

НЕЧІТКА ІМОВІРНІСНО-МОЖЛИВІСНА ПОСЛІДОВНА КЛАСТЕРИЗАЦІЯ ДАНИХ НА ОСНОВІ АНСАМБЛЕВОГО ПІДХОДУ

П. С. ЖЕРНОВА, Є. В. БОДЯНСЬКИЙ

У роботі запропонована нейро-фаззі мережа для кластерування потоку даних у ситуації, коли дані подаються до обробки в онлайн режимі у припущенні про невідому кількість та форму кластерів. Основна ідея базується на модифікації нечіткого алгоритму C-means з використанням імовірно-можливісного підходу, а також використанням ансамблевого підходу для кластерування даних. Для оцінки якості кластерування був використаний індекс Kсі-Бені. Експериментальні результати підтвердили факт ефективності запропонованої системи для вирішення широкого кола завдань Data Stream Mining, коли набори даних обробляються у послідовному режимі та містять велику кількість спостережень.

Ключові слова: кластерування; нечіткий метод C-means; ансамбль нейро-фаззі мереж; нейронна мережа Т. Кохонена; самонавчання.

ВСТУП

Завдання кластерування багатовимірних спостережень, які послідовно надходять на обробку, є важливим напрямком у рамках Data Stream Mining, а для її вирішення розроблено досить велику кількість різних методів. Найбільш популярним тут є підхід, заснований на прототипах-центроїдах [1–4], як які можуть використовуватися K-середні, K-медіани, K-медоїди тощо. Необхідно відзначити кластерувальні нейронні мережі Т. Кохонена [5], які найкраще пристосовані для обробки інформації в online режимі. При цьому апріорно передбачається, що кількість кластерів, на яку розбивається аналізований масив даних, відома заздалегідь. У разі, якщо число кластерів апріорі не відомо, може бути використаний метод X-середніх [6, 7], в основі якого лежать досить жорсткі статистичні припущення. Крім того, цей метод може бути реалізований тільки у пакетному режимі. У разі, якщо інформація на обробку подається послідовно, як альтернатива X-середнім може бути використаний підхід, заснований на кластерувальних ансамблях [8–11], при цьому кожен з членів ансамблю налаштований на різне число можливих кластерів. Якщо членами ансамблю є нейронні мережі Т. Кохонена – SOM, кожна з яких працює в припущенні різного числа класів у даних, така система може ефективно функціонувати в режимі реального часу.

Таким чином, якщо задана вибірка даних (можливо зростаюча) $X = \{x(1), \dots, x(2), \dots, x(k), \dots, x(N), \dots\} \subset R^n$

$x(k) = (x_1(k), \dots, x_i(k), \dots, x_n(k))^T$, яка подається на входи ансамблю, утвореного M-1 паралельно з'єднаними SOM так, що перша з них працює в припущенні, що число можливих кластерів в даних $m = 2$, а остання передбачає, що $m = M$, найкращі результати будуть

отримані за допомогою SOM з $2 \leq m^* \leq M$ нейронами в шарі Кохонена, де m^* визначає істинну кількість класів в оброблюваній вибірці [12].

Ситуація істотно ускладнюється, якщо кластери, які формуються, перетинаються у просторі ознак. Такі завдання вирішуються за допомогою методів нечіткої кластеризації [4, 13], найбільш популярним з яких є алгоритм нечітких C-середніх (FCM). Для роботи в online режимі з успіхом можуть бути використані нечіткі кластерувальні мапи Кохонена [14].

Тому є доцільною розробка ансамблю нечітких карт Кохонена з використанням тих або інших цільових функцій для вирішення задач кластеризації за умов невідомої кількості класів, що довільним чином перетинаються у просторі ознак.

