

РОССИЙСКАЯ АКАДЕМИЯ НАУК

СИБИРСКОЕ ОТДЕЛЕНИЕ

А В Т О М Е Т Р И Я

---

2007, том 43, № 5

УДК 681.8

ИСПОЛЬЗОВАНИЕ МЕТОДА САМООРГАНИЗАЦИИ  
ПРИ СИНТЕЗЕ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ  
НА МАЛЫХ ВЫБОРКАХ

**В. Г. Щетинин, В. С. Абруков, А. И. Бражников**

Чувашский государственный университет, г. Чебоксары

E-mail: abrukov@yandex.ru

Рассматриваются проблемы синтеза нейросетевых моделей на основе неполных экспериментальных данных. Точность моделей, синтезируемых в таких условиях, оказывается в значительной степени зависимой от их сложности. Предлагается метод самоорганизации нейросетевых моделей, сложность которых близка к оптимальной. Представлены примеры синтеза нейросетевых моделей интерферометрических данных и роста регионального промышленного производства.

**Введение.** Наиболее распространенные методы создания моделей объектов основаны на использовании экспериментальных данных, представляющих поведение этих объектов [1–4]. В предлагаемой работе рассматриваются задачи синтеза моделей в условиях, когда объем эмпирических наблюдений ограничен в силу определенных обстоятельств, например: высоких вычислительных затрат, отсутствия технической возможности или малой вероятности наступления таких событий (редких явлений). Недостаток эмпирической базы в таких случаях часто восполняется введением дополнительной экспертной информации, в частности допущения о гауссовском распределении случайных шумов эмпирических данных. Эта информация существенно упрощает синтез моделей объекта и открывает возможности использования методов оптимального проектирования [2–6].

В экспертную информацию могут быть включены предположения о степени влияния входных переменных на выходные и предполагаемый состав этих переменных. Эксперты могут предопределить, какой должна быть нейромодель, например многослойный перцептрон с заданным числом слоев и нейронов [3–6]. В этом случае перцептрон должен быть обучен на выборке классифицированных экспертом наблюдений. Выбор метода и алгоритма обучения, как и его параметров, должен быть адекватным выборке наблюдений, условиям решения задачи и также остается за экспертами. Перечисленные подходы усложняют синтез моделей, делают решение задачи скорее субъективным, нежели научно обоснованным [3–6].

В отличие от методов перцептронной схемы предопределенной структуры методы многорядной самоорганизации нейросетевых моделей [3–7] не требуют предварительного определения структуры нейросети и параметров обучения. Они позволяют синтезировать эффективные модели в условиях

непредставительной статистики наблюдений благодаря использованию случайного поиска и специальных критериев селекции.

В методах многорядной самоорганизации осуществляется случайный поиск (или полный перебор) нейронов с двумя входами и лучшие из них (по критерию величины ошибки на проверочной выборке) используются для построения следующего слоя нейронов. В каждом последующем слое этот процесс повторяется для новых нейронов-кандидатов с двумя входами, соединенными с выходами нейронов предыдущего слоя. Наращивание рядов повторяется до тех пор, пока точность предсказания проверочных примеров не перестает улучшаться.

Создавая в каждом новом ряду нейроны-кандидаты и отбирая лучшие из них по величине внешних критериев, методы многорядной самоорганизации позволяют найти наилучшие структурные связи и оценки их параметров. При такой итеративной процедуре исключаются неэффективные нейронные связи и входные переменные, не использованные ни одним из нейронов, отобранных для сети. Синтезированные таким образом модели решений имеют квазиоптимальную сложность, которая в данном случае может быть оценена числом синтезированных нейронов и использованных исходных переменных [3–7].

Однако результаты самоорганизации, полученные в рамках известных методов, оказываются зависимыми от произвольного выбора некоторых параметров, например структуры внешних критериев и правила остановки итерационной процедуры [3–6, 8]. Для устранения этих недостатков были предложены новые критерии самоорганизации в классе булевых функций [9, 10]. Исследование эффективности методов самоорганизации моделей оптимальной сложности в условиях непредставительной обучающей выборки остается актуальным и требует разработки новых эвристик.

