

УДК 004.032.26

С.В. Попов, Т.Е. Чепенко

Харьковский национальный университет радиоэлектроники, Харьков

ПРОГНОЗИРОВАНИЕ НЕСТАЦИОНАРНОГО МНОГОМЕРНОГО ВРЕМЕННОГО РЯДА НА ОСНОВЕ СПЕЦИАЛИЗИРОВАННОЙ НЕЙРОННОЙ СЕТИ

Статья посвящена разработке специализированной искусственной нейронной сети, предназначенной для прогнозирования многомерных рядов показателей, описывающих поведение сложных многосвязных систем и методов обучения этой сети. Рассмотрен пример моделирования процесса одношагового прогнозирования многомерного ряда на основе искусственной нейронной сети с динамическими нейронами и на основе искусственной нейронной сети на нейронах-фильтрах. Решена задача построения прогнозирующей модели системы охранной сигнализации, с учетом нестационарности прогнозируемой последовательности. Синтезирована прогнозирующая искусственная нейронная сеть на динамических нейронах.

Ключевые слова: специализированные искусственные нейронные сети, временной ряд, многомерные стохастические процессы, динамические нейроны-фильтры, конечная и бесконечная импульсные характеристики.

Введение

Задача прогнозирования многомерных стохастических временных рядов в условиях структурной и параметрической неопределенности в настоящее время является актуальной и находит широкое применение в различных исследованиях как технического, так и математического направления [1 – 3].

Анализ проблемы. Поведение многих сложных систем определяют различные факторы такие, как нестационарность прогнозируемых последовательностей, высокий уровень априорной и текущей неопределенности, нелинейность, непредсказуемые «скачки» в показателях. При этом традиционные подходы [4] могут оказаться неэффективными, в связи с чем применяются методы нейросетевого прогнозирования (например NARMA-модели, соответствующие нелинейным процессам авторегрессии-скользящего среднего) [5]. Трудность использования нейросетевых моделей определяется тем, что модели сложных многосвязных систем могут иметь специфические формы (структурные и приведенные), отличающиеся от NARMA-структур, а также тем, что обучение нейросетей требует больших обучающих выборок.

Указанные обстоятельства требуют проведения специальных исследований, результатом которых должны стать специализированные нейросети и процедуры их обучения, предназначенные для прогнозирования многомерных рядов показателей, описывающих поведение сложных систем. Решение данной задачи дает возможность предсказать нежелательные режимы сложных многосвязных систем и улучшить качество процессов управления ими.

Целью данной работы является разработка структуры специализированной искусственной нейронной сети (ИНС) для прогнозирования многомер-

ного ряда показателей [6], описывающего поведение сложной многосвязной системы.

Нелинейные стохастические динамические объекты, функционирующие в условиях априорной и текущей параметрической неопределенности могут быть заданы при помощи отображения

$$y(k) = F(y(k-1), \dots, y(k-d), x(k-1), \dots, x(k-d), w) + \xi(k),$$

где $y(k)$ – m -мерный вектор выходов объекта в дискретный момент времени $k = 0, 1, 2, \dots, N$; F – нелинейный неизвестный оператор, подлежащий определению; d – порядок запаздывания; $x(k)$ – n -мерный вектор входных сигналов; w – вектор неизвестных коэффициентов, подлежащих определению; $\xi(k)$ – вектор возмущений, представляющих собой случайные помехи с нулевым математическим ожиданием и неизвестной функцией плотности распределения с ограниченным вторым моментом.

Для заданных объектов строим прогноз сигнала $y(k)$

$$\hat{y}(k+1) = \hat{F}(x(k), \hat{w}, \hat{d}),$$

где l – горизонт прогнозирования, минимизирующий в текущем времени критерий обучения и определяющий рассогласование между выходным сигналом реального объекта и выходом прогнозирующей модели; \hat{F} – оценка оператора нейросети; $\hat{y}, \hat{w}, \hat{d}$ – оценки соответствующих параметров.

Использование методов адаптивного прогнозирования и нелинейной идентификации сложных систем [7, 8] и методов теории ИНС [9, 10] в задачах моделирования и прогнозирования многосвязных

систем позволяет разработать специализированные архитектуры ИНС и процедуры их обучения.

Прогнозирование многомерных рядов показателей

В качестве примера рассмотрим задачу прогнозирования многомерных временных рядов, используя ряд, описывающий потребление электроэнергии, горячей и холодной воды в пределах крупного здания в зависимости от времени суток и погодных условий.

