

Литература

1. *Кривошеев М. И., Кустарев А. К.*, Цветовые измерения // М.: Энергоатомиздат, 1990.
2. *Соболева Н. А., Меламид А. Е.*, Фотоэлектронные приборы // М.: Высшая школа, 1974.
3. *Budde W., Dodd C. X.*, Measurement of relative spectral sensitivity distributions of photoelectric receivers // Applied Optics, 1971.

АППРОКСИМАЦИЯ СТОХАСТИЧЕСКИХ ПРОЦЕССОВ НЕЙРОННОЙ СЕТЬЮ

А. М. Поплетеев

Необходимость аппроксимации функциональных зависимостей, заданных множеством экспериментальных данных, достаточно часто возникает при исследовании и оптимизации сложных радиофизических систем, причем в общем случае процессы в таких системах носят стохастический характер.

Нейронные сети (НС) могут выступать в качестве универсальных аппроксиматоров произвольных детерминированных функций многих переменных [1–2]. Являясь универсальными аппроксиматорами, НС позволяют обеспечить практически неограниченную точность моделирования различных детерминированных процессов и систем. Установлено, что некоторые виды непрерывных стохастических процессов (например, диффузионный процесс) также могут быть аппроксимированы нейронными сетями. Такой подход основан на каноническом разложении случайного процесса по системе базисных функций [3].

В настоящей работе рассматривается возможность аппроксимации стохастических процессов типа случайного телеграфного сигнала (рис. 1) с помощью двух различных НС: многослойного персептрона (МСП) и машины Больцмана (МБ) [4]. Обычно для описания таких процессов применяют аппарат марковских процессов [5]. Сложность такого описания объясняется тем, что матрица вероятностей переходов, определяющих цепь Маркова, обычно неизвестна и должна быть определена из эксперимента. Преимущество НС состоит в том, что указанная задача может быть решена с помощью стандартных алгоритмов обучения НС.




Рис. 1. Пример стохастического процесса

Алгоритм аппроксимации с помощью многослойного персептрона (детерминированной НС) заключается в следующем (рис. 2).

1. Аппроксимируемый процесс квантуется по времени и дискретизируется по N уровням.
2. Строится НС, на ее входы подается предыстория (от 3 до нескольких сотен отсчетов), с выхода снимается следующее значение.
3. Производится обучение НС на отрезке моделируемого ряда.
4. Осуществляется собственно моделирование. На входы сети подается некоторый начальный набор значений. С выхода снимается аппроксимированное значение.
5. Выходное значение сети включается в предысторию, т.е. подается на один из входов НС. Затем вычисляется выход сети с учетом измененной предыстории и рассмотренная процедура повторяется.

В данной работе для моделирования применялась трехслойная НС с пятью входами. Сигнал дискретизировался на восемь уровней в интервале $[-1; 1]$. Обучение сети производилось методом обратного распространения ошибки [4].

Моделирование проводилось несколько раз, т.к. в зависимости от начальных весов связей НС результаты обучения оказывались различными. Сигнал, смоделированный МСП, приведен на рис. 3, а.

Обучение машины Больцмана требует значительных вычислительных и временных ресурсов и является отдельной непростой задачей. Поэтому в данной работе приведен только пример, показывающий принципиальную возможность использования МБ для моделирования стохастических сигналов.

Для моделирования сигнала с помощью МБ использована схема, аналогичная приведенной выше для персептрона. Созданная машина Больцмана имела пять входных нейронов для предыстории, один выходной и пять скрытых нейронов. Моделировался двухуровневый сигнал со значениями 1 и 0. Один из сигналов, сгенерированных сетью, изображен на рис. 3, б.

