

УДК 519.7:007.2

Е.В. БОДЯНСКИЙ, Е.Е. КОРОЛЬКОВА, Н.С. ЛАМОНОВА

МОДИФИЦИРОВАННЫЕ АЛГОРИТМЫ САМООБУЧЕНИЯ САМООРГАНИЗУЮЩИХСЯ КАРТ Т. КОХОНЕНА

В работе рассмотрены алгоритмы конкурентного самообучения самоорганизующихся карт (SOM) Т. Кохонена и предложены их модификации, позволяющие повысить быстродействие и качество обработки информации путем соответствующего выбора шага обучения и функции соседства.

Введение.

В задачах интеллектуального анализа данных, связанных с кластеризацией, гетероассоциацией, диагностикой, сжатием информации и т.п., широкое распространение получили самоорганизующиеся карты, введенные Т. Кохоненом [1], представляющие собой по сути нейронные сети с прямой передачей информации и реализующие отображение входного пространства X с помощью некоторого оператора F в выходное пространство Y так, как это показано на рис. 1




Рис. 1 Отображение $F: X \rightarrow Y$.

Как видно из рисунка, входное пространство X разбито на подобласти X_i , которые “накрываются” “картой”, при этом любой элемент, принадлежащий подобласти X_i , возбуждает только один нейрон w_j^* нейронной сети.

В основе карты Кохонена лежит нейробиологическая модель Д. Виллшоу – К. фон дер Мальсбурга [2, 3], основанная на том, что многие отделы мозга имеют планарную структуру, при этом качественно разнородная информация отображается в разные участки мозга, а обучение происходит за счет самоорганизации синаптических весов по Д. Хэббу [3].

Свойства самоорганизации нейронной сети связаны с тем, что настройка синаптических весов происходит без внешнего обучающего сигнала, т.е. в режиме самообучения, при этом каждый поступающий сигнал вызывает перестройку (адаптацию) тех или иных параметров. Существенно, что этот процесс может протекать непрерывно, обеспечивая возможность решения поставленной задачи в реальном времени.

Самоорганизующаяся карта имеет крайне простую архитектуру и кроме нулевого рецепторного слоя содержит единственный слой нейронов, именуемый иногда слоем Кохонена [4]. Каждый нейрон слоя Кохонена связан с каждым рецептором нулевого слоя прямыми связями и со всеми остальными нейронами поперечными внутрислойными (латеральными) связями. Именно латеральные связи обеспечивают возбуждение одних нейронов и торможение других.

Благодаря такой организации сети, каждый нейрон получает всю информацию об анализируемом входном образе и генерирует на своем выходе соответствующий отклик, после чего в слое Кохонена возникает режим конкуренции, в результате которой определяется единственный нейрон-победитель с максимальным выходным сигналом. Этот сигнал по латеральным связям обеспечивает возбуждение ближайших “соседей” победителя

и подавление реакции далеко от него отстающих узлов. Таким образом, в процессе конкурентного самообучения формируются группы нейронов, каждый из которых максимальным откликом реагирует на образы из соответствующих подобластей X_j входного пространства X . Это что позволяет карте Кохонена, кроме уже отмеченных задач, успешно справиться с квантованием непрерывного входного пространства в компактные дискретные подмножества, понижением его размерности при минимальной потере информации, выделением наиболее информативных признаков анализируемых образов, т.е. со всем тем, что так или иначе связано с компрессией больших объемов информации [5].

Самоорганизующиеся карты могут иметь различную топологию, хотя наиболее часто рецепторы и нейроны располагаются в узлах одномерной или двумерной решетки. Возможны, конечно, решетки и большей размерности, однако более предпочтительными представляются архитектуры, сохраняющие некоторым образом топологическую упорядоченность входного пространства.

Постановка задачи.