1. НЕЧІТКА КЛАСТЕРУВАЛЬНА НЕЙРОННА МЕРЕЖА Т. КОХОНЕНА ДЛЯ ОБРОБКИ ПОТОКУ ДАНИХ

У класі процедур нечіткого кластерування з математичної точки зору найбільш коректними є алгоритми, засновані на цільових функціях [4] та які вирішують задачу їх оптимізації за наявності тих чи інших обмежень. Тут найбільш популярним є імовірно-можливісний алгоритм нечіткого кластерування, заснований на оптимізації цільової функції

$$E(u_j(k), w_j) = \sum_{k=1}^N \sum_{j=1}^m u_j^\beta(k) \|x(k) - w_j\|^2 = \sum_{k=1}^N \sum_{j=1}^m u_j^\beta(k) \sum_{i=1}^n (x_i(k) - w_{ji})^2 \quad (1)$$

за наявності обмежень

$$\sum_{j=1}^m u_j(k) = 1, \quad (2)$$

$$0 \leq \sum_{k=1}^N u_j(k) \leq N. \quad (3)$$

Тут $u_j(k) \in [0, 1]$ – рівень нечіткої належності вектора спостережень $x(k)$ до j -го кластера, w_j – центроїд j -го кластера, β – фаззіфікатор, що визначає розмитість меж між кластерами.

Розв’язання задачі оптимізації (1) за наявності обмежень (2), (3) за допомогою невизначених множників Лагранжа веде до результату

$$\begin{cases} u_j(k) = \frac{\left(\|x(k) - w_j\|^2\right)^{\frac{1}{1-\beta}}}{\sum_{l=1}^m \left(\|x(k) - w_l\|^2\right)^{\frac{1}{1-\beta}}}, \\ w_j = \frac{\sum_{k=1}^N u_j^\beta(k) x(k)}{\sum_{k=1}^N u_j^\beta(k)}, \end{cases} \quad (4)$$

який при $\beta = 2$ повністю збігається з FCM Дж. Бездека.

В найпростішому випадку двох кластерів ($m = 2$) легко бачити, що спостереження $x(k)$, що рівноправно належить до обох кластерів, і спостереження $x(p)$, що не належить жодному з них, можуть мати однакові рівні належності $u_1(k) = u_2(k) = u_1(p) = u_2(p) = 0.5$. Очевидно, що ця особливість може суттєво знизити якість класифікації за допомогою імовірнісного підходу, пов’язаного з цільовою функцією (1). Водночас можливий підхід до нечіткої кластиризації [15–17] допомагає уникнути зазначеної вище ситуації і тим самим покращити якість класифікації.

Для імовірнісного підходу до кластиризації критерій, що мінімізується, має вигляд

$$E(u_j(k), w_j) = \sum_{k=1}^N \sum_{j=1}^m u_j^\beta(k) \|x(k) - w_j\|^2 + \sum_{j=1}^m \mu_j \sum_{k=1}^N (1 - u_j(k))^\beta, \quad (5)$$

де скалярний параметр $\mu_j > 0$ визначає відстань, на якій рівень належності приймає значення 0.5 , тобто якщо $\|x(k) - w_j\|^2 = \mu_j$, то $u_j(k) = 0.5$.

Мінімізація критерію (5) за змінними $u_j(k)$, w_j , μ_j призводить до системи рівнянь:

$$\begin{cases} \frac{\partial E(u_j(k), w_j)}{\partial u_j(k)} = 0, \\ \frac{\partial E(u_j(k), w_j)}{\partial \mu(k)} = 0, \\ \nabla_{w_j} E(u_j(k), w_j) = \vec{0}, \end{cases} \quad (6)$$

а розв’язок перших двох рівнянь дає відомий результат:

$$u_j^{pos}(k) = \left(1 + \left(\frac{\|x(k) - w_j\|^2}{\mu_j} \right)^{\frac{1}{\beta-1}} \right)^{-1}, \quad (7)$$

$$\mu_j = \frac{\sum_{k=1}^N u_j^\beta(k) \|x(k) - w_j\|^2}{\sum_{k=1}^N u_j^\beta(k)}. \quad (8)$$

Розв’язок третього рівняння системи (6) для евклідової норми має вигляд:

$$w_j^{pos} = \frac{\sum_{k=1}^N u_j^\beta(k) x(k)}{\sum_{k=1}^N u_j^\beta(k)}. \quad (9)$$

Можна бачити, що можливісні та імовірнісні методи достатньо схожі та переходять один в інший шляхом заміни виразу (7) на формулу (4), і навпаки. Загальним недоліком розглянутих методів є неможливість роботи в реальному часі, коли дані надходять, у формі потоку спостережень.

