

## СИНТЕЗ НЕЙРОКОНТРОЛЛЕРА С ПРЕДСКАЗАНИЕМ ДЛЯ ДВУХМАССОВОЙ ЭЛЕКТРОМЕХАНИЧЕСКОЙ СИСТЕМЫ

Кузнецов Б.И., д.т.н., проф., Василец Т.Е., к.т.н., доц., Варфоломеев А.А.  
Украинская инженерно-педагогическая академия  
Украина, 61003, Харьков, ул. Университетская, 16, УИПА, кафедра СУТПиО  
тел. (057) 733-79-59

*Виконано синтез нейроконтролера з передбаченням для рішення задачі управління системою наведення і стабілізації озброєння легкоброньованих машин. Наведено порядок синтезу нейроконтролера для заданого об'єкту управління; встановлено, які параметри нейроконтролера суттєво впливають на якість регулювання і визначені оптимальні значення параметрів. Виконано моделювання системи. Показано, що синтезований нейроконтролер забезпечує високі динамічні характеристики системи.*

*Выполнен синтез нейроконтроллера с предсказанием для решения задачи управления системой наведения и стабилизации вооружения легкобронированных машин. Приведен порядок синтеза нейроконтроллера для заданного объекта управления; установлено, какие параметры нейроконтроллера существенно влияют на качество регулирования и определены оптимальные значения параметров. Выполнено моделирование системы. Показано, что синтезированный нейроконтроллер обеспечивает высокие динамические характеристики разрабатываемой системы.*

### ПОСТАНОВКА ПРОБЛЕМЫ

Системы управления вооружением легкобронированных машин характеризуются нелинейными зависимостями, сложными для моделирования динамическими свойствами, наличием неконтролируемых шумов и помех, препятствующих реализации традиционных стратегий управления, поскольку, как современная (в частности теория адаптивного и оптимального управления), так и классическая теория управления в значительной степени базируются на идее линеаризации систем. Поэтому более эффективной является разработка систем управления на основе адаптивного подхода в сочетании с методами теории искусственных нейронных сетей.

### АНАЛИЗ ПОСЛЕДНИХ ДОСТИЖЕНИЙ И ПУБЛИКАЦИЙ

В последние годы нейронные сети широко используются для управления динамическими объектами. Можно сослаться, например, на редакционную статью [1], в которой её авторы определяют проблемы синтеза нейросетевых систем управления динамическими объектами. Эти проблемы касаются: синтеза структур нейросетевых систем управления; ограничений на скорость настройки параметров сети; модификации алгоритмов настройки, обеспечивающих малые траекторные ошибки при ограничениях на значения весовых коэффициентов синаптических связей нейронов; модификации управления, гарантирующего грубость в условиях неконтролируемых возмущений.

Подходы к решению перечисленных проблем отражены в литературе по применению нейросетей в задачах управления. В [2] была разработана процедура синтеза системы управления нелинейными объектами с применением RBF-сети и достаточно подробно рассмотрены вопросы синтеза ее архитектуры и алгоритма настройки. Проблемы же, связанные с качеством процессов и нечувствительностью системы к неизмеряемым возмущениям, не были решены. В ряде других работ в более позднее время (например, [3-5]), были предложены методы синтеза нейросетевых систем

управления сложными техническими объектами.

Проведенный анализ литературы показал, что существует большое количество подходов к проблеме синтеза систем управления нелинейными объектами при случайных сигналах, при этом универсального и идеального регулятора пока не существует.

**Цель статьи.** Целью работы является синтез нейроконтроллера с предсказанием NN Predictive Controller, реализованного в системе Matlab, для решения задачи управления системой наведения и стабилизации вооружения легкобронированных машин при движении машин по пересеченной местности.