Рассмотрим карту Кохонена произвольной топологии, содержащую n рецепторов и m ($m < n$) нейронов в слое Кохонена, каждый из которых характеризуется собственным n -мерным вектором синаптических весов $w_j, j=1,2,\dots$, при этом сам нейрон – это, как правило, либо адаптивный линейный ассоциатор, либо обучаемый соответствующим образом перцептрон Розенблатта, либо радиально-базисный элемент.

Каждый нейрон сети получает n -мерный входной вектор x и генерирует на своем выходе сигнал y_j , зависящий от вектора синаптических весов w_j , настроенных с помощью алгоритма самообучения на определенную область входного пространства X_j . Близкие в смысле используемой метрики входные векторы $x(k)$ и $x(p)$ (здесь k и p либо номера образов, либо такты текущего дискретного времени, в которые эти образы предъявляются сети) могут возбуждать либо один и тот же нейрон w_j , либо два нейрона “соседа”, например, w_j и w_{j+1} или w_j и w_{j-1} . В некоторых случаях нейрон-победитель w_j^* с максимальным выходным сигналом y_j может возбуждать и своих ближайших соседей так, что $y_j > y_{j+1}, y_{j-1} > y_{j+2}, y_{j-2} > \dots$

В основе процедуры самоорганизации карты Кохонена лежат принципы конкурентного самообучения, а ее работа, как и любого другого алгоритма обучения, начинается с инициализации синаптических весов сети, которые обычно выбираются с помощью генератора случайных чисел, при этом весьма желательно, чтобы для каждого из нейронов выполнялось условие $\|w_j(0)\| = \sqrt{w_j^T(0)w_j(0)} = 1$. Сама процедура самоорганизации реализуется в три основных этапа [3]: конкуренции, кооперации и синаптической адаптации. Задачей настоящей работы является модификация известных алгоритмов самоорганизации с целью расширения их функциональных возможностей в плане повышения качества обработки информации.

1. Конкуренция и синаптическая адаптация

Процесс конкуренции начинается с анализа образа $x(k)$, поступающего с рецепторного слоя на все нейроны слоя Кохонена. Для каждого из нейронов вычисляется расстояние

$$D(x(k), w_j(k)) = \|x(k) - w_j(k)\|,$$

причем, если входы и синаптические веса предварительно пронормированы так, что $\|x(k)\| = \|w_j(k)\| = 1$, а в качестве расстояния используется евклидова метрика, то мерой близости между векторами $x(k)$ и $w_j(k)$ может служить скалярное произведение:

$$D(x(k), w_j(k)) = x^T(k)w_j(k) = \cos(x(k), w_j(k)) = \cos \Theta_j.$$

Далее определяется нейрон-победитель, "ближайший" ко входному образу такой, что

$$D(x(k), w^*(k)) = \min_j D(x(k), w_j(k)),$$

после чего в простейшем случае "перепрыгивая" через этап кооперации, можно подстроить синаптические веса сети с помощью элементарного правила конкурентного самообучения [1]:

$$w_j(k+1) = \begin{cases} w_j(k) + \eta(k)(x(k) - w_j(k)), & \text{если } j\text{-тый нейрон является победителем,} \\ w_j(k) & \text{в противном случае.} \end{cases} \quad (1)$$

Несложно видеть, что процедура (1) реализует принцип "победитель получает все", при этом вектор синаптических весов нейрона-победителя "подтягивается" по входному вектору на расстояние, определяемое шагом поиска $\eta(k)$.

Регулирование величины шага поиска обычно производится, исходя из эмпирических соображений [1-6], а общая рекомендация сводится к тому, что он должен монотонно уменьшаться в процессе самообучения. С этой рекомендацией согласуется введенная в [7] процедура

$$\eta(k) = r^{-1}(k), \quad r(k) = \alpha r(k) + \|x(k)\|^2, \quad 0 \leq \alpha \leq 1, \quad (2)$$

которая для пронормированных входов приобретает простой вид

$$r(k) = \alpha r(k-1) + 1, \quad (3)$$

при этом при $\alpha = 1$ (2) приобретает форму, предложенную в [8], а (3) автоматически дает оценку

$$\eta(k) = \frac{1}{k},$$

удовлетворяющую условиям А. Дворецкого. Варьируя фактором забывания α , несложно обеспечить достаточно широкий интервал изменения шага поиска

$$\frac{1}{k} \leq \eta(k) \leq 1.$$

2. Кооперация.