Робота процедури кластиризації розпочинається із завдання початкової (зазвичай випадкової) матриці розбиття W^0 . На основі її значень обчислюється початковий набір прототипів w_j^0 , які потім використовуються для уточнення нової матриці W^1 . Наступним кроком у пакетному режимі є обчислення W^2, \dots, W^t, W^{t+1} і так далі, доки різниця $\|W^{t+1} - W^t\|$ не стане меншою за деяке наперед задане порогове значення ε . Таким чином, вся вибірка даних оброблюється багаторазово.

Розв’язок, що може бути отриманий за допомогою імовірнісного методу, рекомендується використовувати як початкові умови для імовірнісного методу (7)–(9) [17, 18], при чому початкові значення параметрів відстані μ_j^t обираються відповідно до (8) за результатами роботи імовірнісної процедури.

Аналіз (4) показує, що для обчислення рівнів належності $u_j(k)$ замість звичайної функції Лагранжа можна використовувати її локальну модифікацію:

$$L_k(u_j(k), w_j, \lambda(k)) = \sum_{j=1}^m u_j^\beta(k) \|x(k) - w_j\|^2 + \lambda(k) \left(\sum_{j=1}^m u_j(k) - I \right). \quad (10)$$

Оптимізація виразу (10) за допомогою процедури Ерроу-Гурвіца-Удзави [17, 19] веде до процедури:

$$u_j^{pr}(k) = \frac{\left(\|x(k) - w_j(k)\|^2 \right)^{\frac{1}{I-\beta}}}{\sum_{l=1}^m \left(\|x(k) - w_l(k)\|^2 \right)^{\frac{1}{I-\beta}}}, \quad (11)$$

$$\begin{aligned} w_j^{pr}(k+1) &= \\ &= w_j^{pr}(k) - \eta(k) \nabla_{w_j} L_k(u_j(k), w_j^{pr}(k), \lambda(k)) = \\ &= w_j^{pr}(k) - \eta(k) u_j^\beta(k) \|x(k+1) - w_j^{pr}(k)\| \times \\ &\quad \times \nabla_{w_j} \|x(k+1) - w_j^{pr}(k)\|, \end{aligned} \quad (12)$$

де $\eta(k)$ – параметр кроку навчання; $w_j^{pr}(k)$ – прототи-ти j -го кластера, що обчислюються на вибірці з k спостережень.

Процедура (11)–(12) схожа на процедуру навчання Чанга-Лі [20] і для $\beta = p = 2$ збігається з градієнтною процедурою кластеризації Парка-Деггера [21]:

$$u_j^{pr}(k) = \frac{\|x(k) - c_j(k)\|^{-2}}{\sum_{l=1}^m \|x(k) - c_l(k)\|^{-2}}, \quad (13)$$

$$\begin{aligned} w_j^{pr}(k+1) &= \\ &= w_j^{pr}(k) + \eta(k) u_j^2(k) (x(k+1) - w_j^{pr}(k)). \end{aligned} \quad (14)$$

Нескладно бачити, що процедура (14) є не що інше, як WTM-правило самонавчання Т. Кохонена з функцією сусідства $u_j^2(k)$.

У межах можливісного підходу локальний критерій набуває вигляду

$$\begin{aligned} E_k(u_j(k), w_j) &= \\ &= \sum_{j=1}^m u_j^\beta(k) \|x(k) - w_j\|^2 + \sum_{j=1}^m \mu_j (I - u_j(k))^\beta, \end{aligned} \quad (15)$$

а результат його оптимізації записується як

$$u_j^{pos}(k) = \left(I + \left(\frac{\|x(k) - w_j(k)\|^2}{\mu_j(k)} \right)^{\frac{1}{\beta-1}} \right)^{-1}, \quad (16)$$

$$\begin{aligned} w_j^{pos}(k+1) &= \\ &= w_j^{pos}(k) - \eta(k) u_j^\beta(k) \|x(k+1) - w_j^{pos}(k)\| \times \\ &\quad \times \nabla_{w_j} \|x(k+1) - w_j^{pos}(k)\|, \end{aligned} \quad (17)$$

$$\mu_j(k+1) = \frac{\sum_{p=1}^k u_j^\beta(p) \|x(p) - w_j(k+1)\|^2}{\sum_{p=1}^k u_j^\beta(p)}. \quad (18)$$