**1. Постановка задачи и метод многорядной самоорганизации.** Очевидно, что данные, используемые для обучения, могут быть представлены как количественными, так и качественными (в том числе бинарными) признаками. Использование булевых нейронных сетей предполагает, что все признаки бинарные. Количественные признаки при этом могут быть преобразованы в бинарные без существенных потерь информации одним из способов, описанных в [4, 6]. Поэтому без ограничения общности рассмотрим случай, когда все входные данные  $x_1, \dots, x_m$ , а также выходные  $y$  исследуемой системы представлены количественными переменными, где  $m$  – размер вектора признаков  $\mathbf{x}$ .

Зададим обучающую выборку  $\{\mathbf{x}^{(i)}, y_i^0\}, i=1, \dots, n$ , где  $y_i^0$  – желаемая реакция системы на вход  $\mathbf{x}^{(i)}$ , а  $n$  – длина обучающей выборки. Требуется найти такую модель решений  $y = f^*(\mathbf{x})$ , число  $v$  ошибок которой было бы минимальным не только на обучающей последовательности, но и на проверочной выборке, элементы которой не были включены в обучающую выборку.

В рамках метода самоорганизации искомая модель  $f^*(\mathbf{x})$  представляется в виде суперпозиции предварительно заданных опорных функций следующего вида:

$$g = (u_1, \dots, u_k), \quad k = 2, 3, \dots, \quad (1)$$

где  $u_1, \dots, u_k$  – аргументы функции или входы нейрона, реализующего заданную опорную функцию.

В нашем случае опорная функция (1) принадлежит классу  $\Omega_k$  функций  $k$  аргументов,  $g(\mathbf{u}) \in \Omega_k$ . Выбор класса определяется условиями решения задачи. Эти функции могут быть заданы, например, регрессионными или булевыми. Число аргументов  $k$  обычно задают равным 2. В этом случае любая функция  $f(\mathbf{x})$  при  $m \geq k$  такая, что  $f(\mathbf{x}) \in \Omega_m$ , и может быть представлена в виде следующей суперпозиции опорных функций:

$$f(\mathbf{x}) = g^{(r)}(g^{(r-1)}(\dots g^{(1)}(x_i, x_j) \dots)), \quad i \neq j = 1, \dots, m, \quad (2)$$

где  $r$  – число суперпозиций или слоев нейронной сети.

Очевидно, что число слоев определяет размер нейронной сети и, следовательно, ее сложность.

После определения функции (1) и суперпозиции (2) можно представить следующую нейронную сеть. Нейронная сеть  $f(\mathbf{x})$ , образованная суперпозицией из  $r$  базовых элементов  $g$ , имеет минимальную сложность, если среди всех возможных функций  $f(\mathbf{x}) \in \Omega_m$ , обеспечивающих одинаковое число ошибок обучения, существует хотя бы одна функция  $f^*$ , в которой число слоев (суперпозиций) минимальное:

$$r^* = \min_{f_i \in \Omega} r_i. \quad (3)$$

Из обученных нейронных сетей  $\{f(\mathbf{x}) \in \Omega_m\}$ , обеспечивающих одинаковую ошибку обучения, но имеющих разные размеры, в соответствии с принципом, известным как лезвие Оккама [3–6], следует выбирать сеть минимального размера.

Тогда по аналогии с нейронной сетью минимальной сложности, нейронные сети, для которых выполняется условие (3) при минимальном числе ошибок обучения, имеют квазиоптимальную сложность. В данном случае сложность квазиоптимальна, потому что самоорганизация нейронных сетей осуществляется на основе эвристик, а не формальных методов оптимизации.

В известных методах самоорганизации в каждом новом ряду отбирается заданное число  $F$  нейронов-претендентов; этот параметр называется свободой выбора решений [3–6]. Отбор нейронов осуществляется на основе критериев, удовлетворяющих принципу внешнего дополнения, введенного в [1]. Рассмотрим критерий, известный в теории самоорганизации [3–6] как критерий несмешенности  $CR$ :

$$CR = \| f(W/A) - f(W/B) \|, \quad W = A \cup B, \quad (4)$$

где  $f(W/A)$  и  $f(W/B)$  – значения функций  $f$ , синтезированных на подмножествах  $A$  и  $B$  обучающей выборки.

