УДК 681.513.7

А.Н. Чернодуб

Институт проблем математических машин и систем НАН Украины, г. Киев 03187, Украина, г. Киев, проспект академика Глушкова, 42

Обучение нейроэмуляторов с использованием псевдорегуляризации для метода нейроуправления с эталонной моделью

A.N. Chernodub

Institute of Mathematical Machines and Systems Problems of NAS of Ukraine, c. Kyiv 03187, Ukraine, Kyiv, Glushkova 42 ave.

Training of Neuroemulators with Use of Pseudoregularization for Model Reference Adaptive Neurocontrol

А.Н. Чернодуб

Інститут проблем математичних машин і систем НАН України, м. Київ 03187, Україна, м. Київ, проспект академіка Глушкова, 42

Навчання нейроемуляторів з використанням псевдорегулярізації для методу нейроуправління з еталонною моделлю

В статье рассматриваются задачи идентификации и управления для нелинейного динамического объекта на основе использования нейронных сетей. Излагается метод применения расширенного фильтра Калмана для обучения нейронных сетей. Предлагается метод псевдорегуляризации для эффективного обучения нейроэмуляторов в методе нейроуправления с эталонной моделью. Приводятся результаты множественных экспериментов по обучению нейроэмуляторов и нейроконтроллеров.

Ключевые слова: нейроуправление, расширенный фильтр Калмана, псевдорегуляризация.

The problems of identification and control for nonlinear dynamic object with use of neural networks are considered. The Extended Kalman Filter method for neural networks training is described. Pseudoregularization method for effective training of neuroemulator for Model Reference Adaptive Neurocontrol is proposed. The results of numerical experiments for training of neuroemulators and neurocontrollers are presented.

Key Words: neurocontrol, the extended Kalman filter, pseudoregularization

У статті розглядаються задачі ідентифікації та управління для нелінійного динамічного об'єкта на основі використання нейронних мереж. Викладається метод застосування розширеного фільтра Калмана для навчання нейронних мереж. Пропонується метод псевдорегулярізації для ефективного навчання нейроемулятора в методі нейроуправління з еталонною моделлю. Наводяться результати експериментів з навчання нейроемуляторів і нейроконтролерів.

Ключові слова: нейроуправління, розширенний фільтр Калмана, псевдорегулярізація.

Введение

В последние десятилетия искусственные нейронные сети широко используются для решения задач адаптивного управления. Нейросети успешно применялись для синтеза систем управления гибридным двигателем автомобиля [1], самолетом [2], вертолетом [3], турбогенератором [4], вооружением легкобронированных машин [5] и др. Нейронные системы управления по своей природе являются нелинейными системами, также они обладают способностью адаптироваться к изменяющимся свойствам объекта управления и внешней среды, что дает им принципиальные преимущества перед применяемыми сейчас повсеместно ПИД-контроллерами. Среди множества разработанных методов нейроуправления наибольшую популярность получили методы нейроуправления с эталонной моделью [1], [6-8], [9, с. 168], [10, с. 861] (Model Reference Adaptive Neurocontrol) и системы адаптивной критики [4], [6], [9, с. 94], [11] (Adaptive Critics).

Метод нейроуправления с эталонной моделью, также известный как «схема с нейроэмулятором и нейроконтроллером» или «обратное распространение во времени», был независимо предложен несколькими исследователями одновременно в начале 1990-х. Этот метод не требует знания математической модели объекта управления. Вместо этого, прямой динамике объекта управления обучается отдельная нейронная сеть, нейроэмулятор, затем она используется для вычисления производных при обучении управляющей нейросети, нейроконтроллера.

В предыдущем исследовании [12], [13] мы установили, что нейроэмуляторы, показывающие лучшие результаты качества идентификации в смысле минимизации среднеквадратичной ошибки моделирования динамики объекта управления, не всегда обеспечивают хорошее качество обучения нейроконтроллеров. Нами был предложен критерий отбора нейроэмуляторов на основе анализа управляющих локальных градиентов нейроэмулятора, который позволил улучшить качество обучения нейроконтроллеров в среднем на 20-30%.

В настоящей работе мы предлагаем новый метод обучения нейроэмуляторов, обеспечивающий максимизацию модулей локальных управляющих градиентов в процессе обучения, эффективный в смысле качества обучения последовательно подключенных к нейроэмуляторам нейроконтроллеров, названный нами псевдорегуляризацией. Результаты проведенных численных экспериментов показали, что полученные таким образом нейроэмуляторы обеспечивают повышение качества обучения нейроконтроллеров в среднем в 2-3 раза.