У квадратичному випадку (при $\beta = 2$) процедура (16)–(18) перетворюється в достатньо просту конструкцію

$$u_j^{pos}(k) = \frac{\mu_j(k)}{\mu_j(k) + \|x(k) - w_j(k)\|^2}, \quad (19)$$

$$\begin{aligned} w_j^{pos}(k+1) &= \\ &= w_j^{pos}(k) + \eta(k) u_j^2(k) (x(k+1) - w_j^{pos}(k)), \end{aligned} \quad (20)$$

$$\mu_j(k+1) = \frac{\sum_{p=1}^k u_j^2(p) \|x(p) - w_j(k+1)\|^2}{\sum_{p=1}^k u_j^2(p)}. \quad (21)$$

Паралельне застосування адаптивних імовірнісної і можливісної процедур призводить до об'єднаної процедури нечіткої кластеризації [22]

$$\left\{ \begin{aligned} w_j^{pr}(k) &= w_j^{pos}(k-1) - \eta(k) u_j^{pos\beta}(k-1) \|x(k) - w_j^{pos}(k-1)\| \times \nabla_{w_j} \|x(k) - w_j^{pos}(k-1)\|, \\ u_j^{pr}(k) &= \left(\|x(k) - w_j^{pr}(k)\|^2 \right)^{\frac{1}{1-\beta}} \times \left(\sum_{l=1}^m \left(\|x(k) - w_l^{pr}(k)\|^2 \right)^{\frac{1}{1-\beta}} \right)^{-1}, \\ w_j^{pos}(k) &= w_j^{pr}(k-1) - \eta(k) u_j^{pr\beta}(k) \|x(k) - w_j^{pr}(k)\| \times \nabla_{w_j} \|x(k) - w_j^{pr}(k)\|, \\ \mu_j(k) &= \left(\sum_{p=1}^k u_j^{pr\beta}(p) \|x(k) - w_j^{pos}(k)\|^2 \right) \times \left(\sum_{p=1}^k u_j^{pr\beta} \right)^{-1}, \\ u_j^{pos}(k) &= \left(1 + \left(\frac{\|x(k) - w_j^{pos}(k)\|^2}{\mu_j(k)} \right) \right)^{-1}, \quad j = 1, 2, \dots, m. \end{aligned} \right. \quad (22)$$

Ознакою правильного знаходження прототипів (а отже і коректної кластеризації), використовуючи процедуру (22), є виконання нерівності

$$\sum_{l=1}^m \|w_l^{pr}(k) - w_l^{pos}(k)\| \leq \varepsilon, \quad (23)$$

де ε визначає прийнятну точність кластеризації.

Для евклідової метрики значення параметра $\mu_j(k)$ може обчислюватися відповідно до рекурентного співвідношення, яке безпосередньо впливає з (21):

$$\left\{ \begin{aligned} \beta_q(k) &= \beta_q(k-1) + u_j^{pr2}(k) s_q(x(k)), \\ q &= 0, 1, 2, \\ \mu_j(k) &= \\ &= \frac{\beta_2(k-1) - 2w_j^{posT}(k)\beta_1(k-1) + \|w_j^{pos}(k)\|^2 \beta_0(k-1)}{\beta_0(k-1)}, \end{aligned} \right. \quad (24)$$

де

$$s_q(x(k)) = \begin{cases} 1, & \text{якщо } q = 0, \\ x(k), & \text{якщо } q = 1, \\ \|x(k)\|^2, & \text{якщо } q = 2. \end{cases} \quad (25)$$

Початкові значення параметра $\beta_q(k)$ обираються як

$$\beta_q(N) = \sum_{p=1}^N \left(u_j^{pr}(p) \right)^2 s_q(x(p)), \quad q = 0, 1, 2. \quad (26)$$

Таким чином, процедура (22) може працювати як в пакетному режимі для ітеративної обробки заданої вибірки, так і в послідовному режимі, де кількість спостережень визначається дискретним часом $k = 1, 2, \dots, N, N+1, \dots$. В останньому випадку за допомогою цієї

процедури послідовно оброблюються спостереження, що надходять на опрацювання. Отже, у випадку нестационарних даних рівні належності та прототипи кластерів перестроюються відповідно до нових даних.