Критерий несмешенности обладает свойствами внешнего дополнения, потому что значения функций, синтезированных на различных непересекающихся частях  $A$  и  $B$  обучающей выборки, сравниваются на новых примерах, принадлежащих соответственно подвыборкам  $B$  и  $A$ , т. е. для функции  $f$ , синтезированной на подвыборке  $A$ , элементы подвыборки  $B$  будут внешними, и наоборот.

Внешние критерии (4) являются эвристическими, поскольку построены на предположении о том, что искомая функция  $f^*$  не зависит от того, на ка-

кой из частей обучающей выборки она построена. В процессе самоорганизации величина критерия несмешенности для функций  $f^*$ , созданных на представительных подвыборках  $A$  и  $B$ , будет стремиться к некоторому квазиглобальному минимуму  $CR^*$ :

$$CR^* = \|f^*(W/A) - f^*(W/B)\| \rightarrow \min. \quad (5)$$

Очевидно, что, если нейронная сеть в процессе самоорганизации имеет недостаточную или же, наоборот, чрезмерную сложность, величина критерия будет больше, чем  $CR^*$ . Благодаря подобной конструкции внешних критериев, в процессе самоорганизации нейронной сети значения этих критериев проходят через точку минимума  $CR^*$ , указывающую на искомую модель  $f^*$  квазиоптимальной сложности.

Естественно, если подвыборки  $A$  и  $B$  не будут представительными, то трудно ожидать, что в процессе самоорганизации может достигаться минимум, близкий к квазиглобальному минимуму  $CR^*$ , и что в результате искомая функция  $f^*$  не будет смешенной. Аналогичное смещение может возникнуть из-за неадекватного назначения числа  $F$  нейронов, отбираемых в следующий ряд нейронной сети. На непредставительных выборках возникает также нежелательная зависимость результатов самоорганизации от вариантов разбиений обучающих данных на подвыборки  $A$  и  $B$ .

На практике выбор параметра  $F$  осуществляется экспериментальным путем в зависимости от размерности данных, уровня шумов в них и имеющейся вычислительной мощности. Вероятность нахождения искомой модели  $f^*$  пропорциональна числу  $F$  нейронов-претендентов, отбираемых для самоорганизации следующего слоя нейронной сети. Однако при увеличении  $F$  быстро растут вычислительные затраты. Поэтому при большой размерности данных, когда число признаков, например, более 20, ищется компромисс между значениями параметра  $F$  и затратами на самоорганизацию. Без учета ограничений на вычислительные затраты экспериментально определено [3, 4], что наибольшая вероятность обнаружения искомой функции  $f^*$  при небольшом уровне шумов в данных достигается, когда  $F \approx 0,4C_m^k$ , где  $C_m^k$  – число сочетаний из  $m$  по  $k$ . Обычно  $k = 2$ , и тогда  $F \approx 0,2m(m-1)$ .

Теория самоорганизации еще не дает исчерпывающего ответа на вопрос, каким должно быть назначено число  $F$  при низком и высоком уровнях помех в данных и при различных конструкциях внешних критериев типа критерия несмешенности (4)?

В связи с нерешенными проблемами искомые модели, синтезированные в процессе эвристической самоорганизации, часто оказываются смешенными.

**2. Самоорганизация нейронных сетей оптимальной сложности.** Как известно, теория самоорганизации использует принцип неокончательных решений, введенный для предсказания по зашумленным данным в [3–5]. Этот принцип выполняется при  $F > 1$ , когда для синтеза следующего ряда нейронной сети используется не один нейрон, лучший по величине критерия отбора, а несколько, но с худшими показателями этого критерия. Естественно, что при наличии шумов в данных вероятность того, что в следующем ряду окажется истинный нейрон, который по величине критерия отбора на

ранних этапах самоорганизации из-за шума уступал другим, тем больше, чем больше параметр  $F$ .