При прогнозировании значений выходных параметров используются заданные значения входных переменных, а именно: год, месяц, число, время, температура воздуха, относительная влажность, уровень солнечной радиации, скорость ветра. Данные заданы в виде таблицы, содержащей значения перечисленных величин, измеренные с интервалом в один час на протяжении полугода.

Для устранения отрицательного влияния несогласности единиц измерения различных величин на качество прогнозирования все данные предварительно нормированы. Первые 1000 измерений прогнозируемых переменных представлены на рис. 1. Верхний график отражает потребление горячей воды, средний – холодной воды, нижний – электроэнергии. Все ряды после нормировки имеют нулевое математическое ожидание, но на графиках разнесены по оси ординат для удобства визуального представления. Такой способ отображения многомерных рядов принят и в дальнейшем.

Анализ данных показывает, что, во-первых, они имеют ярко выраженные суточные колебания и, во-вторых, средние уровни потребления существенно различаются в разные дни недели. Это означает, что для успешного решения поставленной задачи необходимо ввести день недели в качестве входной переменной, при этом месяц и число могут быть заменены одним более информативным значением – номером дня в году, а сам год исключен, так как не несет существенной информации.




Рис. 1. Входные переменные

Представление времени суток требует некоторой модификации. Это связано с тем, что общепринятый способ представления времени имеет числен-

ные разрывы в моменты смены суток (рис. 2, а): после 23 часов наступает 0 часов, хотя в самом времени, естественно, никакого разрыва нет. Для устранения разрывов удобно применить кодировку времени t с помощью тригонометрического преобразования $st = \sin(t/24)$, $ct = \cos(t/24)$. Полученная пара переменных имеет взаимно однозначное соответствие с исходной переменной, однако не претерпевает разрывов (рис. 2, б – на верхнем графике – st , на нижнем графике – ct). Аналогичное преобразование необходимо произвести и для номера дня в году.

Информация о дне недели проще всего кодируется введением семи флажковых переменных, каждая из которых равна «1» в соответствующий день и «0» во все остальные (рис. 3).

После соответствующих преобразований, введения новых и исключения несущественных переменных на вход процедуры прогнозирования подается 15 значений (рис. 4), отражающих текущее состояние, на основе которого должны быть спрогнозированы 3 выходные переменные.

Для оценки качества прогнозирования используются следующие критерии: квадрат ошибки $SE(k) = \|e(k)\|^2$, где $e(k)$ – мгновенное значение ошибки на k -м шаге прогнозирования; нормированная средне-

квadraticная ошибка
$$NRMSE = \frac{\sqrt{\frac{1}{N} \sum_{k=1}^N SE(k)}}{\sigma_x}$$
,

где N – число наблюдений; σ_x – среднеквадратичное отклонение прогнозируемого ряда. Следует обратить внимание, что $SE(k)$ вычисляется на каждом шаге прогнозирования, а $NRMSE$ – на каждой эпохе, то есть после прохождения всего ряда.

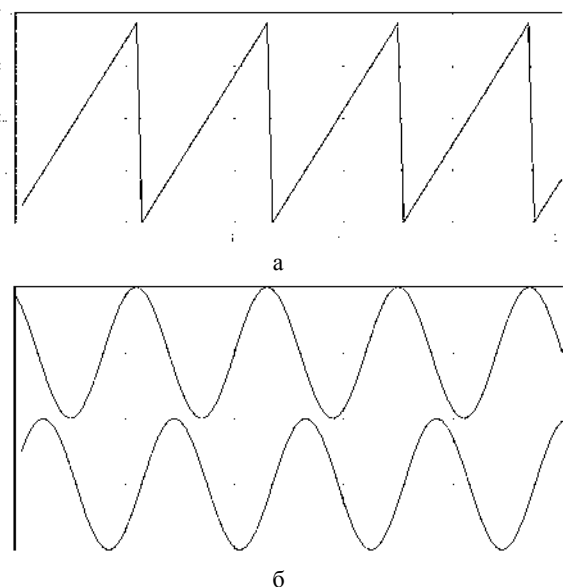


Рис. 2. Изменение времени суток:
а – при общепринятом представлении;
б – закодированное с помощью тригонометрических функций




Рис. 3. Представление информации о дне недели




Рис. 4. Входные переменные для процедур прогнозирования


Проведем моделирование процесса одношагового прогнозирования многомерного ряда показателей на основе линейной модели:

$$y(k) = Ax(k) + \xi(k),$$


где $y(k)$ – вектор, описывающий прогнозируемую последовательность в дискретный момент времени $k = 0, 1, 2, \dots, N$; A – матрица параметров, подлежащих определению; $x(k)$ – n -мерный вектор предыстории; $\xi(k)$ – вектор неконтролируемых внешних возмущений.

