



ОПРЕДЕЛЕНИЕ ЧИСЛА НЕЙРОНОВ ВЕРОЯТНОСТНОЙ НЕЙРОННОЙ СЕТИ

Галина Щербакова, Виктор Крылов, Олег Логвинов

Одесский национальный политехнический университет
пр. Шевченко, 1, Одесса, 65044, Украина,
e-mail: Galina_onpu@mail.ru

Резюме: Разработан метод определения числа нейронов внутреннего слоя для вероятностной нейронной сети на основе определения количества групп данных путем оценки нарушения локальной плотности распределения данных в λ -пространстве на основе помехоустойчивого субградиентного итеративного метода оптимизации. Разработанный метод позволил упростить структуру вероятностной нейронной сети и снизить время классификации.

Ключевые слова: вероятностная нейронная сеть, кластеризация, компактность, количество нейронов, субградиентный метод оптимизации.

THE PROBABILISTIC NEURAL NET NEURON'S NUMBER CALCULATIONS

Galina Shcherbacova, Victor Krylov, Oleg Logvinov

Odessa National Polytechnic University,
Prospect Shevchenko, 1, Odessa, 65044, Ukraine,
e-mail: Galina_onpu@mail.ru

Abstract: The sub-gradient method of estimation of the number of the hidden layer neurons of a probabilistic neural network is suggested. This method allows evaluating the data compactness violation in λ -space. This evaluation based on the noise stability sub-gradient iterative optimization method. This method allows reducing the number of the hidden layer neurons and classification time.

Keyword: probabilistic neural net, clustering, compactness, neuron's number, sub-gradient optimization method.

ВВЕДЕНИЕ

Автоматизация технического диагностирования (ТД) по многомерным, коррелированным между собой параметрам при контроле технологических процессов производства, контроле качества, диагностировании неисправностей изделий предполагает использование методов классификации, которые часто реализуют на основе нейронных сетей (НС) [1-8]. Это обусловлено гибкой структурой НС и возможностью быстро переобучать классификатор на их основе при изменении производственной ситуации.

Чаще всего для такой классификации

используют разновидность радиально-базисных НС – вероятностные НС (ВНС), реализующие классификатор Байеса, и многослойные НС с обучением на основе обратного распространения ошибки [4, 8, 9]. Основные особенности разработки таких многослойных НС – необходимость итеративного выбора числа внутренних слоев [9], значительная длительность обучения при разработке и дополнительного обучения НС при изменении производственной ситуации, отыскание локального оптимума функционала качества при обучении. В отличие от них ВНС обучаются быстро и имеют только один внутренний слой. Максимальное количество нейронов этого слоя ВНС

определяется количеством векторов исходных данных. Такой вариант ВНС отличается (в случае больших наборов данных для обучения НС) значительной сложностью структуры сети и большим временем, необходимым для принятия диагностического решения. Поэтому при разработке ВНС важно сократить количество таких нейронов путем группировки близких по значениям данных. Это позволяет упростить структуру ВНС и сократить вычислительные затраты при ее эксплуатации [5, 8].

Для такой группировки и определения количества групп в данных чаще всего используют кластеризацию [6, 8]. Основывается процедура кластеризации, как правило, на гипотезе компактности, когда данные одного кластера сближены, а разных кластеров – разнесены в пространстве признаков [6, 7]. Помехоустойчивость и точность процедуры группировки обусловлены свойствами показателей оптимальности количества кластеров [6]. Эти свойства определяются способами оценки компактности данных кластера и расстояния между кластерами. При оценке этих параметров по единичным максимально сближенным или удаленным в пространстве признаков данным – понижается помехоустойчивость, если при оценке учитываются параметры всего набора данных (с расчетом среднего значения, медианы и других) – повышается помехоустойчивость, но снижается точность. Из-за противоречивости этих свойств даже в случае компактных, удаленных друг от друга кластеров значительное число этих показателей дает неверный результат [6, 7, 13, 14]. В связи с этим с целью обеспечения кластеризации в случае кластеров более сложной формы предложена гипотеза λ -компактности, позволяющая проводить границу между кластерами на основе оценки изменения локальной плотности расположения данных в пространстве признаков [15]. Однако функционал [15]

$$F = h^4 \tau^2 d, \quad (1)$$

на основе λ -компактности позволяет получить кластеры с одинаковым количеством объектов, что не оправданно при группировке данных и может усложнить структуру ВНС. Параметры в (1) характеризуют: d – расстояние между данными в пространстве признаков; τ – локальную неоднородность плотности множества; h – равномощность кластеров [15].

