

Сравнительный анализ нейрорегуляторов пакета прикладных программ Neural Network Toolbox

Н. А. Беззубов, email: nikobezzubov@gmail.com

С. В. Феофилов, email: svfeofilov@mail.ru

ФГБОУ ВО «Тюльский государственный университет»

***Аннотация.** В работе рассматриваются нейросетевые регуляторы, реализованные в пакете MATLAB Simulink Neural Network Toolbox в виде отдельных блоков. Проводится сравнительный анализ представленных нейрорегуляторов в части характеристик качества управления двигателем постоянного тока.*

***Ключевые слова:** нейроуправление, нейросетевые регуляторы, регулятор на основе эталонной модели, регулятор NARMA L2, регулятор с предсказанием.*

Введение

В практике проектирования систем управления динамическими процессами все большее применение находят нейронные сети. Это связано с одной стороны со все возрастающими требованиями к характеристикам систем управления и усложняющимися объектами, и процессами, которыми необходимо управлять, а с другой с интенсивным развитием специализированной вычислительной техники, например, нейропроцессоров. Универсальные возможности аппроксимации с помощью многослойного персептрона делают их полезным инструментом для решения задач идентификации, проектирования и моделирования нелинейных регуляторов [1].

Ниже представлено краткое описание архитектур нейросетевых регуляторов, реализованных в пакете прикладных программ Neural Network Toolbox MATLAB Simulink.

Далее проводится сравнительный анализ влияний каждой нейросетевой архитектуры регулятора на характеристики качества переходного процесса и точности системы с объектом управления в виде двигателя постоянного тока (ДПТ).

1. Регулятор на основе эталонной модели

При управлении на основе эталонной модели регулятор – это нейронная сеть, которая обучена управлять процессом так, чтобы он отслеживал поведение эталонного процесса. При этом модель

управляемого процесса активно используется при настройке параметров самого регулятора.

Архитектура регулятора с эталонной моделью требует обучения нейронной сети управляемого процесса и нейронной сети регулятора. При этом обучение регулятора оказывается достаточно сложным, поскольку обучение основано на динамическом варианте метода обратного распространения ошибки, так как нейронная сеть использует линии задержки. Достоинством регуляторов на основе эталонной модели является то, что они применимы к различным классам управляемых процессов [2].

Структурная схема, поясняющая принцип построения системы управления с эталонной моделью, показана на рис. 1.

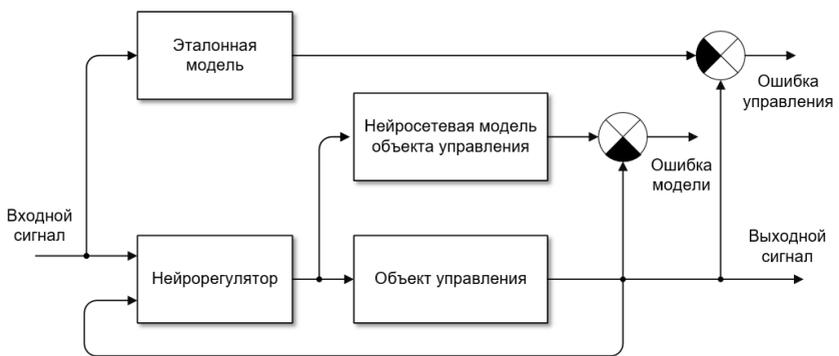


Рис. 1. Структурная схема управления с эталонной моделью

2. Регулятор NARMA-L2

При управлении на основе модели авторегрессии со скользящим средним регулятор представляет собой достаточно простую реконструкцию модели управляемого процесса.

Данный регулятор представляет собой модифицированную нейросетевую модель управляемого процесса, полученную на этапе автономной идентификации. Из представленных архитектур этот регулятор требует наименьшего объема вычислений. Вычисления в реальном времени связаны только с реализацией нейронной сети. Недостаток состоит в том, что модель процесса должна быть задана в канонической форме пространства состояния, которой соответствует сопровождающая матрица, что может приводить к вычислительным погрешностям [3].

