

УДК 004.67



Е.В. Мантула

ХНУРЭ, г. Харьков, Украина, elenamantula@gmail.com

## ПРОГНОЗИРУЮЩАЯ НЕЙРОННАЯ СЕТЬ С ПЕРЕМЕННОЙ СТРУКТУРОЙ ДЛЯ КОНТРОЛЯ ПОКАЗАТЕЛЕЙ ЗАГРЯЗНЕНИЯ ОКРУЖАЮЩЕЙ СРЕДЫ

В статье проведен анализ возможности использования в задачах экологического мониторинга для прогнозирования нестационарных временных рядов полиномиальных нейронных сетей, характеризующихся высокой скоростью обучения, и МГУА-сетей, которые имеют переменную структуру с возможностью изменения во время обучения. Предложена нейронная сеть, которая объединяет преимущества многослойного персептрона и МГУА-сети для обучения на основе малой выборки и численного упрощения процесса обучения сети.

ПРОГНОЗИРОВАНИЕ, НЕЙРОННАЯ СЕТЬ, МГУА – НЕЙРОННАЯ СЕТЬ, ПОЛИНОМИАЛЬНАЯ НЕЙРОННАЯ СЕТЬ, ПЕРСЕПТРОН РОЗЕНБЛАТТА

### Введение

Необходимость прогнозирования временных рядов различной природы часто возникает при анализе промышленных, сельскохозяйственных, финансово-экономических, медико-биологических, экологических систем. При этом необходимо анализировать не только интересующие исследователя ряды показателей, но и множество других факторов (экзогенных переменных), определяющих поведение контролируемого объекта. Сложность реальных систем и повышенные требования к точности прогнозирования порождают необходимость в использовании современных, зачастую достаточно сложных подходов, среди которых в первую очередь можно отметить нейросетевую, основанную на использовании искусственных нейронных сетей, обладающих необходимыми аппроксимирующими и экстраполирующими свойствами [1-4].

Понятно, что без учета специфики конкретной задачи невозможно выбрать или синтезировать архитектуру нейронной сети, наилучшим образом приспособленную для данного случая. Примером такой весьма специфической задачи является проблема контроля и прогнозирования показателей загрязнения окружающей среды, описываемых многомерными хаотическими нелинейными нестационарными рядами [5].

При этом участки стационарности рядов контролируемых показателей настолько коротки, что имеющихся данных просто не хватает, чтобы обучить все синаптические веса традиционных широко используемых нейронных сетей. В связи с этим Н. Ниска с соавторами [5] для прогнозирования показателей загрязнения воздуха предложили использовать эволюционирующие нейронные сети. При этом для выбора архитектуры нейронной сети (и набора ее входов) был использован генетический алгоритм. Данный подход весьма громоздок с вычислительной точки зрения, характеризуется низкой скоростью обучения, а базовая архитектура синтезируемой сети ограничивается

многослойным персептроном, обучаемым на основе обратного распространения ошибок. В данной работе предпринимается попытка синтеза гибридной конструкции на основе многослойного персептрона и метода группового учета аргументов [6, 7].

### 1. Полиномиальная нейронная сеть

Следуя А.Г. Ивахненко [6]: «Метод Группового Учета Аргументов (МГУА) является основой математического обеспечения ... для прямого моделирования сложных систем по небольшому числу экспериментальных данных.

Если представлены короткие выборки данных, то наиболее точные ... прогнозы дают математические модели, синтезированные по Методу Группового Учета Аргументов».

И далее: «МГУА представляет собой объединение регрессионного анализа и способов регуляризации».

Задача построения математических моделей экологического мониторинга сводится в общем случае к восстановлению неизвестных, однако, объективно существующих зависимостей между многомерными рядами контролируемых показателей загрязнения  $y(k) = (y_1(k), \dots, y_i(k), \dots, y_n(k))^T$  и многомерными же рядами экзогенных переменных  $x(k) = (x_1(k), \dots, x_p(k), \dots, x_q(k))^T$ , описывающих текущие метеорологические условия. При этом  $y_i(k)$  — значение  $i$ -го контролируемого показателя в момент времени  $k = 1, 2, \dots$ ;  $x_p(k)$  — значение  $p$ -го фактора метеорологических условий, например, скорость и направление ветра, атмосферное давление и т.п. Таким образом, речь идет о синтезе многомерной и нелинейной модели вида

$$\hat{y}(k) = f(x(k)), \quad (1)$$

связывающей с помощью некоторого априори неизвестного преобразования  $f(\cdot)$  экзогенный многомерный ряд  $x(k)$  с прогнозной оценкой  $\hat{y}(k)$  векторного процесса  $y(k)$ .