Матрица параметров A в данном случае имеет размер 3×15 , то есть содержит 45 настраиваемых параметров. Сначала в качестве алгоритма обучения используем процедуру Качмажа [11]. Для введения в процесс обучения сглаживающего эффекта, используем процедуру с параметром сглаживания $\alpha = 0,7$.

Результаты прогнозирования представлены на рис. 5. Время моделирования составило 0,27 с, при этом ошибка по всей выборке $\text{NRMSE} = 0,3426$. Характерной особенностью полученных результатов являются резкие выбросы и осцилляция прогноза вокруг желаемого значения. Это связано с одношаговой структурой данного алгоритма обучения, что делает его крайне чувствительным к шумам, неизбежно присутствующим в данных.




а




б

Рис. 5. Результаты прогнозирования с применением процедуры Качмажа: а – время моделирования 0,27 с, ошибка по выборке 0,3426 (сплошная линия – желаемый сигнал, пунктирная линия – прогноз); б – мгновенные значения ошибки $SE(k)$

Результаты моделирования с применением процедуры со сглаживающими свойствами [6, 12] представлены на рис. 6.



а



б

Рис. 6. Результаты прогнозирования с применением процедуры со сглаживающими свойствами: а – время моделирования 0,39 с, ошибка по выборке $\text{NRMSE} = 0,3664$ (сплошная линия – желаемый сигнал, пунктирная линия – прогноз); б – мгновенные значения ошибки $SE(k)$

Время моделирования составило 0,39 с, ошибка по выборке $\text{NRMSE} = 0,3664$. На графике прогноза

отчетливо проявляются сглаживающие свойства процедуры: выбросы и осцилляция практически полностью исчезли, однако в целом появилось некоторое запаздывание прогноза относительно требуемого ряда. Такое поведение имеет две стороны: отрицательная – за счет запаздывания несколько возросла ошибка по выборке, положительная – уменьшение числа всплесков мгновенной ошибки. Важное преимущество сглаженной процедуры по сравнению с процедурой Качмажа состоит в том, что большая ошибка является ложным сигналом для последующих процедур, использующих результат прогнозирования.

Использование матричного коэффициента усиления совместно со сглаживанием в процедуре Петерки [13] позволяет достичь некоторого компромисса между скоростью сходимости и подавлением выбросов (рис. 7).




Рис. 7. Результаты прогнозирования с применением алгоритма Петерки : а – время моделирования 0,56 с, ошибка 0,3533 (сплошная линия – желаемый сигнал, пунктирная линия – прогноз); б – мгновенные значения ошибки $SE(k)$

Особенно это заметно на графике $SE(k)$ (рис. 7, б), где мгновенное значение ошибки редко выходит за уровень 0,2. Однако за повышение качества всегда нужно чем-то платить и в данном случае ценой является повышение вычислительной сложности процедур, что отражается на общем времени моделирования, которое для процедуры Петерки в два раза больше, чем для процедуры Качмажа.

Используем для моделирования тот же многомерный ряд, однако усложним задачу прогнозирования. Если ранее производилось прогнозирование выходных переменных на том же интервале, для которого были заданы входные переменные, то теперь

построим прогноз на 12 часов вперед. Обучение будем производить в пакетном режиме [5], что позволит один раз настроить сеть на обучающей выборке и затем использовать ее на любом участке ряда без необходимости постоянной подстройки весов.

Архитектура нейронной сети (рис. 8) имеет 15 входов, 10 нейронов с сигмоидальной активационной функцией [14] в скрытом слое и 3 нейрона с линейной активационной функцией в выходном слое, каждый динамический фильтр с конечной импульсной характеристикой имеет по 2 элемента задержки [15].




Рис. 8. Архитектура специализированной нейронной сети

Общее число параметров такой сети составляет 553, при этом заметим, что если бы сеть с аналогичными свойствами реализовывалась на основе многослойного персептрона с элементами задержки на входах сети, то она содержала бы 2823 параметра. Таким образом, даже для такой простой задачи выигрыш по числу настраиваемых параметров более чем в 5 раз.