### ИЗЛОЖЕНИЕ МАТЕРИАЛА ИССЛЕДОВАНИЯ, ПОЛУЧЕННЫХ НАУЧНЫХ РЕЗУЛЬТАТОВ

Синтез нейросетевой системы управления производился с помощью пакета прикладных программ Neural Network Toolbox системы MATLAB. Далее приводится краткая характеристика пакета и порядок синтеза нейроконтроллера, а так же результаты моделирования нейросетевой системы стабилизации вооружения легкобронированной машины.

В [6] описаны 3 нейроконтроллера: контроллер с предсказанием NN Predictive Controller; контроллер на основе модели авторегрессии со скользящим средним NARMA – L2 Controller; контроллер на основе эталонной модели Model Reference Controller.

Как показали исследования, для решения поставленной задачи наиболее эффективным является NN Predictive Controller. Регулятор использует модель нелинейного управляемого объекта в виде нейронной сети для того, чтобы предсказывать его будущее поведение. Кроме того, регулятор вычисляет сигнал управления, который оптимизирует поведение объекта на заданном интервале времени. Следовательно, проектирование нейроконтроллера состоит из двух этапов: этап идентификации управляемого объекта и этапа синтеза закона управления. На этапе идентификации разрабатывается модель управляемого объекта в виде нейронной сети, которая на этапе синтеза используется для синтеза регулятора.

При синтезе нейроконтроллера NN Prediction Controller используются файлы, размещенные в каталоге `toolbox/nnet/ncontrol` системы SIMULINK, которые можно разбить на три группы: функции одномерной оптимизации, модели SIMULINK, вспомогательные функции: `Sfunx2` – функция для вывода графиков; `Nncontrolutil` – поддержка, обеспечивающая возможность обращения к частным функциям из системы SIMULINK; `Nnident.m` – функция, используемая при идентификации объекта, находящаяся в каталоге `private` обеспечивает графический интерфейс пользователя (GUI), генерацию обучающей выборки, создание и тренировку сети.

Для обеспечения высоких динамических характеристик системы наведения и стабилизации вооружения легкобронированной машины разработана система

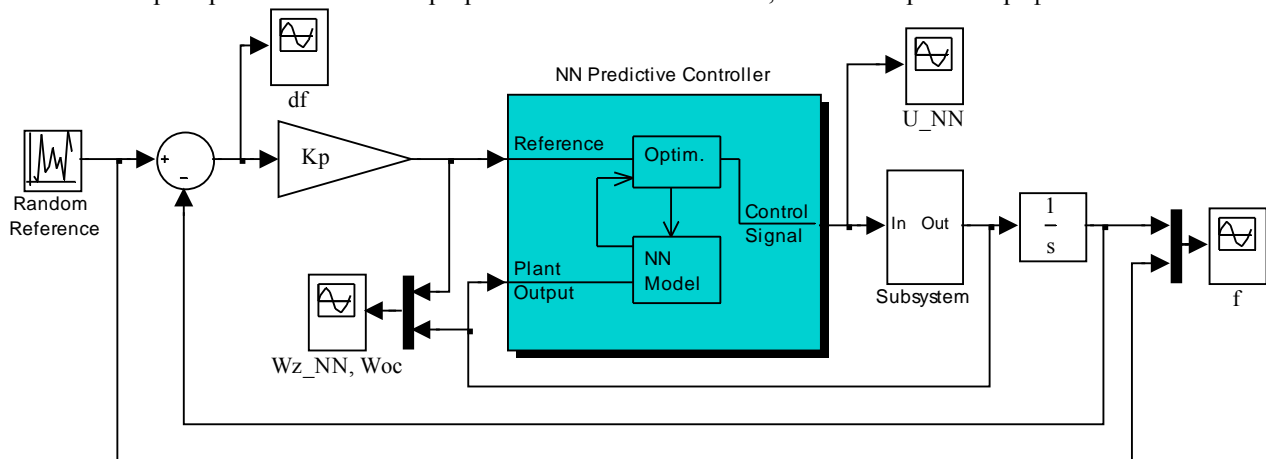


Рис. 1. Схема системы управления с нейроконтроллером NN Prediction Controller

Структурная схема нейроконтроллера NN Prediction Controller показана на рис. 2. Данная схема появляется в отдельном окне при выборе пункта меню `Look Under Mask` блока NN Prediction Controller.