Учитывая предысторию прогнозируемых и экзогенных переменных, уравнение (1) для  $i$ -го прогнозируемого показателя можно переписать в виде:

$$\hat{y}_i(k) = f_i(y_i(k-1), \dots, y_i(k-n_{A,i}), x_1(k-1), \dots, x_1(k-n_{B,1}), x_2(k-1), \dots, x_2(k-n_{B,2}), \dots, x_p(k-l), \dots, x_q(k-n_{B,q})) \quad (2)$$

(здесь  $n_{A,i}$ ,  $n_{B,q}$  – порядки максимального запаздывания прогнозируемой и экзогенных переменных соответственно) или, переобозначая аргументы:

$$\hat{y}_i(k) = f_i(z_1(k), \dots, z_{n_{A,i}}(k), z_{n_{A,i}+1}(k), \dots, z_{n_{A,i}+n_{B,1}}(k), \dots, z_{n_{A,i}+n_{B,1}+\dots+n_{B,q}}(k)), \quad (3)$$

общее количество которых составляет

$$n_{A,i} + n_{B,1} + \dots + n_{B,q} = \hat{n}.$$

В качестве базовой модели в МГУА наиболее часто используется степенной полином Колмогорова-Габора [6], в общем случае имеющий вид:

$$\hat{y}_i(k) = w_{i0} + \sum_{j_1=1}^{\hat{n}} w_{ij_1} z_{j_1}(k) + \sum_{j_1=1}^{\hat{n}} \sum_{j_2=j_1}^{\hat{n}} w_{ij_1 j_2} z_{j_1}(k) z_{j_2}(k) + \dots + \sum_{j_1=1}^{\hat{n}} \sum_{j_2=j_1}^{\hat{n}} \dots \sum_{j_l=j_{l-1}}^{\hat{n}} w_{ij_1 j_2 \dots j_l} z_{j_1}(k) z_{j_2}(k) \dots z_{j_l}(k), \quad (4)$$

где  $w_{ij}, \dots$  – параметры полинома, подлежащие оцениванию. Опираясь на теорему Стоуна-Вейерштрасса, можно показать, что при некоторых степенях аргументов  $z_j$  может быть достигнута сколь угодно высокая точность аппроксимации.

Описание (4) лежит в основе так называемой полиномиальной нейронной сети [8-11], архитектура которой приведена на рис. 1.




Рис. 1. Полиномиальная нейронная сеть

Первый скрытый слой расширяет входное пространство с помощью полиномиального нелинейного преобразования входного вектора

$$z = (z_1, z_2, \dots, z_{n_{A,i}+n_{B,1}+n_{B,q}})^T,$$

так что происходит отображение входов в новое пространство повышенной размерности

$$z \in R^{n_{A,i}+n_{B,1}+\dots+n_{B,q}} \rightarrow (\varphi_1(z), \varphi_2(z), \dots, \varphi_n(z))^T \in R^H. \quad (5)$$

Выходной же слой образован  $n$  обычными адальнами [4] и реализует отображение расширенного пространства в выходное

$$\varphi(z) \in R^H \rightarrow \hat{y} = (\hat{y}_1, \hat{y}_2, \dots, \hat{y}_n)^T \in R^n, \quad (6)$$

так что

$$\hat{y}_i = w_{i0} + \sum_{j=1}^H w_{ij} \varphi_j(z), \quad i = 1, 2, \dots, n. \quad (7)$$

Здесь важно, что каждая из функций  $\varphi_j(z)$  зависит только от входного сигнала  $z$  и используемого полиномиального расширения и не содержит свободных параметров, что выгодно отличает полиномиальные сети от популярных и широко используемых радиально-базисных нейронных сетей.

Полиномиальные сети характеризуются высокой скоростью обучения, благодаря тому, что их выходной сигнал линейно зависит от настраиваемых синаптических весов  $w_{ij}$ . Однако они имеют один существенный недостаток: большое количество этих весов, что приводит к так называемому «проклятию размерности» [12]. Несложно показать, что при использовании кубических полиномов и  $\hat{n} = 20$  (что не так уж велико) полиномиальная сеть содержит 1270 настраиваемых синаптических весов [8], что вызывает проблемы со скоростью обучения и требованием достаточно длинной обучающей выборки, получить которую в системах экологического мониторинга весьма сложно.