Моделирование выполнялось на протяжении 500 эпох, каждая из которых заняла 23,5 с. Результаты моделирования приведены на рис. 9. Анализ полученных результатов подтверждает, что время обучения на 2 порядка больше, чем в случае применения простых линейных моделей, однако при этом решается значительно более сложная задача и достигается более высокая точность: $NRMSE = 0,3317$. По сравнению с линейными методами следует отметить полное отсутствие запаздывания прогноза и больших ошибок, что связано именно с пакетным режимом обучения сети.

Эту же задачу можно решить, внося в архитектуру сети изменение: в синапсах использовать фильтры с бесконечной импульсной характеристикой с одним элементом задержки на входе и одним на выходе [16]. При таком построении сети число ее параметров уменьшается до 373, но длина памяти становится бесконечной, что имеет свои плюсы и минусы. К положительным качествам следует отнести возможность моделирования процессов с дли-

тельными зависимостями между переменными, без наращивания длины линий задержки на входах нейронов. Однако процесс обучения становится более громоздким в связи с необходимостью учета взаимовлияния входных данных на состояние сети во все последующие моменты времени. В случае большой обучающей выборки это может быть существенным затруднением, поэтому в реализацию алгоритма обучения целесообразно ввести ограничение на длину просматриваемой памяти. Так в данной реализации учитывается влияние только 100 ближайших входных значений.




Рис. 9. Результаты прогнозирования с применением нейросети на базе динамических нейронов: а – сплошная линия – желаемый сигнал, пунктирная линия – прогноз; б – эволюция ошибки по ходу процесса обучения (NRMSE=0,3317)

Результаты моделирования представлены на рис. 10.

Процесс обучения занял 500 эпох, после чего ошибка NRMSE замедлила падение и установилась на уровне 0,3353. Одна эпоха обучения занимает 38,6 с, что медленнее, чем в случае применения динамических фильтров по названным выше причинам. Качество полученного прогноза практически совпадает с результатами, полученными в предыдущем случае, но число параметров сети при этом меньше в полтора раза.

Снизилась также и скорость сходимости процесса обучения: после 100 эпох ошибка находится на уровне 0,7, в то время как для сети на базе динамических нейронов она составляла порядка 0,5. Это еще один эффект, связанный с бесконечностью памяти сети.




Рис. 10. Результаты прогнозирования с применением нейросети на базе нейронов-фильтров: а – сплошная линия – желаемый сигнал, пунктирная линия – прогноз; б – эволюция ошибки по ходу процесса обучения (NRMSE=0,3353)

Прогнозирующая модель системы охранной сигнализации

Решим задачу построения прогнозирующей модели системы охранной сигнализации одного из районов города. Особенностью современных систем наблюдения является возможность организации сетевого соединения между удаленными объектами. Рассмотрим пример работы сети с использованием выделенных телефонных линий для передачи сигнала от АТС к пульту централизованной охраны, который позволяет отслеживать состояние средств сигнализации на предприятиях, в организациях, офисах, квартирах. Наблюдение осуществляет оператор, который фиксирует сообщения, поступающие с различных устройств на объектах. Количество «сработок» суммируется за смену, а также за сутки, записывается в файл и вместе с файлом обработанных данных является отчетом работников охранного комплекса. Данная информация – количество «сработок» по району за восьмичасовую смену – является исходной информацией, подлежащей обработке и прогнозированию. Эта последовательность является существенно нелинейной, так как подвержена неконтролируемым возмущениям. В связи с этим представляется возможным применение нейросетевых методов прогнозирования.

Чтобы решить задачу прогнозирования количества выходных данных, а также зависимости от различных стохастических воздействий, будем поочередно подавать эту последовательность на входы

различных прогнозирующих моделей. Исследование может быть остановлено, если достигнутый результат наиболее точно характеризует состояние на объектах в течение заданного промежутка времени и с учетом новых входных данных. На рис. 11 показан ряд входных данных для прогнозирующей модели, который характеризуется наличием различных «скачков» и выбросов в показателях, а также определенной сезонной зависимостью. Верхний график отражает события за сутки, остальные – события за 1, 2 и 3-ю смену соответственно.

Для реализации поставленной задачи синтезируем нейронную сеть на динамических нейронах с одним входом, тремя нейронами в скрытом слое и одним нейроном в выходном слое (рис. 12).




