

Е.В. Бодянский, А.А. Дейнеко

АДАПТИВНОЕ ОБУЧЕНИЕ АРХИТЕКТУРЫ И ПАРАМЕТРОВ РАДИАЛЬНО-БАЗИСНОЙ НЕЙРОННОЙ СЕТИ

Анотация. Предложены архитектура и метод обучения искусственной эволюционной радиально-базисной нейронной сети, которая настраивает не только свои веса, но и определяет автоматически количество нейронов и расположение центров радиально-базисных функций в on-line режиме с высокой скоростью поступления и обработки данных.

Ключевые слова. искусственная нейронная сеть, адаптивное обучение, радиально-базисная нейронная сеть, самоорганизующаяся карта Кохонена, активационная функция Епанечникова

Введение. В настоящее время искусственные нейронные сети (ИНС) получили широкое распространение для решения большого класса задач обработки информации, прежде всего интеллектуального управления, идентификации, распознавания образов, классификации, кластеризации, прогнозирования, эмуляции в условиях неопределенности и существенной нелинейности. В случае необходимости обработки информации в on-line режиме по мере последовательного поступления на вход новых данных, на первый план выходит вопрос скорости сходимости процесса обучения, существенно ограничивающий класс ИНС, пригодных для работы в этом режиме. С точки зрения оптимизации по скорости процесса обучения весьма перспективными являются ИНС, основанные на ядерных (радиально-базисных, потенциальных, колоколообразных) функциях активации.

Наиболее популярными из перечисленных ИНС являются радиально-базисные нейронные сети (Radial Basis Function Neural Networks – RBFN). Основные идеи радиально-базисных нейронных сетей связаны с методом потенциальных функций [1], оценками Парзена [2, 3], ядерной [4] и непараметрической [5] регрессиями. Важной особенностью этих сетей является то, что они обладают универсаль-

ными аппроксимирующими свойствами и способны обучаться в реальном времени.

Обучение RBFN основывается на оптимизации некоторого (обычно квадратичного) критерия, а поскольку выходной сигнал сети \hat{y}^R линейно зависит от синаптических весов, для их настройки могут быть использованы быстродействующие алгоритмы оптимизации второго порядка, например, рекуррентный метод наименьших квадратов.

Основным недостатком радиально-базисной сети является ее подверженность «проклятию размерности», порождающему экспоненциальный рост числа радиально-базисных нейронов (R-нейронов) с ростом размерности входного пространства, в связи с чем, в настоящей работе предлагается подход к обучению RBFN с ограничением количества нейронов в on-line режиме обработки информации.

1. Радиально-базисная нейронная сеть. На рис. 1 приведена стандартная архитектура радиально-базисной сети, скрытый слой которой реализует некоторое нелинейное преобразование пространства входов R^n в скрытое пространство R^{h_R} более высокой размерности ($h_R > n$), а выходной слой, образованный адаптивным линейным ассоциатором, формирует отклик сети, осуществляя нелинейное преобразование вида

$$\hat{y}^R = F(x) = w_0 + \sum_{i=1}^h w_i \phi_i(x),$$

где $\phi_i = \phi(\|x - c_i\|, \sigma)$ – радиально-базисные функции, определяющие свойства сети, зависящие от расстояния $\|x - c_i\|$ между входным вектором $x = (x_1, x_2, \dots, x_n)^T$ и центром c_i и параметра ширины σ , определяющего локальную область входного пространства, на которую реагирует эта функция. Чаще всего в качестве активационной функции применяется гауссиан

$$\phi_i(x) = \exp\left(-\frac{\|x - c_i\|^2}{2\sigma^2}\right), \quad i = 1, 2, \dots, h^R,$$

хотя может быть использовано и множество других конструкций.