Таким образом, обычный многослойный персептрон малоприспособен для моделирования стохастических

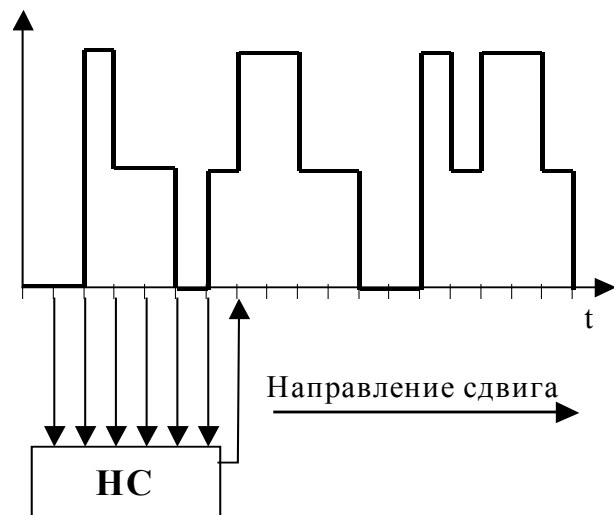


Рис. 2. Схема моделирования сигнала с помощью НС

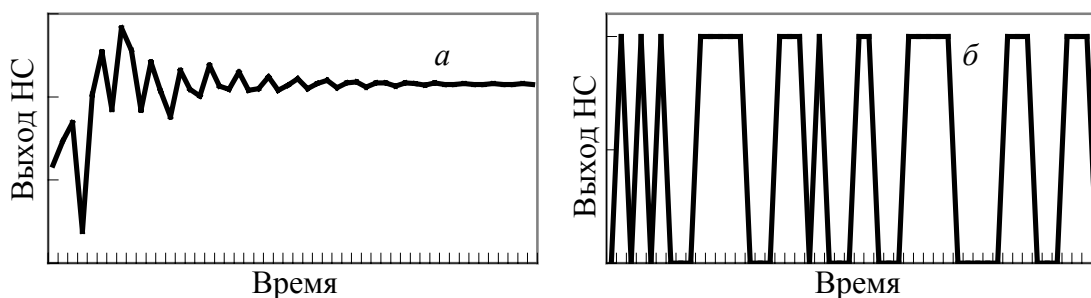


Рис. 3. Результаты аппроксимации:
а) многослойный перцептрон; б) машина Больцмана

ческих сигналов, т.к. свойство обобщения обученной НС отрицательно сказывается на результатах аппроксимации, не позволяя отслеживать динамику случайного процесса. Использование стохастических НС в рассматриваемом случае представляется более перспективным. К сожалению, их обучение требует больших временных и вычислительных ресурсов. Тем не менее, эти затраты оправданы, если конфигурация и параметры НС сохраняются и их можно многократно использовать при моделировании сигналов.

Работа выполнена при финансовой поддержке Белорусского государственного университета (грант 2003-533/18).

Литература

1. Cybenko G. Approximations by superpositions of a sigmoidal function // Math Contr Signals Syst, 1989, Vol. 2, pp. 304–314.
2. Hornik K., Stinchcombe M., White H. Multilayer feedforward networks are universal approximators // Neural Networks, 1989, Vol. 2, pp. 359–366.
3. Belli M. R., Conti M., Crippa P., Turchetti C. Artificial Neural Networks as Approximators of Stochastic processes // Neural Networks (1999) 12: 647–658.
4. Лутковский В. М. Нейронные сети: Конспект лекций. Мн. БГУ. 2003. 100 с.
5. Кемени Д., Снелл Д. Конечные цепи Маркова. М.: Наука. 1970.

ПРИМЕНЕНИЕ МНОГОКАНАЛЬНОГО СПЕКТРОМЕТРА SL-40 ДЛЯ КОНТРОЛЯ И УПРАВЛЕНИЯ ПРОЦЕССОМ МАГНЕТРОННОГО НАНЕСЕНИЯ TiO_2

С. Л. Прокопьев, В. Н. Кулешов

Магнетронные технологии нашли широкое применение для модификации свойств поверхностей твердых тел, в частности, для нанесения пленочных покрытий различного назначения. Однако без систем динамического управления ходом магнетронного нанесения пленок не удастся достичь воспроизводимости свойств покрытий и высоких скоростей нанесения [1].