Рис. 11. Значения входных данных для прогнозирующей модели

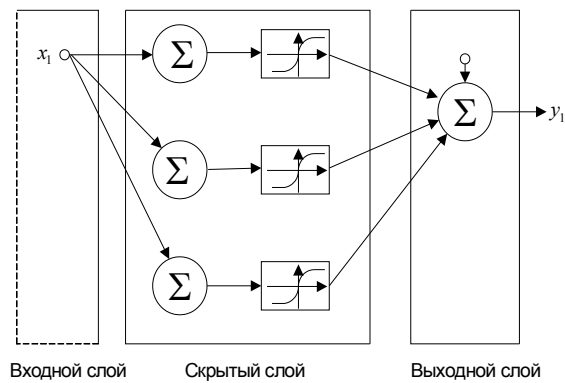



Рис. 12. Нейронная сеть на динамических нейронах


Каждый из динамических нейронов, на базе которых построена нейросеть, имеет элементы задержки. В нейронной сети имеется 46 настраиваемых параметров. Обучение в пакетном режиме позволяет настроить сеть на обучающей выборке и использовать результат на любом участке ряда без подстройки весов. Моделирование выполнялось на протяжении 120 эпох. Прогнозирование выходных переменных произведено как на интервале, для которого были заданы входные переменные, так и на 30 шагов вперед.

Результаты прогнозирования выходных параметров с применением нейросети на динамических нейронах приведены на рис. 13. На рис. 13, а можно видеть несущественное отличие прогнозируемой последовательности от реальной выборки данных. Несмотря на то, что время обучения нейросетевой модели на динамических нейронах больше, чем в случае применения линейных моделей, становится возможным достижение достаточной степени точности в условиях нелинейности и неопределенности: $NRMSE=0,6203$.

Таким образом, при решении практической задачи построения прогнозирующей модели системы охранной сигнализации, учитывающей нестационарность прогнозируемой последовательности и сложный нелинейный характер связей внутри системы, синтезирована прогнозирующая ИНС на динамических нейронах. Подобная нейросеть позволяет строить прогноз выходных данных на интервале с заданными входными переменными, а также на несколько шагов вперед и позволяет достигнуть достаточно высокой степени точности прогноза в условиях нелинейности и текущей неопределенности входной последовательности.



а



б

Рис. 13. Результаты прогнозирования с применением нейросети на динамических нейронах: а – сплошная линия – желаемый сигнал, пунктирная линия – прогноз; б – значение ошибки NRMSE в процессе обучения нейросети

Выводы

Проведенное моделирование доказало работоспособность предложенных линейных методов прогнозирования для решения задачи прогнозирования многомерных временных рядов.

При моделировании многомерного ряда на основе ИНС с динамическими нейронами и построении прогноза на несколько шагов вперед показано, что при решении более сложной задачи, достигается более высокая точность по сравнению с линейными методами.

При моделировании методов прогнозирования на основе ИНС на нейронах-фильтрах установлено, что качество прогноза практически совпадает с результатами прогнозирования на основе сети на динамических нейронах, однако число параметров сети в данном случае становится значительно меньше.

Решена практическая задача построения прогнозирующей модели системы охранной сигнализации. Синтезирована прогнозирующая ИНС.

Список литературы

1. *Applications and Innovations in Intelligent Systems XV: Proceedings of AI-2007, the Twenty-seventh SGAI International Conference on Innovative Techniques and Applications of Artificial Intelligence*, Springer, 2008. – 350 p.
2. *Knowledge-based intelligent information and engineering systems: 9th international conference, KES 2005, Melbourne, Australia, September 14 - 16, 2005*, Springer. – 1371.
3. Mandic D.P. *Recurrent Neural Networks for Prediction: Learning Algorithms, Architectures and Stability* / D.P. Mandic, J.A. Chambers. – John Wiley, 2001. – 285 p.
4. Уидроу Б. *Адаптивная обработка сигналов* / Б. Уидроу, С. Стирнз. – М.: Радио и связь, 1989. – 440 с.
5. Бодянский Е.В. *Искусственные нейронные сети: архитектуры, обучение, применения: моногр.* / Е.В. Бодянский, О.Г. Руденко. – Х.: ТЕЛТЕХ, 2004. – 372 с.