В связи с этим определение количества групп в данных предлагается проводить, исследуя

критерий $K = \max(k_i)$ [16],

$$k_i = \frac{f(i+1)}{f(i)}, \quad i \in [1, n-1], \quad (2)$$

где $f(i)$ – среднее λ – расстояние при добавлении i – го значения к группе данных.

Параметр k_i в (2) характеризует нарушения локальной однородности распределения данных в λ -пространстве и число групп в них. Изменение этого параметра в зависимости от i описывается полимодальной, зашумленной зависимостью. В работе [17] для поиска оптимума таких зависимостей при определении количества кластеров предложено использовать разработанный авторами субградиентный метод оптимизации в пространстве вейвлет – преобразования (ВП), с повышенной помехоустойчивостью, низкими погрешностью и чувствительностью к локальным экстремумам [18]. Такой подход позволяет разделить данные на два кластера, так как при оценке k_i для всего набора данных амплитуда последующих мод меньше первой моды в несколько десятков раз. В связи с этим в данной работе предлагается после расчета k_i [16, 17] отыскивать максимумы критерия $K = \max(k_i)$ с помощью этого метода оптимизации [18] итеративно, исключая при оценке k_i данные, отнесенные к предыдущей группе.

Цель работы – разработать метод определения количества групп в данных и упрощения структуры ВНС. Для достижения этой цели проведен анализ существующих методов группировки на основе методов оценки количества кластеров; разработан метод поиска координат оптимумов критерия $K = \max(k_i)$ и на его основе – количества групп в данных для обучения ВНС.

1. АНАЛИЗ МЕТОДОВ ОЦЕНКИ КОЛИЧЕСТВА КЛАСТЕРОВ

Для оценки количества групп в данных введены показатели на основе оценки отношения дисперсии данных внутри кластера к расстоянию между кластерами [6, 14]. Эти показатели отличаются рядом недостатков. Так, процедура определения показателя Губерта [19] отличается слабой степенью формализации (количество кластеров определяется по координате самого острого угла между отрезками кусочно-линейной кривой на графике). Результат определения числа кластеров субтрактивным методом [11]

зависит от нескольких задаваемых эвристически параметров. У показателей Данна и ряда показателей Беждека-Пала – низкая помехоустойчивость, они в основном ориентированы на разделение кластеров гиперсферической формы [6]. Для определения количества кластеров более сложной формы разработаны методы оценки на основе анализа кратчайшего незамкнутого пути, соединяющего точки в пространстве признаков [20]. Однако такой подход понижает помехоустойчивость. В работе [6] оценка количества кластеров была проведена для тестового набора данных X_{30} (рис.1, а) с помощью более чем двадцати показателей.