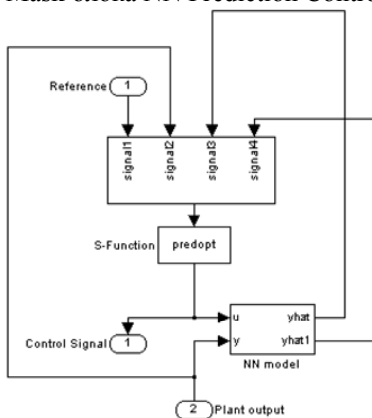


Рис. 2. Структурная схема нейроконтроллера

Процесс синтеза нейроконтроллера начинается путём активизации блока NN Prediction Controller. Появляется окно, показанное на рис. 3. Оно выполняет функции графического интерфейса пользователя.

Прежде чем установить параметры контроллера, необходимо выполнить идентификацию управляемого объекта, т.е. построить его нейросетевую модель, воспользовавшись специальной процедурой `Plant Identification`. Вид окна `Plant Identification` проведен на рис. 4.

тема подчинённого регулирования с нейронной компенсацией нелинейностей исполнительного устройства стабилизатора вооружения. Схема содержит два контура: контур скорости и контур положения. Анализ динамики исполнительного устройства стабилизатора вооружения показывает, что нелинейности можно компенсировать в контуре регулирования скорости. Регулятор положения может быть линейным.

На рис. 1 показана структурная схема нейросетевой системы стабилизации вооружения легкобронированной машины, разработанная в системе SIMULINK. Эта структура включает блок управляемого объекта и блок контроллера NN Prediction Controller, а также блоки генерации эталонного ступенчатого сигнала со случайной амплитудой `Random Reference`, блоки построения графиков.

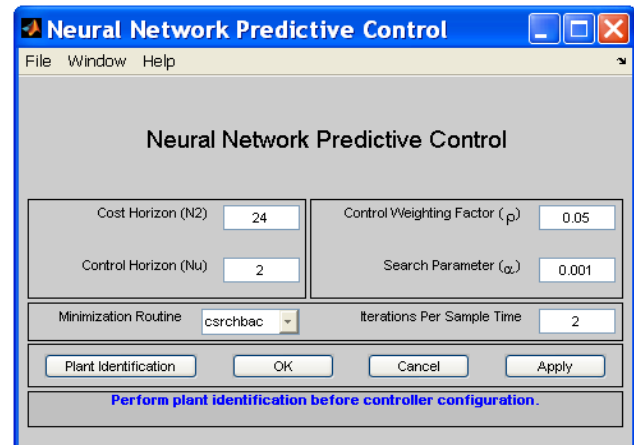


Рис. 3. Окно задания параметров контроллера

Процедура идентификации позволяет построить нейронную сеть, которая будет моделировать динамику управляемого объекта.

Процедура идентификации требует задания следующих параметров.

- Параметры архитектуры:

- `Size of Hidden Layer (N)` - размер скрытого слоя определяется количеством используемых нейронов;

- `Sampling Interval ( $\Delta t$ )` - такт дискретности в секундах определяет интервал между двумя последовательными моментами съема данных;

No. Delayed Plant Inputs ( $N_i$ ) - количество элементов запаздывания на входе модели;  
 No. Delayed Plant Outputs ( $N_j$ ) - количество элементов запаздывания на выходе модели;  
 Normalize Training Data. Окно контроля нормирования обучающих данных к диапазону [0 1].