Анализируя назначение параметра  $F$ , можно прийти к выводу, что использование принципа неокончательных решений в теории многорядной самоорганизации нуждается в некотором уточнении. Действительно, выбор  $F > 1$  нейронов является принципиально важным для создания каждого нового слоя нейронной сети. Однако, на наш взгляд, из этого не следует, что параметр  $F$  должен быть назначен одинаковым для всех рядов нейронной сети. Рассмотрим, например, нейронную сеть, сложность которой в процессе самоорганизации растет. Можно ожидать, что ее рост сопровождается увеличением разнообразия сетей. Если в первых рядах самоорганизации синтезированные модели могут быть примитивными, то необходимое их разнообразие достигается увеличением числа возможных моделей-претендентов, т. е. увеличением параметра  $F$ . По мере нарастания новых слоев нейронной сети сложность моделей и их разнообразие увеличиваются, а, следовательно, число  $F$  моделей-претендентов может быть пропорционально снижено, оставаясь при этом больше единицы. Из этого следует важный для практики вывод, что, контролируя разнообразие создаваемых моделей-претендентов, можно назначать параметр свободы выбора решений индивидуально для каждого ряда. Очевидно, как только разнообразие моделей достигает некоторого максимума, ни одна из новых моделей, синтезированных в текущем слое нейронной сети, не может обладать разнообразием, большим достигнутого уровня. В результате в следующий ряд нейронной сети ни один из нейронов не пройдет, что в данном случае является признаком завершения самоорганизации.

Рассмотрим задачу самоорганизации нейронных сетей на непредставительной выборке обучающих примеров с точки зрения, изложенной выше. Прежде всего, для самоорганизации требуется предварительно определить опорную функцию  $g$ , как это было описано в разд. 1. После определения  $g$  правило суперпозиции (2) становится применимым к функции  $f^{(r)}$   $r$ -го слоя нейронной сети. Но это правило может быть рассмотрено относительно функции  $f^{(r-1)}$ , синтезированной в предыдущем слое, несколько иначе, и по отношению к переменным  $(x_{i_1}, \dots, x_{i_r})$  функции  $f^{(r-1)}(x_{i_1}, \dots, x_{i_r})$  новая переменная  $x_k: x_k \notin (x_{i_1}, \dots, x_{i_r})$  может внести дополнительную информацию, являющуюся внешней, т. е. новой по отношению к этим переменным. В такой формулировке правило суперпозиции сводится к виду

$$f^{(r)} = g^{(r)}(f^{(r-1)}(x_{i_1}, \dots, x_{i_r}), x_k). \quad (6)$$

Видно, что аналогично (2) правило (6) можно применять ко всем слоям  $r = 1, \dots, r^*$  нейронной сети, если ввести для слоя  $r = 0$  функцию одного аргумента  $f_i^{(0)} = x_i, i = 1, \dots, m$ .

Внешнее дополнение, участвующее в (6), может быть формально определено следующим образом. Найдем число  $v^{(r)}$  ошибок модели  $f^{(r)}$   $r$ -го слоя. Тогда можно предположить, что дополнение, вносимое переменной  $x_k$ , будет внешним, если выполняется условие

$$v^{(r)} < v^{(r-1)}. \quad (7)$$

Предположим, что переменная  $x_k$  внутренняя, т. е.  $x_k \in (x_{i_1}, \dots, x_{i_r})$ . Тогда ее использование в суперпозиции (6) не может снизить число ошибок модели  $f^{(r)}$  и, следовательно,  $v^{(r)} \geq v^{(r-1)}$ . И условие (7) не выполняется, если переменная  $x_k$  коррелирована с одной из переменных  $(x_{i_1}, \dots, x_{i_r})$ .

Для создания нового алгоритма самоорганизации осталось ввести правило останова. Для этого рассмотрим число  $L^{(r+1)}$  функций, для которых удовлетворяется условие (7). Очевидно, что наращивание рядов следует прекратить в одном из двух случаев:

$$v^{(r)} = v_0, \quad (8)$$

$$L^{(r+1)} = 0; \quad v^{(r)} > v_0, \quad (9)$$

где  $v_0 \geq 0$  – допустимое число ошибок обучения или противоречий.

Первый случай тривиален, поскольку достигается распознавание всех обучающих примеров с заданной точностью. Во втором случае в новом ряду не найдено ни одной функции, удовлетворяющей условию отбора (7). При этом число противоречий моделей, найденных в предыдущем ряду, остается больше заданного. Это может означать, что при заданных параметрах качества обучения не может быть достигнуто.

Установка  $v_0 = 0$  при наличии в обучающих примерах шумов, как известно, приводит к тому, что правила останова (8) и (9) дают переусложнение исключимых моделей [9–11]. Это происходит вследствие того, что модели, синтезируемые в процессе самоорганизации, подгоняются под специфику обучающих примеров, отсутствующих в новых данных. Однако переобучения в этом случае легко избежать путем экспериментального определения адекватного числа противоречий на обучающей выборке. Тогда в процессе самоорганизации можно будет найти модели, менее чувствительные к такой специфике обучающих примеров.