Одной из особенностей карты Кохонена является возможное наличие этапа кооперации в процессе самоорганизации, когда нейрон-победитель определяет так называемую локальную область топологического соседства, в которой возбуждается не только он сам, но и его ближайшее окружение, при этом более близкие к победителю нейроны возбуждаются сильнее чем удаленные. Эта топологическая область определяется функцией соседства $\varphi(j, l)$, зависящей от расстояния $D(w_j(k), w_l(k))$ между победителем $w_j^*(k)$ и любым из нейронов слоя Кохонена $l = 1, 2, \dots, m$ и некоторого параметра, задающего ее "ширину". Как правило, $\varphi(j, l)$ - это потенциальная (ядерная) функция, симметричная от-

носителем максимума в точке $D(w_j^*(k), w_j^*(k)) = 0$ и принимающая с ней единичное значение, монотонно убывающая с ростом расстояния и стремящаяся к нулю при $D(w_j^*(k), w_l(k)) \rightarrow \infty$.

Наиболее часто в качестве функции соседства используется гауссиан [9], конус (треугольник) [2], параболоид (перевернутая квадратичная функция) [10], “мексиканская шляпа” [5] и целый ряд других [11].

Использование функции соседства приводит к правилу самообучения вида

$$\begin{aligned} w_l(k+1) &= w_l(k) + \eta(k)\varphi(j, l, k)(x(k) - w_l(k)), \\ l &= 1, 2, \dots, m, \end{aligned} \quad (4)$$

реализующему принцип “победитель получает больше” вместо традиционного “победитель получает все”. Естественно, что при $\varphi(j, l) = \delta_{jl} = 1$ при $j = l$ и 0 в остальных случаях, приходим к стандартному алгоритму (1), обеспечивающему на каждом такте настройку единственного нейрона $w_j^*(k)$. Использование же в качестве $\varphi(j, l)$ ядерных функций ведет к тому, что все нейроны сети в большей или меньшей мере подтягивают векторы своих синаптических весов к текущему $x(k)$.

Анализ сходимости процессов конкурентного самообучения, произведенный М. Котрелом и Дж. Фортон [12], показал, что в процессе настройки синаптических весов, должен уменьшаться не только шаг поиска $\eta(k)$, но и параметр, определяющий ширину функции соседства, которая таким образом становится зависимой от текущего времени.

Для гауссовской функции:

$$\varphi(j, l) = \exp\left(-\frac{\|w_j^*(k) - w_l(k)\|^2}{\sigma^2}\right)$$

а фактически для

$$Y(j, l) = \exp\left(-2\frac{1 - w_l^T(k)w_j^*(k)}{\sigma^2}\right).$$

Г. Риттером и К. Шультемом было предложено [13, 14] для настройки параметра ширины σ использовать процедуру:

$$\sigma(k) = \sigma(0) \exp\left(-\frac{k}{\beta}\right), \quad (5)$$

где β - скалярный параметр, определяющий скорость уменьшения силы влияния нейрона-победителя на свое окружение.

Естественно, что при этом меняется и форма области топологического соседства, приобретающая вид

$$\varphi(j, l, k) = \exp\left(-\frac{\|w_j^*(k) - w_l(k)\|^2}{\sigma^2(k)}\right) = \exp\left(-2\frac{1 - w_l^T(k)w_j^*(k)}{\sigma^2(k)}\right).$$