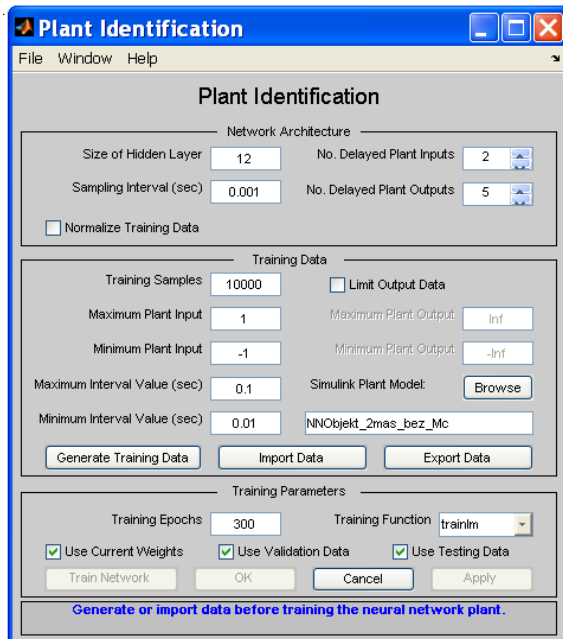


Рис. 4. Окно идентификации управляемой системы

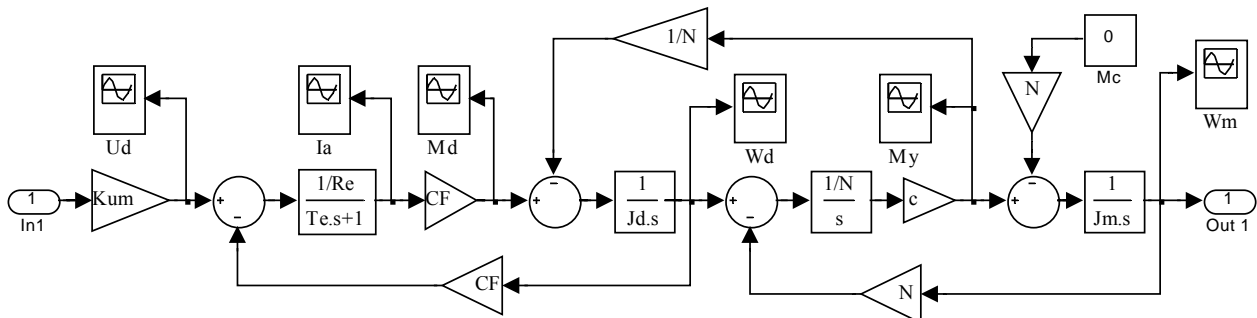


Рис. 5. Упрощённая схема модели исполнительного устройства стабилизатора вооружения

■ Параметры обучения:  
 Training Epochs - количество циклов обучения;  
 Training function - задание обучающей функции;  
 Use Current Weights - окно контроля, позволяющее подтвердить использование текущих весов нейронной сети;

Use Validation/Testing Training - выбор этих окон контроля означает, что по 25% данных из обучающей последовательности будет использовано для формирования контроля и текстового подмножеств.

Выбор процедуры Generate Training Data приведет к тому, что будет запущена программа генерации обучающей последовательности. Программа генерирует обучающие данные путем воздействия ряда случайных ступенчатых сигналов на модель SIMULINK управляемого объекта. Графики входного и выходного сигналов объекта управления выводится на экран (рис. 6).

■ Параметры обучающей последовательности:  
 Training samples ( $N_B$ ) - длина обучающей выборки (количество точек съема информации);  
 Maximum Plant Input ( $\varphi_{\max}$ ) - максимальное значение входного сигнала;  
 Minimum Plant Input ( $\varphi_{\min}$ ) - минимальное значение входного сигнала;  
 Maximum Interval Value (sec) ( $t_{\max}$ ) - максимальный интервал идентификации в секундах;  
 Minimum Interval Value (sec) ( $t_{\min}$ ) - минимальный интервал идентификации в секундах;  
 Limit Output Data. Окно контроля, позволяющее ограничить объем выходных данных, только при включенном окне будут доступны 2 следующих окна редактирования текста:

Maximum Plant Output. Максимальное значение выходного сигнала;

Minimum Plant Output. Минимальное значение выходного сигнала;

Simulink Plant Model - задание модели Simulink с указанием входных и выходных портов, используемых при построении нейросетевой модели управляемой системы.