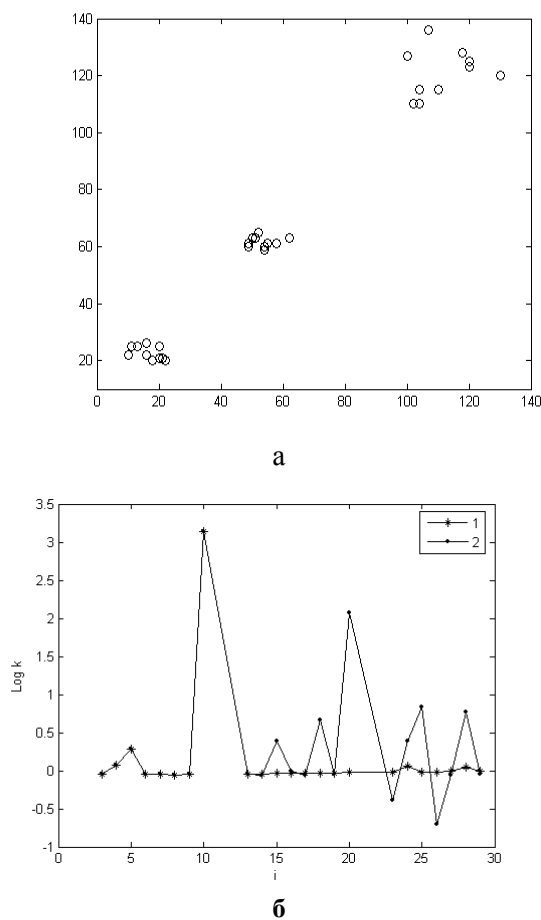


Рис. 1 – Данные (неименованные) [6] для определения количества кластеров (рис. 1, а); значения $\text{Log}(k_i)$ (2) по методике [16] (1 на графике) и по предлагаемой методике (2 на графике) (рис. 2, б)

Эти данные (рис.1, а) неименованные и состоят из трех компактных групп по десять точек в двумерном пространстве признаков.

В результате исследований, проведенных в работе [6] ее авторами верное разделение на кластеры для данных (рис.1, а) показало только около 50% показателей [6].

В связи с этим в работе предлагается определять количество кластеров, перейдя в λ -пространство, оценивая нарушения локальной плотности распределения данных посредством отыскания оптимумов на основе разработанного авторами субградиентного итеративного метода. Поскольку амплитуда второй и последующих мод может быть меньше первой в несколько десятков раз в работе предлагается после расчета k_i [16, 17] отыскивать максимумы критерия $K = \max(k_i)$ последовательно, исключая из суммирования при оценке k_i данные, отнесенные к предыдущей группе (кластеру).

2.МЕТОД ВЫБОРА ЧИСЛА ГРУПП

Метод определения числа кластеров (групп) в данных для классификации с помощью ВНС предполагает следующие этапы.

Этап 1. Отображение параметров данных из евклидова в λ -пространство: построение полного графа в евклидовом пространстве; расчет нормированного расстояния между всеми парами его вершин $d_i = \frac{\alpha_i}{D}$; расчет характеристики локальной плотности множества в окрестности i -го ребра $\tau_i = \frac{\alpha_i}{\beta_{i \min} \tau_{\max}}$ (здесь

α_i - расстояние между i -ой парой вершин; D и $\beta_{i \min}$ - длина самого длинного и самого короткого ребра; τ_{\max} - наибольшее значение $\tau_i^* = \frac{\alpha_i}{\beta_{i \min}}$); расчет длин ребер графа в λ -пространстве как $\lambda_i = \tau_i^2 \times d_i$ [15].

Этап 2. Построение λ - графа кратчайшего незамкнутого пути согласно λp - алгоритму с учетом вероятности разрыва его ребра [16]

$$\rho_{iz} = \frac{\lambda_{iz}}{\sum_{j=1}^k \lambda_{iz}}. \quad (3)$$

Этап 3. Расчет показателя качества k_j (2), если все данные сгруппированы – переход к этапу 5.

Этап 4. Поиск максимума $K = \max(k_i)$ с помощью субградиентного метода оптимизации [18]. В результате исходное множество объектов разделяется на два кластера (группы). Ребро, соединяющее первую группу с остальными

данными, разрывается. Если оставшихся несгруппированными данных более одного – возврат к этапу 3.

Этап 5. Для каждого кластера определяются координаты его центра (как оценка математического ожидания). Полученные математические ожидания используются как координаты центров радиальных элементов скрытого слоя ВНС [10]. Определяется количество кластеров m_1 .

Этап 6. Определяются расстояния между центрами кластеров. Определяется максимальное расстояние между центрами кластеров d_{max} и ширина радиальной базисной функции как

$$\sigma = \frac{d_{max}}{\sqrt{2m_1}} [8].$$

Указанный метод был проверен на примере оценки качества паяных соединений при монтаже интегральных схем (ИС) на поверхность путем исследования их отклика на воздействие импульсного лазерного излучения [21]. Для выявления некачественных паяных соединений с помощью ВНС была решена задача классификации и построена поверхность, разделяющая в пространстве признаков ИС с качественными и дефектными паяными соединениями (рис.2, б).