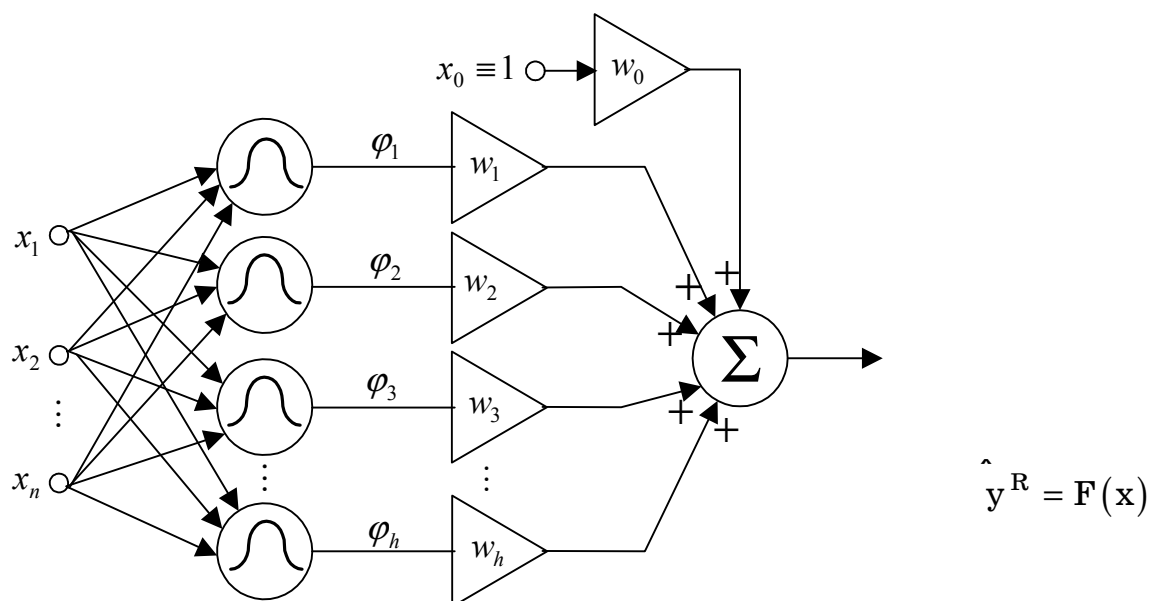


Рисунок 1 – Радиально-базисная нейронная сеть

Преобразования, которые реализует радиально-базисная нейронная сеть, можно записать в виде

$$\hat{y}^R(k) = w_0 + \sum_{l=1}^h w_l \varphi_l(x(k)) = \sum_{l=0}^h w_l \varphi_l(x(k)) = \mathbf{w}^T \tilde{\varphi}^R(x(k)),$$

где

$$\tilde{\varphi}(x(k)) = (\mathbf{1}, \varphi^T(x(k)))^T, \varphi(x(k)) = (\varphi_1(x(k)), \varphi_2(x(k)), \dots, \varphi_{h_R}(x(k)))^T,$$

h_R – число нейронов скрытого слоя, \mathbf{T} – символ транспонирования.

Оптимизация квадратичного критерия обучения

$$\begin{aligned} E(k) &= \sum_{k=1}^N \alpha^{N-k} \left(y(k) - \sum_{l=0}^h w_l \varphi_l(x(k)) \right)^2 = \\ &= \sum_{k=1}^N \alpha^{N-k} \left(y(k) - \mathbf{w}^T \tilde{\varphi}(x(k)) \right)^2 = \sum_{k=1}^N \alpha^{N-k} \left(e^2(k) \right) \end{aligned}$$

в реальном времени может быть реализована с помощью рекуррентного метода наименьших квадратов в виде

$$\left\{ \begin{array}{l} w(k+1) = w(k) + \frac{P(k)(y(k+1) - w^T(k)\tilde{\phi}^R(x(k+1)))}{1 + \tilde{\phi}^T(x(k+1))P(k)\tilde{\phi}^R(x(k+1))} \tilde{\phi}^R(x(k+1)), \\ P(k+1) = \frac{1}{\alpha} \left(P(k) - \frac{P(k)\tilde{\phi}(x(k+1))\tilde{\phi}^T(x(k+1))P(k)}{\alpha + \tilde{\phi}^T(x(k+1))P(k)\tilde{\phi}(x(k+1))} \right), \\ 0 < \alpha \leq 1. \end{array} \right.$$

2. Постановка задачи исследования. Вопрос выбора количества нейронов h_R и правильного расположения центров c_i чрезвычайно актуален. Простейшим вариантом решения этой проблемы является использование алгоритма Subtractive clustering [6], который достаточно эффективен при работе в пакетном режиме, но при этом требует выбора целого набора свободных параметров. Если решаемая задача связана с обработкой нестационарных процессов, то необходимо время от времени переинициализировать сеть, т.е. запускать ее работу с нуля.

