
КОМПЬЮТЕРНОЕ МОДЕЛИРОВАНИЕ

УДК 303.732.4

НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ СИСТЕМ УПРАВЛЕНИЯ

В.И. Капалин¹⁾
И.В. Витохин¹⁾
Нгуен Дун Чинь²⁾
Нгуен Нгок Хуэ³⁾

*¹⁾ Московский институт
электроники и математики
(технический университет)*

*²⁾ Вьетнамский университет
транспорта*

*³⁾ Вьетнамский морской
университет*

Рассматриваются методы обучения нейросетевых моделей для линейных и нелинейных систем управления с помощью расширения Neural Network Toolbox пакета MATLAB. Настроенные модели используются для построения нейросетевых регуляторов типа NARMA-L2.

Ключевые слова: непараметрическая идентификация, нелинейные модели, нейронная сеть, скрытые нейроны, алгоритм обратного распространения ошибки, нейросетевой регулятор.

Введение

Одной из основных проблем, возникающих при управлении техническими объектами, является проблема идентификации, т.е. проблема построения математической модели управляемого объекта по экспериментальным данным. Традиционно методы идентификации разделяют на две большие группы – непараметрические и параметрические. К первым относят методы, применимые когда информация о структуре модели объекта отсутствует, т.е. когда объект представляет собой «черный ящик». В этом случае отыскиваются некоторые функциональные характеристики модели, такие как импульсная переходная функция или частотные характеристики для линейных систем. Для нелинейных систем это могут быть ядра полиномов Вольтерра или полиномов Винера или их изображения по Фурье [1]. В тех случаях, когда имеется априорная информация об уравнении модели, заданной с точностью до неизвестных параметров, используются методы параметрической идентификации. Здесь проблема сводится к проблеме отыскания неизвестных коэффициентов передаточной функции системы или коэффициентов уравнения в пространстве состояний [2]. Следует отметить, что если непараметрические методы, как например, измерение частотных характеристик, осуществляется для целей управления объектами, неизбежно возникает еще один этап – параметризация модели [3].

Альтернативным путем решения задачи непараметрической идентификации, не требующим параметризации модели для целей управления является нейросетевой

подход. Его практическое применение стало возможным после включения в фактический университетский стандарт MATLAB расширения Neural Network Toolbox [4].

В данной работе рассматриваются результаты обучения в этом расширении моделей линейных и нелинейных систем управления и результаты построения для них нейросетевых регуляторов.

Нейросетевая модель линейной системы управления

В качестве модели линейной системы использовалась модель морского дизеля Foden FD7 для средних скоростей, задаваемая передаточной функцией.

$$W(p) = \frac{-0.36p + 19.06}{s^2 + 15.58s + 13.04} \quad (1)$$

Выбранная архитектура нейронной сети задавала сеть прямого распространения со скрытыми нейронами. Обучение осуществлялось с помощью алгоритма обратного распространения ошибки. Моделирование вход-выходных свойств дизеля по передаточной функции (1) осуществлялось в расширении Simulink, с помощью кнопки Random Numbers.

Кривая, характеризующая изменение ошибки в процессе обучения сети, показана на рис. 1.




Рис. 1

Обучение закончилось через 300 эпох. Модель задавалась сетью прямого распространения со скрытыми нейронами.

Модели нелинейных систем

В качестве нелинейных моделей для нейросетевой непараметрической идентификации использовались три вида моделей:

- Модель Гаммерштейна

$$y(t) = \int_0^t k(\tau) \sum_{i=1}^M a_i u^i(t-\tau) d\tau \quad (2)$$

- Модель Винера

$$y(t) = \sum_{i=1}^M a_i \left(\int_0^t k(\tau) u(t-\tau) d\tau \right)^i \quad (3)$$

- Модель Винера-Гаммерштейна

$$y(t) = \int_0^t k(\tau) \sum_{i=1}^M a_i x^i(t-\tau) d\tau \quad (4)$$

где

$$x(t) = \int_{t_0}^t h(\tau) u(t-\tau) d\tau$$

Эксперименты в Neural Network Toolbox показали, что обучение для нелинейных моделей значительно сложнее, чем обучение для линейных моделей. Для дости-

жения приемлемой точности было необходимо ввести следующие модификации в процессе обучения. Во-первых, число нейронов скрытого слоя было увеличено до 32 для обеспечения возможности моделирования сложной динамики нелинейных объектов. Во-вторых, была увеличена длина обучающей последовательности до 20000 для обеспечения возможности адекватной реакции на различные входные сигналы. В-третьих, были введены ограничения на значения входного сигнала, выбираемого из интервала $[-1;1]$. Указанные видоизменения позволили провести обучение нейронных сетей для всех трех типов нелинейных систем. На рис. 2 приведена схема Simulink-модели для нелинейной модели Гаммерштейна.




Рис. 2

Кривая ошибки показана на рис. 3. Обучение закончилось через 300 эпох.




Рис.3

На рис. 4-5 показаны аналогичные результаты для модели Винера, а на рис. 6-7 – для модели Винера-Гаммерштейна.




Рис. 4




Рис. 5




Рис. 6




Рис. 7

Верификация нейронных сетей

На последнем этапе непараметрической идентификации с помощью нейронных сетей проводилась их верификация с полигармоническими сигналами и сигналами типа белый шум с помощью соответствующих кнопок в Simulink (рис. 8).