В качестве признаков при распознавании в работе [21] ее автором (Sheng) были выбраны два. Первый признак – это относительное отклонение отклика на воздействие лазерного излучения эталонной ИС с качественными паяными соединениями и исследуемой ИС – $f(t)$ во временной области

$$Er = \frac{\int (f(t) - r(t))^2 dt}{\int (r(t))^2 dt}. \text{ На рис.2 в соответствии с}$$

терминологией работы [21] этот параметр обозначен как максимальный уровень ошибки. Второй признак – первая собственная частота вибрации ИС с паяными соединениями (преобладающая частота на рис.2 (соответственно обозначениям работы [21])).

При классификации, проведенной по методике автора работы (Sheng) [21] каждый вектор в пространстве признаков соответствует одному нейрону скрытого слоя ВНС. При этом данные, соответствующие качественным паяным соединениям [5,11 0; 5,05 0,1; 5,12 0,15 5,12 0,2] [21] (первый параметр – преобладающая частота вибрации ИС (в сотнях килогерц), второй параметр – максимальный уровень ошибки) представляют собой компактную группу в нижней части рис.2, а. Поэтому количество

нейронов ВНС для ИС с качественными паяными соединениями составило 4, для ИС с некачественными паяными соединениями – 16. Время построения разделяющей поверхности при классификации для такой ВНС по методике работы [21] составило 5,9 с.

После группировки исходных данных предлагаемым в этой работе методом количество нейронов ВНС для качественных соединений – два, с координатами в пространстве признаков [5.08 0.05; 5.12 0.175] и для некачественных паяных соединений – пять с координатами [5.15 1.25; 5.0925 0.905; 5.097 0.55; 4.45 0.55; 4.43 0.88]. Время построения разделяющей поверхности при классификации в этом случае составило 2,56 с. Вероятностная нейронная сеть сформирована на основе методики [10] и стандартных программ пакета MatLab [10, 22].

Расчеты проведены на компьютере Intel Celeron D 326, 2533 MHz, 1 Gb ОЗУ в среде MatLab 7.0 [10, 22]. С использованием стандартных программ этого пакета была также проведена группировка данных о качественных и некачественных паяных соединениях двумя методами: с помощью субтрактивной кластеризации [11, 22] и с помощью агломеративного иерархического метода [6, 7].


При субтрактивной кластеризации последовательно для каждой точки данных в признаковом пространстве вычисляется мера способности представлять центр кластера. Эта мера позволяет оценивать плотность расположения точек данных в пространстве признаков вокруг исследуемой точки. Данный алгоритм, обобщающий метод кластеризации Р. Ягера (R. Yager), основан на выполнении следующих действий: выбрать точку данных с максимальным потенциалом для представления центра первого кластера; удалить все точки данных в окрестности центра первого кластера, величина которой задается параметром rad_{ii} [22], чтобы определить следующий кластер и координаты его центра, пока все точки данных не окажутся внутри окрестностей радиуса rad_{ii} искомым центром кластеров. Количество кластеров при этом зависит от задаваемых эвристически параметров $options$ функции $subclust$ и rad_{ii} [10, 22]. В этой работе набор $options$ принят как [1,25 0,5 0,15 1] по рекомендациям [22], радиус кластера rad_{ii} принят равным 0,1.

При кластеризации агломеративным иерархическим методом [6, 7] вначале предполагается, что каждый кластер содержит одну точку данных в пространстве признаков. Объединение данных в группы заканчивают, получив нужное число кластеров. В стандартной

программе cluster пакета MatLab [10, 22] число кластеров определяется путем задания порогового значения параметра inconsistent, определяемого эвристически. В работе этот параметр принят равным 0,7.

В результате при субтрактивной кластеризации данные разделены на 13 групп следующим образом. Для качественных паяных соединений – на три группы с центрами в [5,05 0,1; 5,11 0; 5,12 0,15] и для некачественных – на десять групп с центрами в [5,1 0,9; 5,12 0,55; 4,42 0,55; 4,3 1,0; 4,6 0,7; 5,15 1,4; 4,55 0,5; 5,15 1,1; 4,4 0,95; 5,05 0,6] соответственно. При иерархической кластеризации получено 14 групп данных. Для качественных паяных соединений было определено три группы с центрами в [5,05 0,1; 5,11 0; 5,12 0,175] и для некачественных – 11 групп с центрами [5,15 1,4; 5,1 0,91; 5,1 0,92; 4,55 0,5; 5,15 1,4; 4,35 0,975; 5,12 0,9; 5,05 0,9; 5,12 0,53; 4,4 0,57; 5,15 1,1]. Координаты центра группы оценивались как среднее по каждому параметру. Время построения разделяющей поверхности составило 3,8 с. и 3,85 с. соответственно.