Заметим также, что экспоненциальное убывание параметра ширины может быть обеспечено и с помощью более простого чем (5) выражения

$$\sigma(k) = \beta\sigma(k-1), \quad 0 < \beta < 1.$$

В принципе в качестве функции соседства можно использовать не ядерные конструкции, а выходной сигнал каждого из нейронов слоя Кохонена, при этом нейрон-победитель определяется по максимальному положительному значению этого сигнала. Алгоритм самообучения при этом естественно приобретает форму

$$\begin{aligned} w_l(k+1) &= w_l(k) + \eta(k)\varphi(j, l, k)(x(k) - w_l(k)) = \\ &= w_l(k) + \eta(k)y_l(k)(x(k) - w_l(k)), \quad l = 1, 2, 3, \dots, m. \end{aligned} \quad (6)$$

Несложно заметить, что (6) представляет собой модифицированное правило обучения входной звезды С. Гроссберга [15] и обеспечивает не только притяжение к образу $x(k)$ близких к нему нейронов, но и отталкивание тех узлов, выход которых находится в “противофазе” ко входному сигналу.

Если в качестве нейронов слоя Кохонена использовать линейные ассоциаторы, то (6) можно переписать в форме

$$w_l(k+1) = w_l(k) + \eta(k)w_l^T(k)x(k)(x(k) - w_l(k)),$$

з, поскольку $\|w_l(k)\| = \|x(k)\| = 1$, то и в более простом виде

$$\begin{aligned} w_l(k+1) &= w_l(k) + \eta(k)\cos(x(k), w_l(k))(x(k) - w_l(k)) = \\ &= w_l(k) + \eta(k)\cos\Theta_l(k)(x(k) - w_l(k)). \end{aligned}$$

Таким образом, приходим к биполярной функции соседства, приведенной на рис. 2 и обеспечивающий более широкие возможности процессу самоорганизации.




Рис. 2. Биполярная функция соседства

3. Нейронный газ.

Еще один подход к самоорганизации основан на использовании порядковых статистик и получил название алгоритма нейронного газа [16,17]. В рамках этого подхода все нейроны ранжируются в порядке возрастания расстояний $D(x(k), w_l(k))$ так, что

$$D(x(k), w^*(k)) < D(x(k), w^1(k)) < D(x(k), w^2(k)) < \dots < D(x(k), w^{m-1}(k)),$$

где верхний индекс обозначает ранг $R(w_l(k))$ каждого нейрона в слое после предъявления образа $x(k)$ т.е.

$$R(w^*(k)) = 0 < R(w^1(k)) = 1 < R(w^2(k)) = 2 < \dots < R(w^{m-1}(k)) = m-1.$$

Несложно видеть, что при нормированных входах удобно использовать ранжирование

$$1 \geq \cos \Theta^*(k) > \cos \Theta^1(k) > \cos \Theta^2(k) > \dots > \cos \Theta^{m-1}(k) \geq -1$$

или

$$1 \geq y^*(k) > y^1(k) > y^2(k) > \dots > y^{m-1}(k) \geq 1.$$

Далее для каждого из нейронов определяется значение функции соседства

$$\varphi(x(k), w_l(k)) = \exp\left(-\frac{R(w_l(k))}{\lambda(k)}\right),$$

где $\lambda(k)$ - параметр ширины) и производится уточнение синаптических весов согласно формуле

$$w_l(k+1) = w_l(k) + \eta(k)\varphi(x(k), w_l(k))(x(k) - w_l(k)).$$

Несложно видеть, что параметры нейрона с нулевым рангом $w^*(k)$ (фактически нейрон-победитель) при этом уточняются с помощью процедуры (1).

Аналогично предыдущему параметры алгоритма в процессе самообучения должны уменьшаться, например, с помощью соотношений [13]

$$\lambda(k) = \lambda_{\max} \left(\frac{\lambda_{\min}}{\lambda_{\max}} \right)^{k/N}, \quad \eta(k) = \eta(0) \left(\frac{\eta_{\min}}{\eta_{\max}} \right)^{k/N},$$

где N - объем обучающей выборки;

λ_{\max} - максимально возможное значение ширины;

λ_{\min} - минимальные значения соответствующих параметров.

Заключение.