Dynamic Decay Adjustment (DDA), тоже является одним из возможных методов обучения радиально-базисных нейронных сетей [9]. Он относится к алгоритмам конструктивного обучения, работает достаточно быстро. Однако, при работе в on-line режиме при обработке нестационарных сигналов этот метод становится неэффективным.

Resource Allocation Network [10] использует комбинированное обучение, основанное как на оптимизации, так и на памяти (принцип «нейроны в точках данных»), с включением элементов конкуренции. При этом в процессе обучения с помощью градиентных процедур настраиваются как синаптические веса, так и параметры центров нейронов, ближайших к поступившему наблюдению. Можно заметить, что в качестве активационных, в этой сети вместо традиционных гауссианов используются квадратичные функции Епанечникова [11]. Недостатком Resource Allocation Network является достаточно высокая вычислительная сложность.

В связи с этим представляется целесообразным разработку искусственной эволюционной радиально-базисной нейронной сети, которая сама настраивает не только свои веса, но и определяет автоматически количество нейронов и расположение центров радиально-базисных функций в on-line режиме с высокой скоростью поступления и обработки данных.

3. **Архитектура гибридной эволюционной сети.** На рис. 2 приведена структурная схема гибридной эволюционной искусственной нейронной сети, основу которой составляет радиально-базисная нейронная сеть с переменным количеством нейронов и самоорганизующаяся карта Кохонена (SOM) [12], которая управляет их числом и настраивает расположение центров в режиме самообучения.




Рисунок 2 – Структурная схема гибридной эволюционной сети

Процесс функционирования предлагаемой системы происходит следующим образом. При поступлении первого наблюдения оно подается на вход радиально-базисной сети, где формируется первый нейрон по принципу «нейроны в точках данных», т.е. практически мгновенно. При последующем поступлении наблюдений они, сперва поступают в SOM, где идет сравнение с уже существующими центроидами, а потом, если же совпадений не обнаружилось формируется новый центроид и соответственно и новый нейрон в RBFN.

4. **Управление количеством нейронов в сети.** В рамках развиваемого подхода введем в рассмотрение следующий метод управления количеством нейронов в сети:

Шаг 1₁: закодировать все значения входных переменных в интервале $-1 \leq x_i \leq 1$ и задать радиус рецепторного поля функции соседства, в интервале $r \leq 0,33$;

Шаг 2₁: при поступлении наблюдения $x(1)$ задать $c_1 = x(1)$;

Шаг 3₁: при поступлении наблюдения $x(2)$:

- если $\|x(2) - c_1\| \ll r$, то $c_1(1)$ корректируется по правилу

$$c_1(2) = \frac{c_1 + x(2)}{2};$$

- если $r < \|x(2) - c_1(1)\| \leq 2r$, $c_1(1)$ корректируется согласно правилу самообучения самоорганизующейся карты Кохонена по принципу «победитель получает больше» (WТМ) [12]

$$c_1(2) = c_1(1) + \eta(2)\psi_1(2)(x(2) - c_1(1))$$

с функцией соседства

$$\psi_1(2) = \max \left\{ 0, 1 - \left(\frac{\|x(2) - c_1(1)\|}{2r} \right)^2 \right\}$$

(функция Епанечникова [11] с рецепторным полем с радиусом $2r$)

- если $\|x(2) - c_1(1)\| > 2r$,

формируется новая радиально-базисная функция с центром $c_2(2) = x(2)$;

На этом первая итерация формирования активационных функций радиально-базисной нейронной сети заканчивается. Пусть к k -му моменту времени сформировано $p \leq h_r$ активационных функций $\varphi_p(x(k))$ с центрами $c_p(k)$ и на обработку поступило наблюдение $x(k+1)$. Далее формирование радиально-базисных функций производится следующим образом:

Шаг 1_{к+1}: определить нейрон-победитель, для которого расстояние $\|x(k+1) - c_l(k)\|$ минимально среди всех $l = 1, 2, \dots, p$;