Таким образом, после группировки исходных данных предлагаемым методом по сравнению с методом, предложенным в работе [21], количество нейронов ВНС сократилось почти в 3 раза, время классификации – более чем в 2,3 раза. По сравнению с результатами группировки с помощью субтрактивного [11, 22] и иерархического методов определения количества кластеров [6, 7] количество нейронов, определенное предлагаемым методом, сократилось в 2 раза, время классификации – в 1,4 раза.



а




Рис.2 – Данные [21] (рис. 2, а) (по оси абсцисс- преобладающая частота вибрации ИС (сотни килогерц), по оси ординат – максимальный уровень ошибки); результат построения разделяющей классы поверхности по сгруппированным данным (рис. 2, б)

3. ВЫВОДЫ

Таким образом, в работе предложен метод определения количества нейронов внутреннего слоя ВНС, который позволил упростить структуру ВНС и за счет этого – сократить время классификации, и может быть рекомендован для применения в практически важных задачах классификации при контроле технологических процессов производства, контроле качества, диагностировании неисправностей изделий.

4. СПИСОК ЛИТЕРАТУРЫ

- [1] A. N. Belbachir, M. Lera, A. Fanni, A. Montisci, An automatic optical inspection system for the diagnosis of printed circuit based on neural networks, *40th IEEE Industry Applications Society Annual Meeting*, Hong-Kong, China, (2005), pp. 680-684.
- [2] K. W. Ko, H. S. Cho, Solder joint inspection using a neural network and fuzzy rule-based classification method, *IEEE Transaction on electronics packaging manufacturing*, (23) 2 (2000), pp. 93-103.
- [3] Y. J. Roh, K. W. Ko, H. S. Cho, H. C. Kim, H. N. Joo, S. K. Kim, Inspection of ball grid array (BGA) solder joint using X-ray cross-sequential images, *Part of the SPIE Conference on Machine Vision Systems for Inspection and Metrology*, Boston, Massachusetts, (1999), pp. 168-178.
- [4] J. Wang, W. S. Tang, C. Roze, *Neural network applications in intelligent manufacturing: An updated survey*, Part 2. Computation intelligence in manufacturing handbook. CRC Press LLC. Boca Raton, 2001. 29 p.