Важно отметить, что правила останова (8) и (9) не зависят от задаваемых параметров  $F$  и вариантов разбиений обучающей выборки. Эти правила, как видим, зависят от одного параметра  $v_0$ . Работоспособность самоорганизации на основе таких критериев подтверждается примерами медицинской диагностики, представленными в [12, 13], а также задачами создания моделей физики пламени двигателей и роста промышленной продукции в регионе.

**3. Синтез модели интерферометрии пламени.** Методы интерферометрии позволяют определить ряд практически важных интегральных характеристик пламени: массу продуктов горения, количество тепла в пламени, архимедову подъемную силу, действующую на пламя, и т. д. [14], которые невозможно определить другими методами. Перечисленные характеристики, в свою очередь, дают возможность оценить такие важные параметры, как масcovая скорость горения, мощность тепловыделения и другие.

Интегральные характеристики определяются в случаях, когда можно измерить полное распределение разности фаз по всей плоскости интерферограммы только в идеальных условиях эксперимента: при небольших размерах пламени. В реальных случаях горения получить идеальные качественные интерферограммы, позволяющие измерить полное распределение раз-

ности фаз, практически невозможно. Но даже в идеальных случаях эта процедура крайне трудоемкая и плохо поддается автоматизации.

Однако искомые модели интерферометрии пламени могут быть найдены в условиях, близких к реальным, если в качестве входных данных выбрать параметры контура интерференционного изображения пламени (интерферограммы как целого), а именно: максимальную высоту  $h$  и ширину  $d$  интерферограммы, ее площадь  $S$  и периметр  $l$ . Измерение этих величин по интерференционному изображению пламени – достаточно простая задача, для решения которой были созданы компьютерные программы [15]. Такие параметры определяют только область существования функции распределения разности фаз, а не саму функцию, и их можно отнести к неполным данным интерференционного эксперимента. Значения этих параметров косвенно определяются характером процессов тепломассопереноса и химической кинетикой горения, т. е. массой продуктов горения и количеством тепла в пламени. Однако данная связь существует в неявной форме, и ее аналитическое определение стандартными методами не представляется возможным.

Методика создания нейросетевой модели интерферометрии пламени с целью определения интегральных характеристик на основе неполных данных была следующей. По каждому кадру интерференционного кинофильма с помощью компьютерной программы [15] были измерены наборы значений  $h, d, S, l$ , которые были использованы как входные параметры модели. В качестве выходных параметров применялись значения интегральных характеристик пламени: массы  $m$ , количества тепла  $H$ , архimedовой подъемной силы  $F_a$ , определенных с помощью методов, описанных в [14].

В результате применения предложенного метода самоорганизации были созданы простые аналитические модели расчета интегральных характеристик пламени по неполным данным об интерферограмме. Например, одна из моделей для расчета массы имеет следующий вид:

$$m = 0,0534 + 1,5017x_1 + 2,3405x_2 - 2,5898x_3 - 0,3031x_4,$$

где  $x_1, \dots, x_4$  – нормализованные ширина, высота, площадь и периметр интерференционного изображения соответственно;  $x_i = z_i / \max(z_i)$  ( $z_i$  и  $\max(z_i)$  – текущее и максимальное значения  $i$ -й переменной,  $i=1, \dots, 4$ ).

Величины ошибок оценивались по схеме leave-one-out cross-validation, которая применяется при верификации моделей на непредставительных выборках наблюдений. Результаты проверки показали хорошую точность предсказания значений интегральных характеристик с помощью созданных моделей. Относительная ошибка не превышала 10 %.

Полученные данные показывают, что предложенный метод самоорганизации позволяет создать простые аналитические модели интерферометрии пламени на неполных экспериментальных данных в условиях горения, близких к реальным, и существенно расширить области применения интерферометрии.

**4. Синтез модели роста регионального промышленного производства.** Предложенный метод использовался для создания модели роста объема промышленной продукции Мордовии в 1995 году [16–18]. Актуальность этой задачи была вызвана тем, что под влиянием рыночных реформ в экономике региона происходили структурные изменения, которые нарушили условия, необходимые для эконометрического моделирования известными методами. К числу таких условий относятся: отсутствие скачкообразных

изменений в выборке наблюдений макроэкономических показателей, наличие представительных временных рядов наблюдений, а также возможность статистического описания неопределенности гауссовским распределением.