## 2. МГУА-нейронная сеть на элементарных персептронах Розенблатта

Преодолеть отмеченное выше затруднение можно, используя так называемые МГУА-нейронные сети [3], в основе которых лежат идеи стандартного МГУА А.Г. Ивахненко. На рис. 2 приведен пример такой сети с четырьмя входами  $z_1, z_2, z_3, z_4$  и одним выходом  $\hat{y}_i$ .




Рис. 2. МГУА-нейронная сеть

В отличие от традиционных нейронных сетей с фиксированной архитектурой типа классического многослойного персептрона МГУА-сеть имеет переменную структуру, которая может изменяться в процессе обучения. В наиболее известной МГУА-нейронной сети [3] в качестве нейронов  $N^{(l)}$  используются нелинейные адальны (N-адальны), которые отличаются от описанных выше обычных адалин тем, что содержат элементарный нелинейный препроцессор, образованный тремя блоками умножения, и вычисляют квадратичную комбинацию двух произвольных входов в виде:

$$\hat{y}_{gh} = f_{gh}(z_g, z_h) = w_{gh0} + w_{gh1}z_g + w_{gh2}z_g^2 + w_{gh3}z_g z_h + w_{gh4}z_h^2 + w_{gh5}z_h^3 = w_{gh}^T z_{gh}, \quad (8)$$

где  $w_{gh} = (w_{gh0}, w_{gh1}, w_{gh2}, w_{gh3}, w_{gh4}, w_{gh5})^T$ ,  
 $z_{gh} = (1, z_g, z_g^2, z_g z_h, z_h^2, z_h^3)^T$ .

При этом, поскольку каждый нейрон содержит два входа, общее количество нейронов первого скрытого слоя определяется числом сочетаний  $c_n^2 = 0,5(\hat{n}(\hat{n}-1))$ .

В случае, когда прогнозируемый сигнал  $y_i(k)$  имеет достаточно сложную внутреннюю структуру, аппроксимирующих возможностей N-адалин может оказаться недостаточно. В этом случае в качестве узлов МГУА-сети могут быть использованы более сложные конструкции [13, 14], которые при этом и обучаются сложно, и требуют больших объемов обучающей выборки.

Преодолеть отмеченное затруднение, на наш взгляд, возможно, объединяя достоинства МГУА-нейронных сетей с универсальными аппроксимирующими возможностями многослойных персептронов [15-17], узлами которых являются элементарные персептроны Розенблатта [1]. На рис. 3 приведена схема такого нейрона с двумя входами  $z_g$  и  $z_h$ .




Рис. 3. Элементарный персептрон Розенблатта с двумя входами

Преобразование, реализуемое таким нейроном, может быть записано в виде:

$$\hat{y}_{gh} = f(z_g, z_h) = \psi(w_{gh0} + w_{gh1}z_g + w_{gh2}z_h) = \psi(u_{gh}) = \psi(w_{gh}^T z_{gh}), \quad (9)$$

где  $\psi(u_{gh})$  – нелинейная активационная функция, обеспечивающая нейрону требуемые свойства [15].

В качестве активационных функций обычно используются либо сигмоидальная функция (однополярная)

$$\hat{y}_{gh} = \frac{1}{1 + e^{-\gamma u_{gh}}}, \quad (10)$$

либо биполярная функция гиперболического тангенса

$$\hat{y}_{gh} = \tanh(\gamma u_{gh}) = \frac{1 - e^{-2\gamma u_{gh}}}{1 + e^{-2\gamma u_{gh}}}, \quad (11)$$

где  $\gamma > 0$  – параметр крутизны активационной функции.

Основное отличие между адалиной и элементарным персептроном Розенблатта состоит в алгоритме обучения, поскольку в адалине ошибка обучения

$$e_{gh} = y_i - \hat{y}_{gh} \quad (12)$$

является линейной функцией вектора входов  $z_{gh}$ , в то время как ошибка обучения персептрона

$$e_{gh} = y_i - \hat{y}_{gh} = y_i - \psi(w_{gh}^T z_{gh}) \quad (13)$$

от входов и синаптических весов зависит нелинейно, причем характер этой нелинейности определяется активационной функцией. Данное обстоятельство затрудняет процесс обучения персептрона и требует использования специальных методов обучения, отличных от процедур, основанных на стандартном методе наименьших квадратов.