6. Бодянский Е.В. *Прогнозирующая адаптивная нейронная сеть с динамическими нейронами-фильтрами* / Е.В. Бодянский, С.В. Попов, Т.Е. Чепенко // *Радиоэлектроника и информатика*. – 2003. – №2 (23). – С. 48-51.

7. Льюнг Л. *Идентификация систем. Теория для пользователя* / Л. Льюнг. – М.: Наука, 1991. – 432 с.

8. Демиденко Е.З. *Оптимизация и регрессия* / Е.З. Демиденко. – М.: Наука, 1989. – 296 с.

9. Уоссермен Ф. *Нейрокомпьютерная техника: теория и практика* / Ф. Уоссермен. – М.: Мир, 1992. – 240 с.

10. Gurney K. *An Introduction to Neural Network* / K. Gurney. – London: UCL Press. – 2003. – 234 p.

11. Kaczmarz S. *Approximate solution of systems of linear equations* / S. Kaczmarz // *Int. J. Control*. – 1993. – №53. – P. 1269-1271.

12. Bodyanskiy Ye. *An adaptive learning algorithm for a neuro-fuzzy network* / Ye. Bodyanskiy, V. Kolodyazhnyi, A. Stephan / Ye. Bodyanskiy, V. Kolodyazhnyi, A. Stephan // *Computational Intelligence. Theory and Applications*. – Berlin – Heidelberg – New York: Springer, 2001. – P. 68-75.

13. Peterka V.A. *A square-root filter for real time multivariate regression* / V.A. Peterka // *ZKI-Informationen. Vortage der 2. Arbeitstagung "Algorithmisierte Prozessanalyse"*. – Berlin, 1974. – Band 1. – S. 59-77.

14. Cybenko G. *Approximation by superposition of a sigmoidal function* / G. Cybenko // *Math. Contr. Sign. Syst.* – 1989. – №2. – P. 303-314.

15. Wan E. *Temporal backpropagation for FIR neural networks* / E. Wan // *Int. Joint Conf. on Neural Networks*. – 1990. – V. 1. – P. 575-580.

16. Back A.D. *FIR and IIR synapses, a new neural network architecture for time series modeling* / A.D. Back, A.C. Tsoi // *Neural Computation*. – 1991. – № 3. – P. 375-385.

Поступила в редколлегию 22.05.2009

Рецензент: д-р техн. наук, проф. Е.В. Бодянский, Харьковский национальный университет радиоэлектроники, Харьков.

ПРОГНОЗУВАННЯ НЕСТАЦІОНАРНОГО БАГАТОВИМІРНОГО ТИМЧАСОВОГО РЯДУ НА ОСНОВІ СПЕЦІАЛІЗОВАНОЇ НЕЙРОННОЇ МЕРЕЖІ

С.В. Попов, Т.Є. Чепенко

Стаття присвячена розробці спеціалізованої штучної нейронної мережі, призначеної для прогнозування багатовимірних рядів показників, що описують поведінку складних багатозв'язкових систем і методів навчання цієї мережі. Розглянутий приклад моделювання процесу однокрокового прогнозування багатовимірною мережею на основі штучної нейронної мережі з динамічними нейронами і на основі штучної нейронної мережі на нейронах-фільтрах. Вирішено завдання побудови прогнозувальної моделі системи охоронної сигналізації, з урахуванням нестационарної прогнозованої послідовності. Синтезована прогнозувальною штучною нейронною мережею на динамічних нейронах.

Ключові слова: спеціалізовані штучні нейронні мережі, часовий ряд, багатовимірні стохастичні процеси, динамічні нейрони-фільтри, кінцева і нескінченна імпульсна характеристика.

MULTIVARIATE NONSTATIONARY TIME SERIES PREDICTION ON THE BASE OF SPECIAL ARTIFICIAL NEURAL NETWORKS

S.V. Popov, T.E. Chepenko

The article is devoted development of the specialized artificial neuron network, intended for prognostication of multidimensional rows of indexes which describe the conduct of the difficult multiconnected systems and methods of studies of this network. The example of design of process of one-step prognostication of multidimensional row is considered on the basis of artificial neuron network with dynamic neurons and on the basis of artificial neuron network on neurons-filters. The task of construction forecasting the model of the system of the protective signaling is decided, taking into account the non-stationary forecast sequence. A forecasting artificial neuron network is synthesized on dynamic neurons.

Keywords: artificial neuron networks, sentinel row, multidimensional stochastic processes, dynamic neurons-filters, are specialized, eventual and endless impulsive descriptions.