Как известно, при невыполнении одного из перечисленных условий невозможно использовать семейство производственных функций [19]. Если же не выполняется второе или третье условие, то невозможно применить факторный анализ [3, 4]. Метод эвристической самоорганизации, примененный к не-представительным выборкам, дает, как это было показано в разд. 1, смещенные модели решений.

В данном случае был использован предлагаемый метод самоорганизации. Для его применения количественные переменные были предварительно преобразованы в булевые по следующему правилу: выходная переменная преобразуется в «0» на интервалах наименьшего роста и в «1» на интервалах наибольшего роста. Пороговая величина роста была выбрана такой, чтобы число интервалов классов «0» и «1» отличалось не более чем на единицу (табл. 1). Всего было взято десять таких значений.

Исходный набор переменных, сформированный экспертами, включал  $m = 7$  макроэкономических показателей,ываемых республиканским Государственным комитетом по статистике, которые приведены в табл. 2. Все эти переменные ( $x_1, \dots, x_7$ ), как видно, имеют численные значения и нуждаются в преобразовании в бинарные значения. В рамках предложенного метода они преобразуются в «0» или «1» путем сравнения с порогом  $u_i$ , величина

Таблица 1  
Классификация интервалов роста

Дата	Прирост	Ускорение	$f(x_i)$
1.01.1995	155,1	—	0
1.02.1995	179,8	24,7	1
1.03.1995	209,1	29,3	1
1.04.1995	200,5	-8,6	0
1.05.1995	217,6	17,1	1
1.06.1995	337,2	119,6	1
1.07.1995	270,1	-67,1	0
1.08.1995	332,6	62,5	1
1.09.1995	176,4	-156,2	0
1.10.1995	542,6	235,2	1

Таблица 2  
Макроэкономические переменные

№ п/п	Наименование показателя	Единицы измерения
1	Производство товаров народного потребления	млрд руб.
2	Капитальные вложения	млрд руб.
3	Розничный товарооборот	млрд руб.
4	Перевозка грузов транспортом	тыс. тонн
5	Экспорт	тыс. долл.
6	Прирост сбережений во вкладах, валюте и ценных бумагах	млрд руб.
7	Денежные доходы населения	млрд руб.

Т а б л и ц а 3  
Двухфакторные модели роста

№ модели	Факторы		Модель
	1-й	2-й	
1	5	2	И
2	5	3	НЕ-И-ИЛИ
3	5	4	И
4	5	5	НЕ-И-ИЛИ
5	4	3	И
6	4	3	НЕ-И-ИЛИ
7	3	2	И
8	3	2	НЕ-И-ИЛИ

Для самоорганизации использовалась обучающая последовательность, состоящая из наблюдений вектора в каждом из девяти месяцев ( $n = 9$ ). В результате самоорганизации была получена модель, включающая четыре показателя из семи предложенных (см. табл. 2). Число ошибок на обучающей последовательности и на teste (последняя строка табл. 1) было равно нулю.

Как видно, полученные модели роста объема промышленной продукции не дали ни одного противоречивого решения на представленных данных. Интерпретация этих моделей (см. табл. 3) не вызывает трудностей – модель принятия решений формально описывается двумя логическими операторами И и НЕ-И-ИЛИ, имеющими по две входных переменных.

Подобные модели роста промышленного производства были также получены для Пензенской области в 1995–1999 гг. [16–18]. Во всех случаях модели, синтезированные на непредставительных выборках, дали состоявшиеся прогнозы, а булевые правила, определенные на их основе, эксперты нашли эффективными для практики.

**Заключение.** Исследования, проведенные в данной работе, показали, что нейросетевые модели могут быть синтезированы предложенным методом самоорганизации в условиях непредставительной статистики. Найденные модели имеют квазипримимальную сложность и обладают достаточно высокой предсказывающей способностью. Представляется, что данный метод может быть использован для создания моделей на основе непредставительной выборки экспериментальных данных в различных областях науки, техники, экономики.