Процесс обучения будем проводить путем минимизации критерия

$$\begin{aligned} J_i(k) &= \frac{1}{2} e_{gh}^2(k) = \frac{1}{2} (y_i(k) - \hat{y}_{gh}(k))^2 = \\ &= \frac{1}{2} (y_i(k) - \psi(u_{gh}(k)))^2 = \\ &= \frac{1}{2} (y_i(k) - \psi(\sum_{l=0}^5 w_{ghl} z_l(k)))^2 = \\ &= \frac{1}{2} (y_i(k) - \psi(w_{gh}^T z_{gh}(k)))^2 \end{aligned} \quad (14)$$

с помощью рекуррентной процедуры

$$\begin{aligned} w_{ghl}(k+1) &= w_{ghl}(k) - \eta(k) \frac{\partial J_i(k)}{\partial e_{gh}(k)} \frac{\partial e_{gh}(k)}{\partial w_{ghl}} = \\ &= w_{ghl}(k) - \eta(k) e_{gh}(k) \frac{\partial e_{gh}(k)}{\partial w_{ghl}} = \\ &= w_{ghl}(k) - \eta(k) e_{gh}(k) \frac{\partial e_{gh}(k)}{\partial u_{gh}(k)} \frac{\partial u_{gh}(k)}{\partial w_{ghl}} = \\ &= w_{ghl}(k) + \eta(k) e_{gh}(k) \psi'(u_{gh}(k)) z_l(k) = \\ &= w_{ghl}(k) + \eta(k) \delta_{gh}(k) z_l(k), \end{aligned} \quad (15)$$

где

$$\delta_{gh}(k) = e_{gh}(k) \psi'(u_{gh}(k)) = -\frac{\partial J_i(k)}{\partial u_{gh}} \quad (16)$$

– локальная ошибка,  $\eta(k)$  – параметр шага обучения.

В векторной форме алгоритм (15) имеет вид:

$$w_{gh}(k+1) = w_{gh}(k) + \eta(k) \delta_{gh}(k) z_{gh}(k) \quad (17)$$

и известен под названием дельта – правила обучения.

Заметим также, что для активационной функции (10) алгоритм (17) приобретает форму

$$\begin{aligned} w_{gh}(k+1) &= w_{gh}(k) + \eta(k) \gamma e_{gh}(k) \hat{y}_{gh}(k) \\ &\quad (1 - \hat{y}_{gh}(k)) z_{gh}(k), \end{aligned} \quad (18)$$

а для активационной функции (11) –

$$\begin{aligned} w_{gh}(k+1) &= w_{gh}(k) + \eta(k) \gamma e_{gh}(k) \\ &\quad (1 - \hat{y}_{gh}^2(k)) z_{gh}(k). \end{aligned} \quad (19)$$

Качество обучения на основе дельта – правила (12) существенным образом зависит от обоснованного выбора параметра шага  $\eta(k)$ , при этом если имеется достаточно длинная обучающая выборка, неудачный выбор приведет лишь к снижению скорости сходимости. В случае же короткой выборки результаты гораздо более критичны к выбору шага.

В этом случае более целесообразным представляется использование модифицированного алгоритма Чана-Фоллсайда [18], приобретающего в данном случае вид

$$w_{gh}(k+1) = w_{gh}(k) + \eta(k)(\nabla_{w_{gh}} J_i(k) + \beta(k)\Delta w_{gh}(k-1)), \quad (20)$$

где

$$\beta(k) = \begin{cases} \beta_0 \frac{\Delta J_i(k-1)}{\|\Delta w_{gh}(k-1)\|}, & \text{если } \Delta w_{gh}(k-1) \leq \varepsilon, \\ 0 & \text{в противном случае,} \end{cases} \quad (21)$$

$$\eta(k) = \eta(k-1)(1 + a \cos \theta(k)), \quad (22)$$

$$\cos \theta(k) = \frac{\nabla_{w_{gh}} J_i^T(k) \Delta w_{gh}(k-1)}{\|\nabla_{w_{gh}} J_i(k)\| \|\Delta w_{gh}(k-1)\|}, \quad (23)$$