2. АРХІТЕКТУРА АНСАМБЛЮ НЕЧІТКИХ КАРТ КОХОНЕНА

Для вирішення завдання кластеризації в умовах, коли кількість кластерів невідома, пропонується використовувати ансамбль кластерувальних нейро-фаззі мереж Кохонена. Даний ансамбль містить $(M-1)$ $FSOM^{[m]}$, де індекс $[m]$ означає кількість кластерів, на яку ця мережа розбиває оброблювану вибірку – тобто кількість нейронів у шарі Кохонена KL, а p -індекс конкретного фаззіфікатора, що приймає q значень. Всі $FSOM^{[m]}$ навчаються за допомогою однотипних процедур (7), (8), які відрізняються один від одного тільки значеннями m та α .

Далі оцінюється якість кластерування, що забезпечується конкретною FSOM, а вихідний шар ансамблю з $(M-1)$ результатів попередніх шарів виділяє найкращий, тобто кількість кластерів m^* в оброблюваних даних, центроїди сформованих кластерів $w_1^*, w_2^*, \dots, w_{m^*}^*$ і рівні належності кожного спостереження $u_1^*(k), u_2^*(k), \dots, u_{m^*}^*(k)$ до відповідного кластеру.

Для оцінки якості кластерування кожним з елементів ансамблю може бути використаний будь-який з індексів нечіткого кластерування [2], де одним з найбільш популярних є індекс Ксі-Бені (Xie-Beni index) [21], який для FCM-процедури в разі m кластерів може бути записаний у формі

$$XB^{[m]} = \frac{\left(\sum_{k=1}^N \sum_{j=1}^m u_j^2(k) \|x(k) - w_j\|^2 \right) / N}{\min_{l \neq j} \|w_j - w_l\|^2} =$$

$$= \frac{NXB^{[m]}}{DXB^{[m]}} \quad (27)$$

Для послідовної обробки можна ввести online версію XB-індексу у вигляді

$$XB^{[m]}(k) = \frac{NXB^{[m]}(k)}{DXB^{[m]}(k)} = \frac{NXB^{[m]}(k-1)}{\min_{l \neq j} \|w_j(k) - w_l(k)\|^2} + \frac{\frac{1}{k} \left(\sum_{j=1}^m u_j^2(k) \|x(k) - w_j(k)\|^2 - NXB^{[m]}(k-1) \right)}{\min_{l \neq j} \|w_j(k) - w_l(k)\|^2} \quad (28)$$

Чим менше значення (27), (28), тим вище якість кластерування.

В процесі обробки даних вихідний блок ансамблю знаходить $FSOM^{[m]}$ з найкращим значенням $MEXB^{[m]}$ і результати роботи саме цієї нейро-фаззи мережі визначають кінцевий результат кластерування.

3. РЕЗУЛЬТАТИ МОДЕЛЮВАННЯ

Для вирішення проблеми визначення оптимального числа кластерів у наборах даних ми використали запропонований ансамбль для онлайн-нечіткого кластерування. Ми обрали набір даних Wine [23] з UCI Machine Repository. Вона містить 178 спостережень, кількість ознак – 13.

На рис. 1 та 2 наведено візуалізацію з використанням аналізу головних компонент (PCA-аналіз, три головні компоненти). На рис. 2 наведено результати роботи імовірнісного ансамблю нейро-фаззи мереж, де можна побачити, що цей підхід не виявив присутність третього кластера у даній вибірці. На рис. 3 наведено результати роботи можливісного підходу до кластерування нейро-фаззи ансамблю мереж. За допомогою цього підходу точність кластеризації була більш точною.

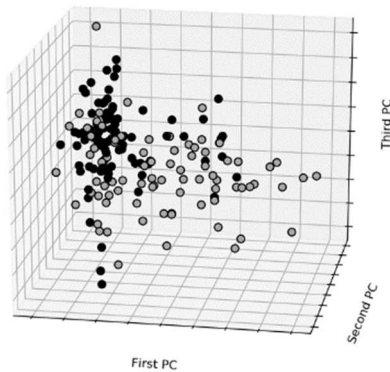


Рис. 1. Імовірнісний підхід для кластеризації даних




Рис. 2. Можливісний підхід для кластеризації даних

ВИСНОВКИ

Запропоновані архітектура та алгоритм самонавчання нейро-фаззи системи, призначеної для вирішення завдання online кластерування потоку даних в умовах, коли кластери, які формуються, перекриваються та їхня кількість заздалегідь невідома. Запропонована система є ансамблем нейро-фаззи самоорганізованих мап Т. Кохонена, кожна з яких відрізняється від інших кількістю нейронів. Налаштування кожного з членів ансамблю відбувається за допомогою модифікованого WTM правила самонавчання, при цьому в процесі налаштування проводиться автоматичне зважування усіх компонент оброблюваних векторів.

