1}, \dots, v_{kK} = \text{grad}M_{\rho_C} \{d_k(\mathbf{c}_1), \dots, d_k(\mathbf{c}_K)\}$ 
    end for
    for all  $j = 1, \dots, K$  do
       $v_1, \dots, v_N = \text{grad}M_\rho \{d_1(\mathbf{c}_j), \dots, d_N(\mathbf{c}_j)\}$ 
       $\mathbf{c}_j \leftarrow \arg \min_{\mathbf{c}} \sum_{k=1}^N v_k v_{kj} d_k(\mathbf{c})$ 
    end for
     $t \leftarrow t + 1$ 
  until положения центров не стабилизируются
  return  $\mathbf{c}_1, \dots, \mathbf{c}_K$ 
end procedure

```

Таким образом, применение M-средних позволило построить процедуры поиска центров кластеров, которые обобщают HCD и SKM, позволяя использовать широкий спектр методов поиска среднего значения для нечеткого отнесения точек к кластерам и методов поиска центра для конечного набора точек.

Работа выполнена при поддержке гранта РФФИ 15-01-03381.

Список литературы

- [1] Teboulle M., "A Unified Continuous Optimization Framework for Center-Based Clustering Method", *Journal of Machine Learning Research*, 2007, № 8, 65–102.
- [2] Mesiar R., Komornikova M., Kolesarova A., Calvo T., *Aggregation functions: A revision. In H. Bustince, F. Herrera, J. Montero, editors, Fuzzy Sets and Their Extensions: Representation, Aggregation and Models.*, Springer, Berlin, Heidelberg, 2008.
- [3] Grabich M., Marichal J.-L., Pap E., *Aggregation Functions. Series: Encyclopedia of Mathematics and its Applications.* V. 127, Cambridge University Press, 2009.
- [4] Шибзухов З.М., "О принципе минимизации эмпирического риска на основе усредняющих агрегирующих функций.", *Доклады РАН*, **476**:5 (2017). [Shibzukhov Z.M., "O printsipe minimizatsii empiricheskogo riska na osnove usrednyayushchikh agregiruyushchikh funktsiy.", *Doklady RAN*, **476**:5 (2017)].
- [5] Calvo T., Beliakov G., "Aggregation functions based on penalties", *Fuzzy Sets and Systems*, **161**:10 (2010), 1420–1436.
- [6] Beliakov G., Sola H., Calvo T., *A Practical Guide to Averaging Functions*, Springer, 2016.
- [7] Bezdek J.C., *Pattern Recognition with Fuzzy Objective Function Algorithms*, Plenum Press, New York, 1981.
- [8] Duda R.O., Hart P.E., Stork D.G., *Pattern Classification.*, John Wiley & Sons, Inc., 2-nd edition, 2001..
- [9] Rose K., Gurewitz E., Fox C.G., "A deterministic annealing approach to clustering", *Pattern Recognition Letters*, **11**:9 (1990), 589–594.

- [10] Banerjee A., Merugu S., Dhillon I.S., Ghosh J., "Clustering with Bregman Divergences", *Journal of Machine Learning Research*, 2005, № 6, 1705–1749.

Список литературы (ГОСТ)

- [1] Teboulle M. A Unified Continuous Optimization Framework for Center-Based Clustering Method // *Journal of Machine Learning Research*. 2007. no 8. pp. 65–102.
- [2] Mesiar R., Komornikova M., Kolesarova A., Calvo T. Aggregation functions: A revision. In H. Bustince, F. Herrera, J. Montero, editors, *Fuzzy Sets and Their Extensions: Representation, Aggregation and Models*. Berlin, Heidelberg: Springer, 2008.
- [3] Grabich M., Marichal J.-L., Pap E. *Aggregation Functions*. Series: Encyclopedia of Mathematics and its Applications. No.127. Cambridge University Press, 2009.
- [4] Шибзухов З.М. О принципе минимизации эмпирического риска на основе усредняющих агрегирующих функций. Доклады РАН. 2017. Т. 476. № 5.
- [5] Calvo T., Beliakov G. Aggregation functions based on penalties // *Fuzzy Sets and Systems*. 2010. vol. 161 no. 10. pp. 1420–1436.
- [6] Beliakov G., Sola H., Calvo T. *A Practical Guide to Averaging Functions* Springer, 2016.
- [7] Bezdek J.C. *Pattern Recognition with Fuzzy Objective Function Algorithms*. N.York: Plenum Press, 1981.
- [8] Duda R.O., Hart P.E., Stork D.G. *Pattern Classification*. John Wiley & Sons, Inc., 2-nd edition, 2001.
- [9] Rose K., Gurewitz E., Fox C.G. A deterministic annealing approach to clustering // *Pattern Recognition Letters*. 1990. vol. 11. no 9. pp. 589–594.
- [10] Banerjee A., Merugu S., Dhillon I.S., Ghosh J. Clustering with Bregman Divergences // *Journal of Machine Learning Research*. 2005. no 6. pp. 1705–1749

Для цитирования: Шибзухов З. М. Классификация на основе поиска центров и усредняющие агрегирующие функции // *Вестник КРАУНЦ. Физ.-мат. науки*. 2017. № 3(19). С. 70-77. DOI: 10.18454/2079-6641-2017-19-3-70-77

For citation: Shibzukhov Z. M. Center based clustering and averaging aggregation functions, *Vestnik KRAUNC. Fiz.-mat. nauki*. 2017, **19**: 3, 70-77. DOI: 10.18454/2079-6641-2017-19-3-70-77

Поступила в редакцию / Original article submitted: 05.10.2017