$\varepsilon$  - пороговый параметр, определяющий момент “включения” регуляризующего члена

$$\Delta w_{gh}(k-1);$$

$$\Delta w_{gh}(k-1) = \Delta w_{gh}(k) - \Delta w_{gh}(k-1);$$

$$\Delta J_i(k-1) = J_i(k) - J_i(k-1); 0,1 \leq a \leq 0,5.$$

Одновременно с синаптическими весами, число которых всего три, можно настраивать и четвертый параметр, характеризующий крутизну активационных функций (10), (11) -  $\gamma$ . Для этого можно воспользоваться алгоритмом, введенным в [19] и являющимся обычной градиентной процедурой оптимизации

$$\begin{aligned} \gamma(k+1) &= \gamma(k) - \eta_\gamma(k) \frac{\partial J_i(k)}{\partial \gamma} = \\ &= \gamma(k) - \eta_\gamma(k) e_{gh}(k) \frac{\partial \psi(\gamma(k) u_{gh}(k))}{\partial \gamma}. \end{aligned} \quad (24)$$

При этом для регулирования параметра шага  $\eta_\gamma(k)$  можно воспользоваться соотношением (22).

Таким образом, настройка всех параметров персептрона Розенблатта производится с помощью соотношений (20) – (24).

В целом же МГУА-нейронная сеть обучается следующим образом. Сначала формируется первый скрытый слой из персептронов Розенблатта с двумя входами  $z_g(k)$  и  $z_h(k)$  с четырьмя настраиваемыми параметрами  $w_{gh0}, w_{gh1}, w_{gh2}, \gamma$ . Общее число этих персептронов  $0,5\hat{n}(\hat{n}-1)$ , а обучаются они параллельно и независимо друг от друга с помощью общего обучающего сигнала  $y_i(k)$ . По

исчерпанию обучающей выборки оценивается точность каждого из узлов, после чего в первом слое оставляют только  $\hat{n}$  наилучших. После этого их параметры “замораживаются” и в дальнейшем эти узлы только пропускают через себя входной сигнал на второй скрытый слой. Второй скрытый слой формируют из  $0,5\hat{n}(\hat{n}-1)$  нейронов и обучают точно так же. Входами этого слоя являются выходы  $\hat{n}$  наилучших нейронов первого слоя. По исчерпанию обучающей выборки оценивается точность каждого из персептронов второго слоя, и в слое остаются только нейроны, чья точность выше чем у наилучшего из нейронов первого слоя. Процесс наращивания слоев продолжается до тех пор, пока в последующем слое не останется единственный нейрон, чей выход является и выходом МГУА-сети в целом.

Поскольку любой из нейронов сети обучается независимо от других, многослойная сеть, содержащая произвольное число узлов, может обучаться на основе малой выборки, что характерно в задачах экологического мониторинга.

## Выводы

Рассмотрена задача прогнозирования нестационарных временных рядов, характеризующихся короткой обучающей выборкой, что характерно для задач экологического мониторинга. Рассмотрены возможности применения полиномиальных и МГУА-нейронных сетей и введена нейронная сеть, являющаяся “гибридом” многослойного персептрона и МГУА-сети и обладающая рядом преимуществ перед своими прототипами. Введен численно простой метод обучения этой сети.

**Список литературы:** 1. *Cichocki A.* Neural Networks for Optimization and Signal Processing [Текст] / A. Cichocki, R. Unbehauen // – Stuttgart: Teubner, 1993 – 526 p. 2. *Masters T.* Practical Neural Networks Recipes in C++ [Текст] / T. Masters. – San Diego: Academic Press, Inc., 1993. – 493 p. 3. *Pham D. T.,* Neural Networks for Identification, Prediction and Control [Текст] / D. T. Pham, X. Liu // – London: Springer – Verlag, 1995. – 238 p. 4. *Haykin S.* Neural Networks: A Comprehensive Foundation [Текст] / S. Haykin – Upper Saddle River, N. J.: Prentice-Hall, Inc., 1999. – 842 p. 5. *Niska H.* Evolving the neural network model for forecasting air pollution time series // Engineering Application of Artificial Intelligence [Текст] / H. Niska, T. Hiltunen, A. Karppinen, J. – 2004. – 17. – P. 159–167. 6. *Ивахненко А. Г.* Системы эвристической самоорганизации в технической кибернетике [Текст] / А. Г.Ивахненко – Киев: Техника, 1971. – 372 с. 7. *Ивахненко А. Г.* Помехоустойчивость моделирования [Текст] / А. Г. Ивахненко, В. С. Степашко // Киев: Наук. Думка, 1985. – 216 с. 8. *Billings A.* Extended model set, global data and threshold model identification of severely non-linear systems [Текст] // A. Billings, S. Chen // Int. J. Control. – 1989. – 50. – P. 1897-1923. 9. *Harris C. J.,* Intelligent Control. Aspects of Fuzzy Logic and Neural Nets [Текст] / C. J. Harris, C. G. Moore, M. Brown // Singapore: World Scientific. – 1993. – 380 p. 10. *Brown M.* Neural networks for