- [5] P. D. Wasserman, *Advanced Methods in Neural Computing*, Van Nostrand Reinhold, New York, 1993.
- [6] J. C. Bezdek, N. R. Pal, Some new indexes of cluster validity, *IEEE Transactions on systems, manufacturing and cybernetics*, (28) 3 (1998), pp. 301-315.
- [7] R. O. Duda, P. E. Hart, D. G. Stork, *Pattern Classification*, Wiley-Interscience. John Wiley & Soon Inc. New-York, 2006, 738 p.
- [8] S. Haykin, *Neural Networks. A Comprehensive Foundation*, Second Edition. Prentice Hall. 1998.
- [9] G. Setlak, Artificial Neural Network Using for Classification Tasks Solution in Management, *Radio Electronics, Computer Science, Control*, (1) (2004), pp. 127-135. (in Russian)
- [10] V. S. Medvedev, V. G. Potiomkin, *Neural Networks. MatLab 6*. Moscow, 2002. 485 p. (in Russian)
- [11] M. S. Yang, K.-L. Wu, A modified mountain clustering algorithm, *Pattern Anal. Applic.* (8) (2005), pp. 125-138.
- [12] Y. Z. Tscypkin, *Adaptation and Training in the Automatic Systems*, Moscow, 1968, 400 p. (in Russian)
- [13] I. D. Mandel, *Cluster's Analysis*, Moscow, 1988, 176 p. (in Russian)
- [14] D. L. Davies, D. W. Bouldin, A cluster separation measure, *IEEE Trans. Pattern Anal. Machine Intell.* (1) 4 (1979), pp. 224-227.
- [15] N. G. Zagoruiko, *Applied Methods of Data and Knowledge Analysis*, Novosibirsk, 1999, 270 p. (in Russian)
- [16] S. A. Yudin, Method of image creating in problems of intellectual data analysis, *Thesis for candidate's degree by spetiality 05.13.23 – Systems and instruments of artificial intelligence*, Odessa National Polytechnic University, 2006, (in Russian)
- [17] G. Yu. Shcherbakova, V. N. Krylov, S. G. Antoshchuk. The number of clusters evaluation in time of electronic apparatus state prediction, *Electronics and Communications*, (3) (2010), pp. 91-95. (in Russian)
- [18] V. N. Krylov, G. Yu. Shcherbakova, Sub-gradient iterative optimization method in the wavelet transforming domain, *Zbirnyk naukovykh prac Vijskovogo instytutu Kyjivskogo nacionalnogo universytetu imeni T. Shevchenka*, (12) (2008), pp. 56-60. (in Ukrainian)
- [19] L. J. Hubert, P. Arabie, Comparing partitions, *J. Classification*, (2) (1985), pp. 193-218.
- [20] N. R. Pal, J. Biswas, Cluster validation using graph theoretic concepts, *Pattern Recognition*, (30) 6 (1991), pp. 847-857.
- [21] L. Sheng, System implementation, modeling and defect pattern recognition for flip chip solder joint inspection using laser techniques, *Thesis for degree Doctor of Philosophy. School of Mechanical Engineering Georgia Institute of Technology*, 2001, 146 p. http://www.me.gatech.edu/charles.ume/UmePage/Documents/Thesis_ShengLiu.pdf.
- [22] A. V. Leonenkov, *Fuzzy Models in MATLAB and FuzzyTECH*, St. Peterburg, 2003, 736 p. (in Russian)



Галина Щербакова – к.т.н. (1992), доцент кафедры электронных средств и информационно-компьютерных технологий (2002). Научные интересы: распознавание образов.



Виктор Крылов – д.т.н. (2003), профессор кафедры прикладной математики и информационных технологий в бизнесе (2005). Научные интересы: цифровая обработка изображений, распознавание образов.



Олег Логвинов – к.т.н. (1991), старший преподаватель кафедры электронных средств и информационно-компьютерных технологий. Научные интересы: электроника, распознавание образов.



THE PROBABILISTIC NEURAL NET NEURON'S NUMBER CALCULATIONS

Galina Shcherbacova, Victor Krylov, Oleg Logvinov

Odessa National Polytechnic University,
 Prospect Shevchenko, 1, Odessa, 65044, Ukraine,
 e-mail: Galina_onpu@mail.ru

Abstract: *The sub-gradient method of estimation of the number of the hidden layer neurons of a probabilistic neural network is suggested. This method allows evaluating the data compactness violation in λ -space. This evaluation based on the noise stability sub-gradient iterative optimization method. This method allows reducing the number of the hidden layer neurons and classification time.*

Keyword: *probabilistic neural net, clustering, compactness, neuron's number, sub-gradient optimization method.*

The diagnostics tasks in the modern plant are solved by the automated classification in the base of the neural networks (NN) [1, 2]. The probabilistic NN (PNN) and multilayer NN has been used to solve a diverse group of classification problems successfully. In this classification PNN competes with the back propagation algorithm [3]. Compared with back propagation, the PNN offers the following advantages. Firstly, the PNN rapid training has. Secondly, with enough training data a PNN is guaranteed to converge to a Bayesian classifier. There is no such guarantee with the back propagation, because long training periods can terminate in a local optimum that may be unsatisfactory solution. At finally, the PNN algorithm allows data to be added or deleted from the training set without lengthy retraining, whereas, any modification to a back propagation training set will generally require a repetition of the entire training process. That's characteristics of the PNN makes it more compatible with many diagnostics problems [3]. The major shortcoming of the PNN is requirements of one neuron of inner layer for each training vector. Approach to overcome this drawback is clustering. Clustering can reduce the number of training vectors by grouping with similar characteristics and by representing them with the cluster centroid. Such way allows to reduce of the PNN structure complexity.