Запропонований підхід є узагальненням низки відомих процедур нечіткого імовірнісного та можливісного кластерування і може бути використаний для розв'язання задач аналізу потоків даних.

Література

- [1] Gan, G.; Ma, Ch.; Wu, J. Data Clustering. Theory, Algorithms and Application; SIAM, Philadelphia, 2007; 489 p.
- [2] Xu, R.; Wunsch, D.C. Clustering. IEEE Press Series on Computational Intelligence; John Wiley & Sons, Inc., Hoboken, NJ, 2009; 368 p.
- [3] Bifet, A. Adaptive Stream Mining. Pattern Learning and Mining from Evolving Data Streams, Amsterdam, IOS Press, 2010; 224 p.
- [4] Bezdek, J. C. Pattern Recognition with Fuzzy Objective Function Algorithms. N.Y., Plenum Press, 1981; 272 p
- [5] Kohonen, T. Self-Organizing Maps. Springer-Verlag, Berlin, 1995; 362 p.
- [6] Pelleg, D.; Moor, A. X-means: extending K-means with efficient estimation of the number of clusters. Proc. 17th Int. Conf. on Machine Learning, Morgan Kaufmann, San Francisco, 2000; pp. 727–730.
- [7] Ishioka, T. An expansion of X-means for automatically determining the optimal number of clusters. Proc. 4th IASTED Int. Conf. Computational Intelligence, Calgary, Alberta, 2005; pp. 91–96.
- [8] Strehl, A.; Ghosh, J. Cluster Ensembles – A knowledge reuse framework for combining multiple partitions. Journal of Machine Learning Research, 2002; pp. 583–617.
- [9] Topchy, A.; Jain, A.K.; Punch, W. Clustering ensembles: models of consensus and weak partitions. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27, pp. 1866–1881.

- [10] Alizadeh, H.; Minaei-Bidgoli, B.; Parvin, H. To improve the quality of cluster ensembles by selecting a subset of base clusters. *Journal of Experimental & Theoretical Artificial Intelligence*, 2013, 26, pp. 127–150.
- [11] Charkhabi, M.; Dhot, T.; Mojarad, S.A. Cluster ensembles, majority vote, voter eligibility and privileged voters. *Int. Journal of Machine Learning and Computing*, 2014, 4, pp. 275–278
- [12] Zhernova, P.; Deyneko, A.; Bodyanskiy, Ye.; Riepin, V. Adaptive kernel data streams clustering based on neural networks ensembles in conditions of uncertainty about amount and shapes of clusters. *IEEE Second International Conference on Data Stream Mining & Processing*, August 21-25, Lviv, Ukraine, 2018; pp. 7–12.
- [13] Bezdek, J.; Keller, J.; Krisnapuram, R.; Pal, N. *Fuzzy Models and Algorithms for Pattern Recognition and Image Processing*. Springer, 2005; 776 p.
- [14] Gorshkov, Ye.; Kolodyazhniy, V.; Bodyanskiy, Ye. New recursive learning algorithms for fuzzy Kohonen clustering network. In *Proc. 17th Int. Workshop on Nonlinear Dynamics of Electronic Systems*. Rapperwil, Switzerland, 2009; pp. 58–61.
- [15] Krishnapuram R. A. possibilistic approach to clustering / R. Krishnapuram, J. Keller // *IEEE Trans. on Fuzzy Systems*. – 1993. – Vol. 1. – P. 98–110.
- [16] Krishnapuram, R. Fuzzy and possibilistic clustering methods for computer vision / R. Krishnapuram, J. Keller // *Neural Fuzzy Systems*. – 1994. – Vol. 12. – P. 133–159.
- [17] Bodyanskiy, Ye. Recursive fuzzy clustering algorithms / Ye. Bodyanskiy, V. Kolodyazhniy, A. Stephan // *Proc. East West Fuzzy Coll. 2002, 10-th East-West Fuzzy Coll.* – Zittau/Goerlitz: HS. - 2002. – P. 276–283.
- [18] Klawonn, F. Constructing a fuzzy controller from data / F. Klawonn, R. Kruse // *Fuzzy Sets and Systems*. – 1997. – Vol. 85. – P. 117–193.
- [19] Arrow, K.J. *Studies in Linear and Nonlinear Programming* / K.J. Arrow, L. Hurwitz, H. Uzawa. – Stanford, CA: Stanford University Press, 1958. – 242 p.
- [20] Chung, F.L. Fuzzy competitive learning / F.L. Chung, T. Lee // *Neural Networks*. – 1994. – Vol. 7. - No. 3. – P. 539–552.
- [21] Park, D. C. Gradient based fuzzy c-means (GBFCM) algorithm / D.C. Park, I. Dagher // *Proc. IEEE Int. Conf. on Neural Networks*. – Orlando, FL, USA: IEEE Press. – 1994. – P. 1626–1631.
- [22] Outlier resistant recursive fuzzy clustering algorithms / [Ye. Bodyanskiy, Ye. Gorshkov, I. Kokshenev, V. Kolodyazhniy] // *Computational Intelligence, Theory and Applications. Advances in Soft Computing* [Ed. Reusch B.]. – Berlin; Heidelberg: Springer-Verlag. – 2006. – Vol. 38. – P. 647–652.
- [23] Xie, X.L.; Beni, G. A. Validity Measure for Fuzzy Clustering. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1991, 13, pp. 841–847.