Метод нейроуправления с эталонной моделью

Пусть задан некоторый динамический объект управления, поведение которого определяется дискретными формулами (1-2):

$$S(k+1) = \Phi(S(k), u(k)),$$
 (1)

$$y(k+1) = \Psi(S(k)), \tag{2}$$

где u(k) – входной сигнал, y(k+1) – выходной сигнал на такте k. Формулы (1-2) считаются априори неизвестными. Хотя состояние объекта S(k) считается недоступным для внешнего наблюдения, его можно оценить, например:

$$S(k) = [y(k) \dots y(k-N)]^{T}.$$
 (3)

Задача управления формулируется следующим образом: пусть на такте k объект управления находится в положении y(k) и задана уставка r(k+1), которая является

желаемым положением объекта управления на следующем такте. Контроллеру необходимо сгенерировать такое управление u(k), чтобы сделать различие между уставкой r(k+1) и положением y(k+1) минимальным.

В методе нейроуправления с эталонной моделью уставка r(k+1) дополнительно сглаживается эталонной моделью, в роли которой используется, как правило, устойчивая линейная динамическая система небольшого порядка. Таким образом, замкнутый нейроконтроллером объект управления должен обучиться траектории следования эталонной модели rm(k+1).

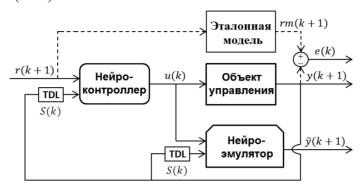


Рисунок 1 – Структурная схема нейроуправления с эталонной моделью

Метод нейроуправления с эталонной моделью предусматривает 3 этапа:

- 1) Этап обучения в режиме офф-лайн первой нейронной сети, нейроэмулятора, моделировать объект управления.
- 2) Этап обучения в режиме он-лайн второй нейронной сети, нейроконтроллера, управлять объектом управления.
- 3) Этап использования обученного нейроконтроллера для управления объектом (нейроэмулятор на этом финальном этапе не задействуется).

Нейроэмулятор

Нейроэмулятор представляет собой нейронную сеть, обученную прямой динамике объекта управления. В качестве нейронной сети мы использовали многослойный персептрон. Обучение нейроэмулятора выполняется согласно схеме «обучение с учителем». Сеть получает на вход x(k) состояние S(k) объекта управления и управляющее воздействие u(k). Таким образом, нейроэмулятор представляет собой нерекуррентную сеть, его «динамизация» происходит за счет использования входов с временными задержками (3).

Расчет выходного значения сети у выполняется по формуле:

$$\widetilde{y} = g(\sum_{j} w_{j}^{(2)} f(\sum_{i} w_{ji}^{(1)} x_{i})),$$
 (4)

где $w^{(1)}$ — веса нейронов скрытого слоя, $f(\cdot)$ — активационные функции нейронов скрытого слоя, $w^{(2)}$ — веса нейронов выходного слоя, $g(\cdot)$ — активационные функции нейронов выходного слоя. На рис. 2 показан нейроэмулятор с четырьмя нейронами в скрытом слое, который получает на вход состояние порядка N=1.

Подобным образом сконструированные нейроэмуляторы могут обучаться различными градиентными оптимизационными методами с вычислением производных по методу обратного распространения ошибки (Backpropagation, BP). При этом размер

выбранного временного окна, определяемый параметром N, должен быть установлен примерно равным порядку моделируемого динамического процесса, в противном случае алгоритму обучения будет невозможно найти корреляцию между входом нейросети и целевым выходом.

Обучение нейроэмуляторов методом расширенного фильтра Калмана

Фильтр Калмана является эффективным рекурсивным фильтром, который по ряду зашумленных и неполных измерений позволяет оценить внутреннее состояние динамической системы и применяется в широчайшем спектре технических устройств, от спидометров автомобиля до радиоприемников и радаров. Типичной задачей для фильтра Калмана является оценка прошлых, текущих или будущих значений положения, скорости или ускорения некоторой динамической системы, для которой известна ее линейная или мгновенная линеаризованная модель.