С помощью кнопки Browser выбирается необходимая модель из числа доступных, например упрощённая схема модели исполнительного устройства стабилизатора вооружения, показанная на рис. 5.

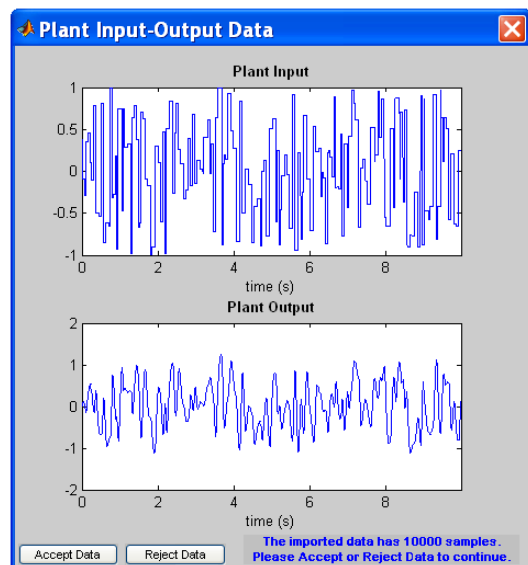


Рис. 6. Окно идентификации управляемой системы

По завершении генерации обучающей происходит создание сети с прямой передачей сигнала с помощью М-функции newff. Данная функция не только создаёт сеть с именем netn, но и инициализирует её веса и смещения и подготавливает нейронную сеть к обучению. Модель нейронной сети может быть построена в системе Simulink с помощью оператора gensim (netn) (рис. 7).




Рис. 7. Модели элементов сети с прямой передачей сигнала, реализованные в Simulink

Элементы нейронной, соответствуют следующим параметрам: размер скрытого слоя  $S = 12$ , количество элементов запаздывания на входе модели  $N_j = 2$  и количество элементов запаздывания на выходе модели  $N_j = 5$ . Каждый последующий элемент появляется в отдельном окне при активизации предыдущего двойным щелчком мыши.

Данная сеть является статической. Сеть использует 1 вектор входа с 6 элементами, имеет 2 слоя с 12 нейронами в первом (скрытом) слое и 1 нейроном во втором (выходном) слое. Используемые функции активации: гиперболического тангенса (tansig) - в первом слое, линейная (purelin) - во втором слое.

После создания сети начинается процесс её обучения. Векторы входа представляется как числовые массивы выборки в формате doubl, что соответствует