Общая структурная схема системы с регулятором NARMA-L2 показана на рис. **Ошибка! Источник ссылки не найден.**

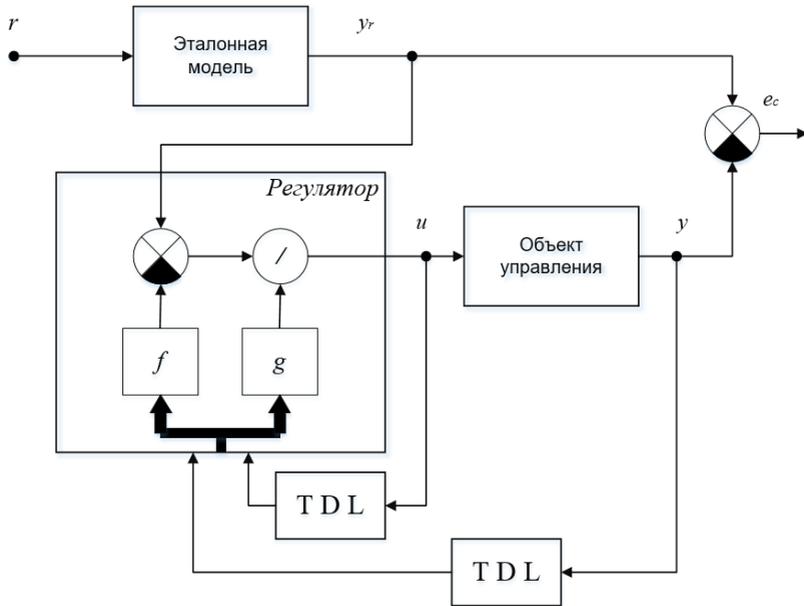


Рис. 2. Структурная схема управления с NARMA-L2

3. Регулятор с предсказанием

При управлении с предсказанием модель управляемого процесса используется для того, чтобы предсказать его будущее поведение, а алгоритм оптимизации применяется для расчета такого управления, которое минимизирует разность между желаемыми и действительными изменениями выхода модели. Управление с предсказанием использует принцип удаляющегося горизонта, когда нейросетевая модель управляемого процесса предсказывает реакцию объекта управления на определенном интервале времени в будущем [4].

Этот регулятор использует модель управляемого процесса в виде нейронной сети, для того чтобы предсказать будущие реакции процесса на случайные сигналы управления. Алгоритм оптимизации вычисляет управляющие сигналы, которые минимизируют разность между желаемыми и действительными изменениями сигнала на выходе модели и таким образом оптимизируют управляемый процесс. Построение модели управляемого процесса выполняется автономно с

использованием нейронной сети, которая обучается в групповом режиме с использованием одного из алгоритмов обучения. Контроллер, реализующий такой регулятор, требует значительного объема вычислений, поскольку для расчета оптимального закона управления оптимизация выполняется на каждом такте управления.

Схема подсистемы идентификации показана на рис. **Ошибка!**
Источник ссылки не найден..