Надійшла до редколегії 26.12.2018



Жернова Поліна Євгенівна, асистент кафедри системотехніки Харківського національного університету радіоелектроніки, м.н.с. ПНДІ АСУ. Галузь наукових інтересів – інтелектуальний аналіз даних, системи обчислювального інтелекту, нейро-фаззі системи, он-лайн-системи для задач кластерування потоків даних.



Бодяньський Євгеній Володимирович, доктор технічних наук, професор, професор кафедри штучного інтелекту Харківського національного університету радіоелектроніки, науковий керівник ПНДІ АСУ, IEEE Senior Member. Галузь наукових інтересів – гібридні системи обчислювального інтелекту, Data Stream Mining, Big Data, Deep Learning, Evolving Systems.

УДК 004.032.26

Жернова П. Е. **Нечеткая вероятностно-возможностная последовательная кластеризация данных на основе ансамблевого подхода** / П. Е. Жернова, Е. В. Бодянский // *Прикладная радиоэлектроника: науч. – техн. журнал.* – 2019. – Том 18, № 1, 2. – С. 40–45.

В статье рассмотрена задача кластеризации данных с использованием ансамблей нейронных сетей Т. Кохонена, при условии, что данные поступают в онлайн режиме наблюдение за наблюдением. Предложен вероятностно-возможностный нейро-фаззи подход для решения проблемы обработки данных большой размерности. Для определения качества кластеризации был использован модифицированный индекс Кси-Бени для онлайн процедуры.

Ключевые слова: кластеризация; нечеткий метод С-средних; ансамбль нейро-фаззи сетей; нейронная сеть Т. Кохонена; самообучение.

Ил.: 02. Библиогр.: 23 назв.

UDC 004.032.26

Zhernova P. **Fuzzy probabilistic-possibilistic sequential clustering of data based on an ensemble approach** / P. Zhernova, Ye. Bodyanskiy // *Applied Radio Electronics: Sci. Journ.* – 2019. – Vol. 18, № 1, 2. – P. 40–45.

The article deals with the clustering of data while using the ensembles of T. Kohonen's neural networks, provided that the data is fed in an online mode supervision after supervision. A probabilistic-possibilistic neuro-fuzzy approach was used to solve a large scale data processing problem. In order to determine the quality of clustering, a modified Xie-Beni index was applied for the online procedure.

Keywords: clustering; fuzzy C-means method; neuro-fuzzy networks ensemble; T. Kohonen's neural network; self-learning.

Fig.: 02. Ref.: 23 items.