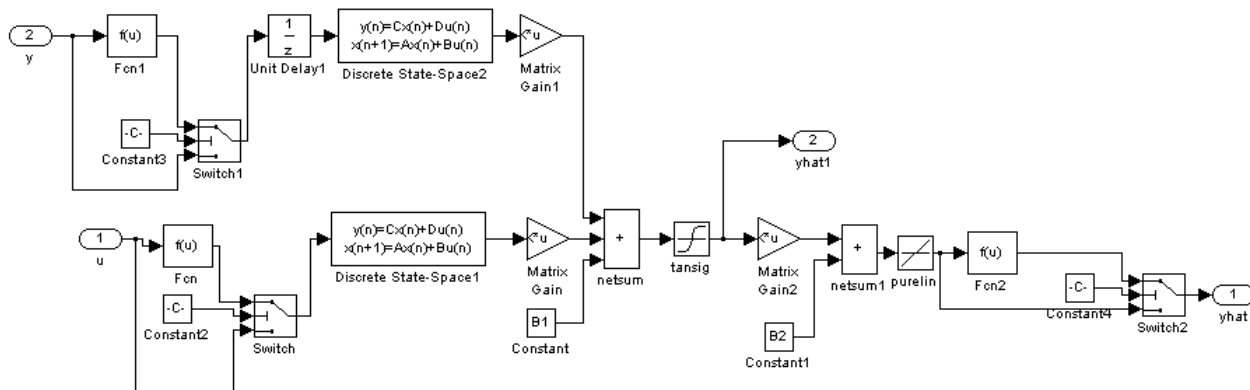


Рис. 9. Структурная схема нейросетевой модели объекта регулирования

групповому представлению данных. Обучение осуществляется с использованием функции trainlm, соответствующей алгоритму Левенберга-Марквардта. Динамика изменения ошибки обучения, а так же проверки на контрольном и текстовом множествах отражаются в соответствующих окнах.

После завершения обучения М-функция Nnidnet выполняет построение динамической сети netn2 с заданным числом задержек по входу и выходу модели, не изменяя при этом полученные значения весов и смещений нейронов слоёв. Схема модели динамической сети, показана на рис. 8. Данная схема построена в режиме Simulink из элементов, которые появляются в окнах в результате использования оператора gensim(netn2) и активизации элементов сети. Элементы матриц весов  $IW\{1,1\}$  и  $LW\{1,2\}$  динамической сети netn2, показанной на рис. 8 составлены из соответствующих элементов матрицы весов  $IW\{1,1\}$  статической сети netn, показанной на рис. 7.




Рис. 8. Модель динамической сети с элементами задержек, построенной в Simulink

В результате параметры нейросетевой модели управляемого объекта вводятся в блок NN Predictive Controller системы Simulink. В системе Simulink данная сеть представляется в виде структурной схемы, показанной на рис. 9.

Блоки Matrix Gain и Matrix Gain 1 соответствуют матрицам  $IW\{1,1\}$  и  $LW\{1,2\}$  соответственно. Блоки Constant (B1) Constant1 (B2) относятся к смещениям нейронов первого и второго слоёв. Элементы задержек моделируются с помощью блоков Discrete State Space 1 и Discrete State Space 2

$$y(n) = Cx(n) + Du(n),$$

$$x(n+1) = Ax(n) + Du(n).$$

Для рассматриваемого случая  $N_i = 2$  и  $N_j = 5$  численные значения матриц **A**, **B**, **C** и **D** указанных блоков следующие

Discrete State Space 1

$$A = \begin{bmatrix} 0 \\ 1 \end{bmatrix}, \quad B = \begin{bmatrix} 1 \\ 1 \end{bmatrix}, \quad C = \begin{bmatrix} 0 \\ 1 \end{bmatrix}, \quad D = \begin{bmatrix} 1 \\ 0 \end{bmatrix}.$$

Discrete State Space 2

$$A = \begin{bmatrix} 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}, \quad B = \begin{bmatrix} 1 \\ 0 \\ 0 \\ 0 \end{bmatrix}, \quad C = \begin{bmatrix} 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad D = \begin{bmatrix} 1 \\ 0 \\ 0 \\ 0 \end{bmatrix}.$$

В системе Simulink формируется так же схема ptest3sim2. Данная схема так же является нейросетевой моделью объекта управления, имеющей дополнительные выходы, и используется М-функцией predopt для предсказания процесса в будущем.

После завершения построения нейросетевой модели управляемого объекта происходит возврат к окну Neural Network Predictive Controller (рис. 3) и устанавливаются параметры оптимизации:

Const Horizon ( $N_2$ ) - верхний предел суммирования в показателе качества  $N_2$ , нижний предел  $N_1$  фиксирован и равен 1;

Control Horizon ( $N_u$ ) – верхний предел суммирования при оценке мощности управления;

Control Horizon ( $N_u$ ) – верхний предел суммирования при оценке мощности управления;

Control Weighting Factor ( $\rho$ ) - коэффициент веса для составляющей мощности управления;

Search parameter ( $\alpha$ ) - параметр одномерного поиска, задающий порог уменьшения показателя качества;

Minimization Routine - выбор процедуры одномерного поиска;

Iterations Per Sample Time - число итераций на 1 такт дискретности.