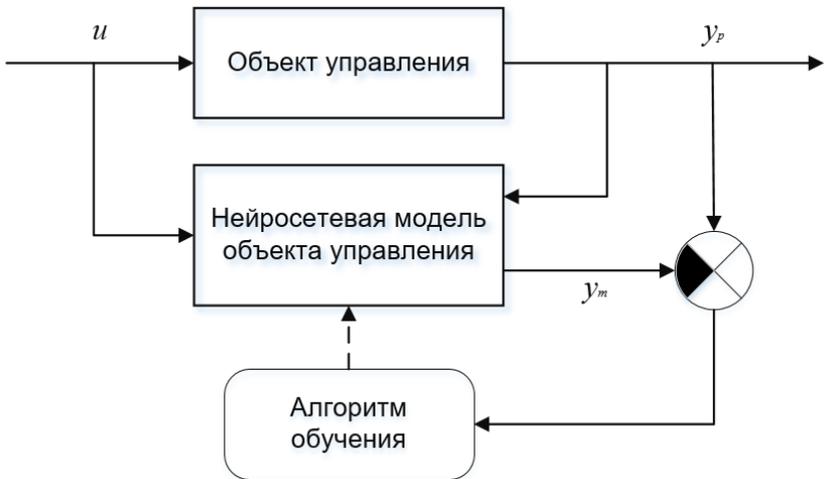


Рис. 3. Структурная схема управления с предсказанием

4. Сравнение результатов моделирования

В качестве объекта управления примем двигатель постоянного тока ЭДМ-20, технические характеристики которого представлены в табл. 1.

Таблица 1

Технические характеристики ЭДМ-20

Номинальное напряжение питания	27 В
Момент инерции якоря	0,0003 кг·м ²
Сопротивление обмотки якоря	0,15 Ом
Индуктивность обмотки якоря	0,15 мГн
Коэффициент противо-ЭДС	0,078 В·с/рад
Коэффициент момента двигателя	0,078 Н·м/А

Simulink-модель ДПТ представлена на рис. 4.

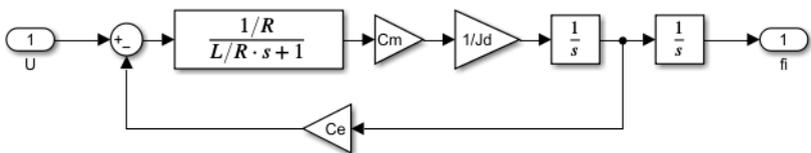


Рис. 4. Simulink-модель ДПТ

На рис. 5 представлена simulink-модель системы управления ДПТ с помощью рассматриваемых нейрорегуляторов.

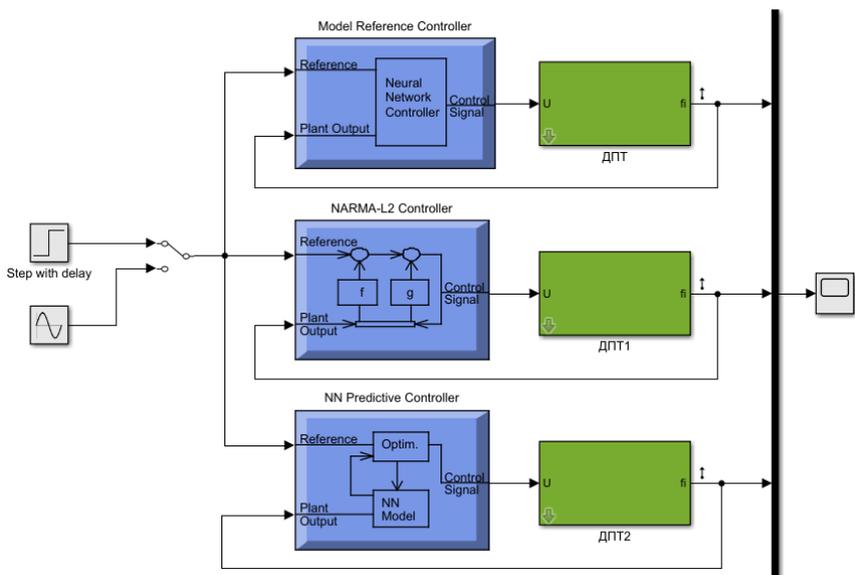


Рис. 5. Simulink-модель системы управления ДПТ с помощью рассматриваемых нейрорегуляторов

В качестве эталонной модели управления для обучения нейроконтроллера примем модель управления ДПТ с помощью ПИД-регулятора с параметрами, предварительно рассчитанными по методу Козна-Куна [5].

В табл. 2 приведены параметры для построения нейросетевой модели управляемого процесса.