The clustering is based on the two compactness hypothesis. First compactness hypothesis are realized in case the one cluster data are placed at short distance and data of another clusters are placed

far off in the sign space. Second hypothesis is λ -compactness one. This hypothesis allows to divide the data by calculation of their local density in the sign space change. For the number cluster estimation the optimization of crisp cluster validity indexes are used. This indexes estimation based on the compactness or λ -compactness hypothesis of data in the sign space. The major shortcoming of the properties of this indexes (a low noise stability or low accuracy) are determined by the method of estimation of data compactness of cluster and distance between clusters [4]. Therefore these crisp indexes of clusters validity may define number of clusters erroneously about 50 % case, even in the case data are grouping in compact, well separated clusters.

Since a priory information about clusters forms and correlation of the cluster dimensions is absent, the number cluster are calculated by investigation of the criteria $K = \max(k_i)$ in the λ -compactness base [5]. In this case $k_i = \frac{f(i+1)}{f(i)}$, $i \in [1, n-1]$ is

the characteristics of the data local homogeneous, $f(i)$ – is the average λ – distance on the i algorithm step.


Parameter k_i characterizes the violation of local homogeneous for data distribution in the λ – space and number of clusters. This parameter has multimodal, noised dependency. For such dependency optimum search the authors work out the sub-gradient iterative optimization method in the

wavelet transforming domain [6]. This noise stability optimization method has high accuracy and low local extreme sensitivity. The k_i dependency optimum search by this optimization method allows to estimate global maximum of this dependency, and two clusters data has been separated. For number neurons of PNN evaluation it is insufficiently. In such dependency the amplitude of second and following modes are smaller then first mode amplitude about several dozens time. That property makes the number cluster estimation difficult.


Therefore we suggest:

- data transforming in the λ – space [5];
- k_i calculation;
- optimum search of $K = \max(k_i)$;
- previous group data except from addition;
- k_i calculation without previous group data; .
- optimum search of $K = \max(k_i)$ end so on.

The estimation method for inner layer neurons number PNN is suggested. This method has been applied in solder joint quality inspection task (fig.1). This method allows to reduce almost three time the neuron number for inner layer PNN and classification time almost in 2,5 time in solder joint quality inspection task as compared with data [7] when grouping (clustering) are absent. As compared with the hierarchical clustering method [2,4] and subtractive clustering method [8] the sub-gradient method of estimation for inner layer neurons number allow reduce neuron number in 1,3 time and classification time in 1,2 time.



a



b

Fig. 1 – Feature vector distribution of sample chips (a); output of the PNN classifier (b)

REFERENCES

- [1] J. Wang, W. S. Tang, C. Roze, *Neural Network Applications in Intelligent Manufacturing: Part 2*, Computation intelligence in manufacturing handbook. Boca Raton, 2001, 29 p.
- [2] R. O. Duda, P. E. Hart, D. G. Stork, *Pattern Classification*, New York, 2006, 738 p.
- [3] P. D. Wasserman, *Advanced Methods in Neural Computing*, New York, 1993.
- [4] J. C. Bezdek, N. R. Pal, Some new indexes of cluster validity, *IEEE Transactions on systems, manufacturing and cybernetics*, (28) 3 (1998), pp. 301-315.
- [5] N. G. Zagoruiko, *Applied Methods of Data and Knowledge Analysis*, Novosibirsk, 1999, 270 p. (in Russian)
- [6] G. Shcherbakova, V. Krylov, S. Antoshchuk, Electronic apparatus automation inspection with adaptive clustering in wavelet domain, *Proc. of the Xth International Conference “Experience of Designing and Application of CAD Systems in Microelectronics” (CADSM’ 2009)*, Ukraine (2009), pp. 153-154.
- [7] L. Sheng, System implementation, modeling and defect pattern recognition for flip chip solder joint inspection using laser techniques, *Thesis for degree Doctor of Philosophy*, 2001, 146 p.
- [8] M. S. Yang, K.-L. Wu, A modified mountain clustering algorithm, *Pattern Anal. Applic.* (8) (2005), pp. 125-138.