После установки параметров оптимизации они вводятся в блок NN Predictive controller системы Simulink.

При синтезе контроллера варьируются величины  $N_2$ ,  $N_u$  и  $\rho$  (величина  $N_1$  фиксирована и равна 1), а так же параметр одномерного поиска  $\alpha$ , задающий порог уменьшения показателя качества и число итераций на 1 такт дискретности  $\gamma$ . Задается так же процедура одномерного поиска.

Как показали исследования, величины  $N_u$ ,  $\rho$  и  $\alpha$  не значительно влияют на результаты синтеза и приняты:  $N_u = 2$ ,  $\rho = 0,05$ ,  $\alpha = 0,001$ . В качестве процедуры одномерного поиска принята csgchbas.

Значения  $N_2$  и  $\gamma$  оказывают существенное влияние на работу контроллера. При их увеличении точность возрастает, однако объем вычислений на каждом такте дискретности существенно увеличивается.

Для решаемой задачи оптимальные значения находятся в пределах  $N_2 = 23 \div 25$ ,  $\gamma = 2 \div 3$ .

При идентификации объекта управления наиболее важным вопросом является выбор количества нейронов скрытого слоя  $S$ . При малом количестве нейронов сеть не может выполнять поставленную задачу, а при большом наблюдается явление переобучения и возрастает объем вычислений.

Для рассматриваемой задачи оптимальные значения  $S = 11 \div 14$  при этом ошибка обучения, а так же ошибка на контрольном и тестовом множестве  $\varepsilon$  не превышает  $10^{-3} \div 10^{-4}$ .

Успех тренировки сети в значительной степени зависит от длины обучающей выборки  $N_B$  и такта дискретности  $\Delta t$ , определяющего интервал между двумя последовательными моментами съема данных. Оптимальными в решаемой задаче являются:  $N_B = 10000$ ,  $\Delta t = 0,001$  с. При увеличении  $\Delta t$  снижается точность вычисления и разность между ошибкой обучения и ошибкой, полученной на контрольном и тестовом множестве. Уменьшение  $\Delta t$  вызывает необходимость соответствующего увеличения  $N_B$  и, как следствие, значительно увеличивается время тренировки сети, при этом существенного снижения  $\varepsilon$  не наблюдается.

Для получения представительной выборки необходимо правильно задать максимальное и минимальное значения интервала идентификации, т.е. длительности скачков заданий. Величина их зависит от параметров объекта Plant. В рассматриваемой задаче максимальная длительность скачков заданий должна быть примерно равна времени регулирования контура скорости, минимальная – на порядок меньше. Тогда тренировочные данные будут содержать только фазы ускорений. В качестве оптимальных приняты:  $t_{\min} = 0,01$  с,  $t_{\max} = 0,1$  с.

Ограничение напряжения двигателя достигается путём задания соответствующих значений параметров обучающей последовательности Maximum Plant Input и Minimum Plant Input при выполнении процедуры идентификации объекта управления. Параметры устанавливались равными +1 и -1 соответственно.

При синтезе нейросетевой модели системы задается количество элементов запаздывания на входе  $N_i$  и выходе  $N_j$  модели. Наилучшие результаты получены при  $N_i = 2$ ,  $N_j = 4 \div 5$ .

Результат тренировки сети зависит от начального значения весов нейронной сети  $w_{ij}$  и количества циклов обучения  $N_{\text{ц}}$ . Для достижения глобального минимума процесс обучения необходимо повторять многократно при различных начальных значениях  $w_{ij}$  и величине  $N_{\text{ц}}$ . В рассматриваемой задаче для каждого варианта сети выбиралось несколько десятков начальных точек расчета. Количество циклов обучения, по истечении которых ошибка обучения переставала уменьшаться, составляло  $200 \div 300$ .