Параметры идентификации управляемого процесса

Параметры архитектуры	
Количество используемых нейронов	9
Шаг дискретности	0,05
Число линий задержки входного слоя	3
Число линий задержки выходного слоя	2
Параметры обучающей последовательности	
Длина обучающей выборки	100
Максимальное значение входного сигнала	1
Минимальное значение входного сигнала	-1
Максимальный интервал идентификации	2
Минимальный интервал идентификации	1
Параметры обучающей последовательности	
Количество циклов обучения	100

Результат обработки ступенчатого сигнала показан на рис. 6.

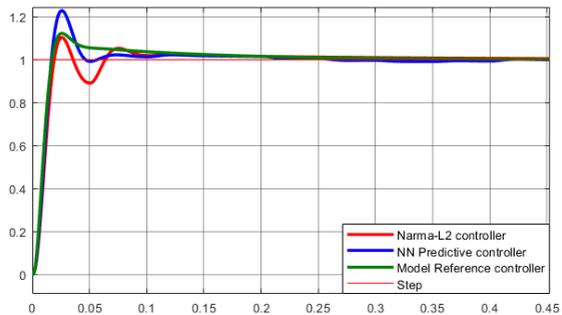


Рис. 6. Результат обработки ступенчатого сигнала

Результат обработки синусоидального сигнала показан на рис. 7.

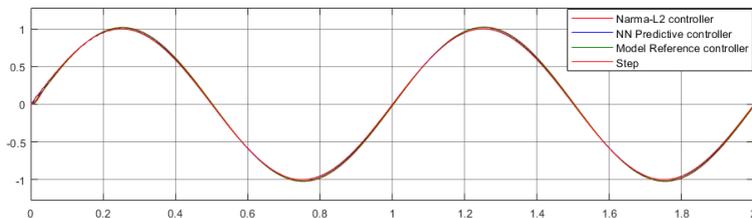


Рис. 7. Результат обработки синусоидального сигнала

В табл. 3 приведены характеристики качества системы управления с рассматриваемыми архитектурами нейрорегуляторов.

Таблица 3

Оцениваемые характеристики качества системы

Характеристика	NARMA-L2	Model Reference	Predictive
Время регулирования (с)	0,08	0,06	0,04
Перерегулирование (%)	10	12,2	22,8
Ошибка (мрад/с)	0,03	0,022	0,007

Заключение

По результатам моделирования можно сделать следующие выводы. Наименьшее время регулирования получили при реализации обобщенного управления с предсказанием. Наименьшее значение перерегулирования получили с использованием нейрорегулятора NARMA-L2. При нейроуправлении с предсказанием показатель точности отработки сигнала наилучший.

Результат сравнения нейросетевых архитектур регуляторов по качественным характеристикам системы и точности отработки сигнала задатчика указывает в целом на эффективность управления двигателем постоянного тока с использованием нейрорегулятора на основе эталонной модели при определенных параметрах идентификации управляемого процесса.

Список литературы

1. Hagan M. T., Demuth H. B. Neural Networks for Control// Proceedings of the 1999 American Control Conference. San Diego: CA, 1999. P. 1642-1656.
2. Hagan M. T., De Jesus O., Schultz R. Training Recurrent Networks for Filtering and Control. Ch. 12. // Recurrent Neural Networks: Design and Applications, L. Medsker, L.C. Jain, Eds. CRC Press, 1999. P. 311-340.
3. Медведев, В. С. Нейронные сети. MATLAB 6: /Под общ. ред. В. Г. Потемкина. – М.: ДИАЛОГ-МИФИ, 2001. – 630 с. – (Пакеты прикладных программ; Кн. 4).
4. Soloway D., Haley P. J. Neural Generalized Predictive Control// Proceedings of the 1996 IEEE International Symposium on Intelligent Control. 1996. P. 277-281.
5. Standard PID Tuning Methods [Электронный ресурс]. Режим доступа: <http://maulana.lecture.ub.ac.id/files/2014/12/Method-Tuning-PID-standard.pdf>