В случае применения класса булевых функций результатам самоорганизации можно дать ясную и строгую интерпретацию на основе правил формальной логики. Например, созданные модели промышленного роста в регионе могут быть представлены в виде компактных булевых правил, понятных экспертам.

Авторы выражают благодарность академику Украинской академии наук А. Г. Ивахненко за плодотворное обсуждение идеи работы.

которого выбирается из условия минимума количества ошибок  $v_i$ , допускаемых однофакторными моделями  $f(x_1), \dots, f(x_7)$  роста.

В первом слое нейронной сети найдены все модели-претенденты  $f_i$ ,  $i = 1, \dots, L$ , образованные из всех возможных комбинаций булевых функций  $g$  двух аргументов,  $L = m(m-1)/2$ . Во втором слое выбраны такие модели, для которых число ошибок оказалось меньше, чем в модели предыдущего ряда. Число слоев увеличивалось, пока количество ошибок не уменьшилось до заданного уровня, в данном случае – до нуля.

В результате были найдены двухслойные нейросетевые модели развития (табл. 3).

## СПИСОК ЛИТЕРАТУРЫ

1. **Бир С.** Мозг фирмы. М.: Радио и связь, 1993.
2. **Растрогин Л. А.** Адаптация сложных систем. Рига: Зинатне, 1981.
3. **Ивахненко А. Г., Юрчиковский Ю. П.** Моделирование сложных систем по экспериментальным данным. М.: Радио и связь, 1987.
4. **Ивахненко А. Г.** Непрерывность и дискретность. Киев: Наук. думка, 1990.
5. **Self-organizing Method in Modeling: GMDH Type Algorithms** /Ed. S. Farlow. New York – Basel: Statistics, 1984.
6. **Müller J. A., Lemke F.** Self-Organizing Data Mining. Extracting Knowledge from Data. Canada British Columbia: Trafford Publishing, 2003.
7. **Глаз А. Б.** Применение принципов самоорганизации для построения решающих правил на недостаточных обучающих выборках // Автоматика. 1984. № 3. С. 3.
8. **Green D. G., Reichelt R., Bradbury R. H.** Statistical behaviour of the GMDH algorithm // Biometrics. 1988. **44**, N 1. P. 49.
9. **Schetinin V. G., Kostunin A. W.** Self-organization of neuron collective of optimal complexity // Proc. of Intern. Symp. NOLTA'96. Kochi, Japan. 1996. Vol. 1. P. 245.
10. **Щетинин В. Г.** Распознавание образов на многослойных нейронных сетях // Автометрия. 2000. № 2. С. 83.
11. **Schetinin V.** Self-organizing multilayered neural networks of optimal complexity // Journ. Automat. Control and Comput. Sci. 1998. **4**. P. 30.
12. **Schetinin V., Brazhnikov A.** Use of neural networks for compiling diagnostic rules // Biomedical Eng. 2000. **34**, N 1. P. 17.
13. **Schetinin V. G., Solomakha A. A., Kostunin A. W.** Prognosis of postoperative complications using neural networks // Biomedical Eng. 2000. **34**, N 2. P. 82.
14. **Abrukov V. S., Andreev I. V., Deltsov P. V.** Optical diagnostics: Automatic data processing and application in fundamental studies and control systems // Optical Methods for Data Processing in Heat and Fluid Flow. London: Professional Engineering Publishing, 2002. Ch. 21. P. 247.
15. **Abrukov V. S.** Automatic analysis of images // SPIE. 2004. **5301**. P. 1.
16. **Щетинин В. Г.** Анализ факторов экономического роста региона // Вопросы статистики. 1996. № 3. С. 40.
17. **Щетинин В. Г., Костюнин А. В.** Принятие решений на нейронных сетях оптимальной сложности // Автоматизация и современные технологии. 1998. № 4.
18. **Щетинин В. Г., Столярова О. В., Костюнин А. В.** Синтез решающих правил на нейронных сетях оптимальной сложности // Приборы и системы управления. 1999. № 1.
19. **Parks P. C., Ivakhnenko A. G., Boichuk L. M., Svetalsky B. K.** A self-organization model of the British economy for control with optimal prediction using the balance-of-variables criterion // Intern. Journ. Comput. and Inform. Sci. 1975. **4**, N 4. P. 349.

Поступила в редакцию 3 ноября 2004 г.