В качестве обучающей функции выбрана trainlm.

Оптимальные параметры нейроконтроллера следующие:  $N_2 = 24$ ,  $\gamma = 2$ ;  $S = 12$ ;  $N_i = 2$ ,  $N_j = 5$ .

Средняя ошибка обучения составляет  $6,17 \cdot 10^{-11}$ , а мгновенные ошибки на обучающем, тестовом и контрольном множествах не превышают  $1 \cdot 10^{-4}$ .

От высокочастотных и высококачественных систем регулирования требуется нечувствительность по отношению к возмущающему воздействию и изменению параметров. Как показали исследования, синтезированный нейроконтроллер без переобучения обеспечивает высокие динамические характеристики реальной нелинейной системы стабилизации при на-

личии возмущающих воздействий и с учётом помех измерения регулируемых координат.

На рис. 10 приведены графики переходных процессов переменных состояния синтезированной системы. Переходные процессы приведены для значений скачков задающего воздействия, находящихся в пределах  $\varphi_3 = -0,1 \div 0,1$  рад. Переходные процессы имеют высокие динамические характеристики. Отработка угла  $\varphi_3 = 0,05$  рад происходит за время  $t = 0,12$  с, перерегулирование составляет 1,03%.




Рис. 10. Графики переходных процессов переменных состояния системы:  
а) – отработки заданного угла  $\varphi$ ; б) – скорости механизма  $\omega_M$ ; в) – скорости двигателя  $\omega_D$

#### ВЫВОДЫ

В статье выполнен синтез нейроконтроллера с предсказанием NN Prediction Controller, для решения задачи управления системой наведения и стабилизации вооружения легкобронированных машин при движении машин по пересеченной местности. При решении задачи было выполнено следующее: рассмотрен принцип построения нейроконтроллера, реализованного в пакете прикладных программ Neural Network Toolbox системы MATLAB, приведен порядок синтеза нейроконтроллера для заданного объекта управления; путем перебора параметров нейроконтроллера в широких пределах, установлено, какие параметры существенно влияют на качество регулирования и определены оптимальные значения параметров. Использование нейросетевой модели объекта управления, обеспечивающей высокую степень идентификации и оптимальных значений параметров позволило синтезировать нейроконтроллер, обеспечивающие высокие динамические характеристики разрабатываемой системы.

#### ЛИТЕРАТУРА

- [1] Lewis F.L., Parisini T. Guest Editorial: Neural network feedback control with guaranteed stability // Int. J. of Control.- 1998.- Vol.70.- № 3.- P. 337-339.
- [2] Sunner R. M., Slotine J. E. Gaussian Networks for Direct Adaptive Control // IEEE Trans. Neural Networks.- 1992.- Vol. 3. № 6.- P. 837-863.
- [3] Омату С, Халид М, Юсоф Р. Нейроуправление и его приложения. - М.: ИПРЖРБ, 2000. – 272 с.
- [4] Клепиков В. Б. Палис Ф. Клепиков А. В. К созданию интеллектуального электропривода для управления машинами с нелинейным трением // Вестник НТУ "ХПИ". "Проблемы автоматизированного электропривода. Теория и практика", Харьков: НТУ "ХПИ".- 2001.- С. 415-417.
- [5] Бодянский Е.В., Руденко О.Г. Искусственные нейронные сети: архитектуры, обучение, применения. – Харьков: Телетех, 2004. - 264 с.
- [6] Медведев В.С., Потемкин В.Г. Нейронные сети. MATLAB 6 / Под общ. ред. к.т.н. В.Г. Потемкина. - М.: ДИАЛОГ-МИФИ, 2002. - 496 с.

Поступила 09.11.2007