modelling and control / Ed. by C. J. Harris "Advances in Intelligent Control" [Текст] / M. Brown, C. J. Harris - London: Taylor and Francis, 1994. - P. 85-112. **11.** Бодянский Е.В. Искусственные нейронные сети: архитектуры, обучение, применения [Текст] / Е. В.Бодянский, О. Г. Руденко // - Харьков. ТЕЛТЕХ, 2004. - 372 с. **12.** Wang H., Advanced Adaptive Control [Текст] / H. Wang, G. P., C. J. Harris, M. Brown - Oxford: Pergamon, 1995. - 262 p. **13.** Bodyanskiy Ye., Hybrid GMDH-neural network of computational intelligence // Proc. Int. Workshop on Inductive Modelling 2009 [Текст] / Ye. Bodyanskiy, O. Vynokurova, I. Pliss // - Krynica, Poland, 2009. - P. 100 - 107. **14.** Bodyanskiy Ye. The neo-fuzzy neural network structure optimization using the GMDH for the solving forecasting and classification problems // Proc. Int. Workshop on Inductive Modelling 2009 [Текст] / Ye. Bodyanskiy, Yu. Zaychenko, E. Pavlikovskaya, M. Samarina, Ye. Viktora. - Krynica, Poland, 2009. - P. 77-89. **15.** Cybenko G. Approximation by superposition of a sigmoidal function // Math Contr. Sign. and Systems [Текст] / G. Cybenko, 1989 -2. P. 303-314. **16.** Hornik K., Multilayer feedforward networks are universal approximators [Текст] / K. Hornik, M. Stinchcombe, H. White // Neural Networks. - 1989. - 2 - P. 359-366. **17.** Hornik K. Approximation capabilities of multilayer feedforward networks [Текст] / K. Hornik // Neural Networks. - 1991. - 4. - P.251-257. **18.** Chan L.W., An adaptive learning algorithm for backpropagation networks [Текст] / L.W. Chan, F. Fallside // Computer Speech and Language. - 1987. - 2. - P. 205-218. **19.** Kruschke J. K., Benefits of gain: Speeded learning and minimal hidden layers in back propagation networks [Текст] / J. K. Kruschke, J.R. Movellan // IEEE Trans. on Syst., Man and Cybern. - 1991. - 21. - P. 67-70.

Поступила в редколлегию 22.02.2013

УДК 004.67

**Прогнозуюча нейронна мережа зі змінною структурою для контролю показників забруднення навколишнього середовища** / О.В. Мантула // Біоніка інтелекту: наук.-техн. журнал. - 2013. - № 1 (80). - С. 112-116.

В статті розглядається задача прогнозування часових рядів, яка є характерною при вирішенні питань екологічного моніторингу. Розглядається застосування поліноміальних мереж, які характеризуються високою швидкістю навчання завдяки тому, що сигнал на виході лінійно залежить від синаптичних ваг. Проте використання цих мереж призводить до проблеми, пов'язаної з експонентним зростанням кількості даних, обумовленим зростанням розмірності вхідного простору та МГУА-нейронних мереж, що дають найточніші прогнози в умовах короткої вибірки. Запропоновано та побудовано на їх основі нейронну мережу, що має ряд переваг і використання якої чисельно спрощує процес навчання мережі.

Л. 3. Бібліогр.: 19 найм.

UDK 004.67

**Predictive neural network with variable structure to control pollution indicators** / O.V. Mantula // Bionics of Intelligense: Sci. Mag. - 2013. - № 1 (80). - P. 112-116.

Article is devoted to the problem of time series forecasting, which is typical problem in environmental monitoring. The application of polynomial networks, which characterized by a high rate of learning due to the fact that the output signal of a linear function depends on synaptic weights, which using leads to a problem with the amount of data exponential increase due to higher dimensional space and the GMDH-neural networks, which give the most accurate forecasts in a conditions of short sample. Proposed neural network, based on them, and has a number of advantages, which using is greatly simplifies network training.

Fig. 3. Ref.: 19 items