Весь процесс самоорганизации имеет две временные фазы [1]. Начальная фаза упорядочения, в которой происходит топологическое разбиение входного пространства, и последующая фаза сходимости, в которой осуществляется точная настройка синаптических весов. По окончании этого процесса нейронная сеть в принципе может решать поставленные задачи без уточнения весов, однако, если появляется входной образ, который не будет отнесен ни к одному из сформированных кластеров, картой должен быть образован дополнительный нейрон в слое Кохонена, несущий информацию об этом образе, при этом весьма желательно, чтобы вновь включился процесс самообучения. Поскольку процесс обучения карты Кохонена происходит обычно быстрее чем настройка многослойной сети с помощью алгоритма обратного распространения ошибок, самоорганизующиеся карты наиболее эффективны для работы в реальном времени, когда настройка синаптических весов и обработка входных сигналов протекают параллельно. Введение в процесс самоорганизации этапа кооперации и соответствующих алгоритмов обучения позволяет расширить функциональные возможности рассматриваемого класса искусственных нейронных сетей.

Список литературы: 1. *Kohonen T.* Self-Organizing Maps. Berlin: Springer-Verlag, 1995. 362 p. 2. *Rojas R.* Neural Networks. A Systematic Introduction. Berlin: Springer-Verlag, 1996. 502 p. 3. *Haykin S.* Neural Networks. A Comprehensive Foundation. Upper Saddle River, N.J.: Prentice Hall, Inc., 1999. 842 p. 4. *Tsoukalas L.H., Uhrig R.E.* Fuzzy and Neural Approaches in Engineering. N.Y. John

Wiley&Sons, Inc., 1997. 587 p. 5. *Advances in Intelligent Control* / Ed. by C.J. Harris. London: Taylor and Francis, 1994. 373 p. 6. *Shalkoff R.J.* Artificial Neural Networks. N.Y: The Mc. Graw-Hill Comp., Inc., 1997. 422 p. 7. *Бодянский Е.В., Плисс И.П., Соловьева Т.В.* Многошаговые оптимальные предсказатели многомерных нестационарных стохастических процессов // Доклады АН УССР. Сер. А. 1986, №12. С.47-49. 8. *Goodwin G.C., Ramadge P.J., Caines P.E.* A globally convergent adaptive predictor // Automatica. 1981. 17. №1. P. 135-140. 9. *Lo Z.-P., Yu Y., Bavarian B.* Analysis of the convergence properties of topology preserving neural networks // IEEE Trans on Neural Networks. 1993. 4. P. 207-220. 10. *Bodyanskiy Ye., Chaplanov O., Kolodyazhniy V., Otto P.* Adaptive quadratic radial basis function network for time series forecasting // Proc. East West Fuzzy Coll. Zittau – Goerlitz: HS, 2002. P. 164-172. 11. *Руденко О.Г., Бодянский Е.В.* Основы теории искусственных нейронных сетей. Харьков: ТЕЛТЕХ, 2002, 317 с. 12. *Cottrel M., Fort J.* A stochastic model of retinotopy: a self-organizing process // Biological Cybernetics. 1986. 53. P. 405-411. 13. *Ritter H., Schulten K.* On the stationary state of the Kohonen self-organizing sensory mapping // Biological Cybernetics. 1986. 54. P. 234-249. 14. *Ritter H., Schulten K.* Convergence properties of Kohonen's topology conserving maps: fluctuations, stability, and dimension selection // Biological Cybernetics. 1988. 60. P. 59-71. 15. *Grossberg S.* Classical and instrumental learning by neural networks / "Progress in Theoretical Biology". N.Y.: Academic Press, 1974. 3. P. 51-141. 16. *Martinetz M., Berkovich S., Schulten K.* "Neural gas" network for vector quantization and its application to time series prediction // IEEE Trans. on Neural Networks. 1993. 4. P. 558-569. 17. *Осовский С.* Нейронные сети для обработки информации. М.: Финансы и статистика, 2004. 344 с.

Поступила в редколлегию 1.07.2003