Рис. 8

Результаты верификации для нейросетевой модели Винера-Гаммерштейна показаны на рис. 9 и 10.




Рис. 9

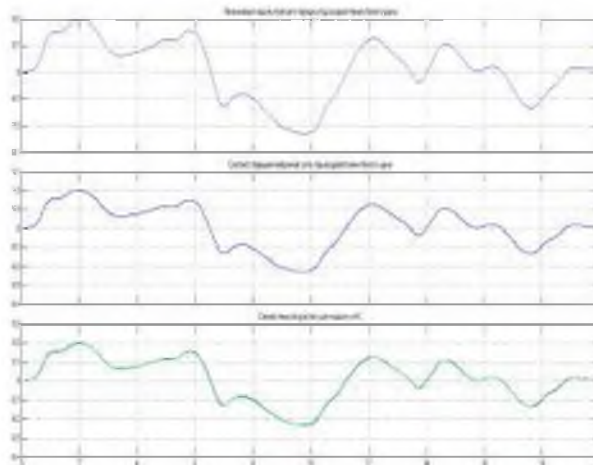


Рис. 10

Из этих графиков и аналогичных графиков, полученных для всех других рассмотренных моделей можно сделать непосредственное заключение об адекватности нейросетевых моделей для линейных и нелинейных объектов управления.

Синтез нейросетевого регулятора

Заключительный этап математического проектирования системы управления – это этап синтеза регулятора. В рассматриваемом случае использовался регулятор NARMA-L2 [4]

$$u(k + 1) = \frac{y_r(k + d) - f[y(k), y(k - 1), \dots, y(k - n + 1), u(k - 1), \dots, u(k - m + 1)]}{g[y(k), y(k - 1), \dots, y(k - n + 1), u(k - 1), \dots, u(k - m + 1)]}, \quad (5)$$

Синтез проводился для модели морского дизеля. Соответствующие схемы моделирования приведены на рис 11. Аналогичные результаты были получены и для нелинейной модели Винера.

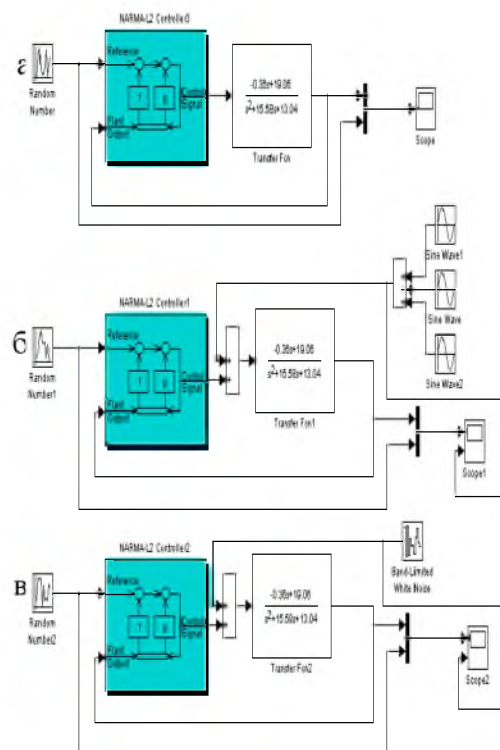


Рис. 11



Это позволяет сделать заключение о работоспособности нейросетевого подхода для синтеза регуляторов, как в линейном, так и в нелинейном случае.

Заключение

Результаты, полученные с помощью расширения Neural Network Toolbox, позволяют сделать заключения об адекватности решения задачи непараметрической идентификации с помощью нейронных сетей, как в линейном, так и в нелинейном случае. Однако для нелинейных систем это гораздо более сложная и длительная по времени проблема. Она требует увеличения числа нейронов скрытого слоя, увеличения длины обучающей последовательности и введения ограничений на ее значения.

Нейросетевые регуляторы NARMA-L2, построенные для линейной модели морского дизеля и элементарной модели Винера, в результате процесса верификации показали приемлемость полученных результатов.

Литература

1. Пупков К.А., Капалин В.И., Ющенко А.С. Функциональные ряды в теории нелинейных систем. М.: Наука, 1976. – 448 с.: ил.
2. Капалин В.И. Метод пространства состояний в теории управления. М.: МИЭМ, 2000. – 98 с.
3. Капалин В.И. Прокопов Б.И. Методы идентификации. М.: МИЭМ, 1989. – 89 с.
4. Дьяконов В.П., Круглов В.В. MATLAB 6.5 SP1/7/7 SP 1/7 SP 2 Simulink 5/6. Инструменты искусственного интеллекта и биоинформатики. М.: СОЛОН-ПРЕСС, 2006. – 456 с.:ил.

NEURAL NETWORK SIMULATION OF CONTROL SYSTEMS

V.I. Kapalin¹⁾

I.V. Vitohin

Nguyen Duy Chin²⁾

Nguyen Ngoc Hue³⁾

*¹⁾Moscow State Institute
of Electronics and Mathematics
(Technical University)*

e-mail: v_kapalin@mail.ru

*²⁾Ho Chi Minh City University
of Transports*

e-mail: duytrinh1981@gmail.com

³⁾Vietnam Maritime University

Methods of training of neural set models for the linear and nonlinear control systems in Neural Network Toolbox of MATLAB are discussed. Those models are used for the building of neural governors of the NARMA-L2 type.

Key words: non-parametric identification, nonlinear models, neural network, hidden layer neuron, back propagation error algorithm, neural governor.