Шаг 2_{к+1}:

- если $\|x(k+1) - c_l(k)\| \leq r$, то $c_l(k+1) = \frac{c_l(k) + x(k+1)}{2}$;

- если $r < \|x(k+1) - c_l(k)\| \leq 2r$, то

$$c_l(k+1) = c_l(k) + \eta(k+1)\psi_l(k+1)(x(k+1) - c_l(k));$$

$$\psi_l(k+1) = \max \left\{ 0, 1 - \left(\frac{\|x(k+1) - c_l(k)\|}{2r} \right)^2 \right\};$$

- если $\|x(k+1) - c_l(k)\| > 2r$, то сформировать радиально-базисную функцию с центром $c_{p+1}(k+1) = x(k+1)$;

если же в процессе формирования радиально-базисных функций возникает ситуация

$$\|x(k+1) - c_l(k)\| > 2r, \text{ а } p = h_R,$$

то необходимо увеличить радиус рецепторного поля и вернуться к шагу 2_{k+1} с увеличенным радиусом функции $\psi_l(k+1)$.

Как видно данная процедура есть гибрид эволюционного алгоритма Касабова [13] и самоорганизующейся карты Кохонена. Однако предложенная конструкция разработана не только для решения задач кластеризации, но для управления количеством нейронов в радиально-базисной нейронной сети.

Выводы. Данный подход позволяет обеспечить необходимое качество обработки информации на заданном количестве наблюдений в последовательном on-line режиме.

ЛИТЕРАТУРА

1. Айзерман М. А. Метод потенциальных функций в теории обучения машин. / Айзерман М. А., Браверман Э. М., Розоноэр Л. И. – М.: Наука, – 1970. – 384 с.
2. Parzen E. On the estimation of a probability density function and the mode / Parzen E. // Ann. Math. Statist. – 1962. – 38. – P. 1065-1076.
3. Надарая Э. А. О непараметрических оценках плотности вероятности и регрессии / Надарая Э. А. // Теория вероятностей и ее применение. – 1965. – 10. – № 1. – С. 199-203.
4. Haykin S. Neural Networks. A Comprehensive Foundation. / Haykin S. // Upper Saddle River, N.J.: Prentice Hall, Inc., 1999. – 842 p.
5. Варядченко Т. В. Непараметрический метод обращения функций регрессии / Варядченко Т. В., Катковник В. Я. // Стохастические системы управления. – Новосибирск: Наука, 1979. – С. 4-14.
6. Chiu, S. Fuzzy model identification based on cluster estimation / Chiu, S. // Journal of intelligent & fuzzy systems. – Vol. 2 – №3 –Sept. 1994.
7. Бодяньський Є.В. Еволюційна нейронна мережа з ядреними функціями активації та адаптивний алгоритм її навчання. / Бодяньський Є.В., Дейнеко А.О., Тесленко Н.О. // Наукові праці – Вип. 148. - Т. 160. – Комп'ютерні технології. – Миколаїв: Вид-во ЧДУ ім. // Петра Могили, – 2011. – С. 53-58.

8. Бодянский Е.В. Адаптивное обучение комбинированной эволюционной нейронной сети. / Бодянский Е.В., Тесленко Н.А., Дейнеко А.А. – Матеріали міжнародної наукової конференції «Інтелектуальні системи прийняття рішень та проблеми обчислювального інтелекту». – Херсон. – 1. – 2011. – С. 215-220.
9. Paetz, J Reducing the number of neurons in radial basis function networks with dynamic decay adjustment. / Paetz, J. // *Neurocomputing* – №62 – 2004 – P. 79-91.
10. Platt, J. A resource allocating network for function interpolation / Platt, J.// *Neural Comp.* –1991 – 3– P. 213-225.
11. Епанечников В.А. Непараметрическая оценка многомерной плотности вероятности / Епанечников В.А. // *Теория вероятностей и ее применение* – 1968 – 14 – №1 – С. 156-161.
12. Kohonen T. *Self-Organizing Maps* / Kohonen T. – Berlin: Springer-Verlag. – 1995. – 362 p.
13. Kasabov N. *Evolving Connectionist Systems*. / Kasabov N. // London: Springer – Verlag. – 2003 – 307p.