Обучение нейронных сетей является достаточно неожиданным приложением для теории фильтрации Калмана и, вместе с тем, очень эффективным: с одной стороны, качество такого обучения находится на уровне лучших пакетных алгоритмов второго порядка, таких как метод Левенберга-Марквардта или квази-Ньютоновских методов [14], а с другой стороны – обучение проводится в режиме он-лайн, что является актуальным в случае выборок большого объема и задач управления. Существуют различные модификации этого метода обучения, так или иначе повышающие его эффективность: многопоточное обучение (multistream learning) [8], позволяющее минимизировать риск попадания в локальный минимум, пакетная форма обучения (batch form) [15], позволяющая обрабатывать несколько последних измерений за один раз, несвязный расширенный фильтр Калмана (Decoupled Extended Kalman Filter) [8], который применяется для экономии вычислительных ресурсов. Также недавно были предложены новые реализации фильтра Калмана, имеющие большую вычислительную точность и, вследствие этого, обеспечивающие улучшенную сходимость: фильтр Калмана на основе квадратного корня [10, с. 960] и кубатурный фильтр Калмана [16, с. 787]. В настоящей работе мы описываем наиболее простую и технологичную реализацию обучения методом расширенного фильтра Калмана, «глобальный расширенный фильтр Калмана» (Global Extended Kalman Filter, GEKF).

Во всех этих вариантах обучение нейронной сети рассматривается как задача оценки истинного состояния некоторой неизвестной «идеальной» нейросети, обеспечивающей нулевое рассогласование, под состояниями в данном случае принимаются значения весов нейросети w(k), а под рассогласованием – текущая ошибка обучения e(k).

Этот динамический процесс обучения может быть описан парой уравнений в пространстве состояний, (5) и (6). Уравнение состояния (5) представляет собой модель процесса, представляющего эволюцию вектора весов под воздействием случайного процесса $\xi(k)$, который считается белым шумом с нулевым математическим ожиданием и известной диагональной ковариационной матрицей Q:

$$w(k+1) = w(k) + \xi(k).$$
 (5)

Уравнение выхода (6) представляет собой линеаризованную модель нейросети (4) на такте k, зашумленную случайным процессом $\zeta(k)$, который считается белым шумом с нулевым математическим ожиданием и известной диагональной ковариационной матрицей R:

$$h(k) = \frac{\partial y(w(k), v(k), x(k))}{\partial w} + \zeta(k), \tag{6}$$

где w(k) – веса нейросети, v(k) – постсинаптические потенциалы нейронов, x(k) – входные значения сети. Вычисление мгновенных значений производных $\frac{\partial y}{\partial w}$ производится методом обратного распространения. Рассогласование e(k) рассчитывается по формуле (7):

$$e(k) = t(k) - \widetilde{y}(k), \tag{7}$$

где t(k) — целевое значение для нейросети, $\tilde{y}(k)$ — реальный выход нейросети, рассчитываемый по формуле (4).

Перед обучением нейросети проходит этап инициализации. Задаются ковариационные матрицы шума измерения $R=\eta I$ и динамического шума обучения $Q=\mu I$, размер матриц $L\times L$ и $N\times N$ соответственно, где L- количество выходных нейронов, N- количество весовых коэффициентов нейросети. Коэффициент η имеет смысл скорости обучения, у нас $\eta=0.001$, коэффициент μ определяет шум измерения, у нас $\mu=10^{-4}$. Также задаются единичная на инициализационном этапе матрица ковариации P размера $N\times N$ и нулевая матрица измерений H размера $L\times N$.

Этап обучения производится в режиме он-лайн, коррекция весов нейросети последовательно выполняется для каждого примера обучающей выборки.

На такте k выполняются следующие действия.

- 1) Вычисляется новое значение выхода нейросети $\mathfrak{F}(k)$ согласно формуле (4), выполняется «прямой проход» нейросети.
- 2) Выполняется «обратный проход» нейросети: методом обратного распространения вычисляются производные $\frac{\partial \widetilde{y}}{\partial w_i}$, $i=\overline{1,N}$. Это делается с помощью такой же техники, что и в методе обратного распространения ошибки, но локальные градиенты для выходных нейронов устанавливаются равными не текущей ошибке e(k), а константе 1, что при всех тех же вычислениях обеспечивает получение значений якобианов выходов нейросети $\frac{\partial \widetilde{y}}{\partial w}$ вместо градиентов $\frac{\partial [e(k)^2]}{\partial w}$, поскольку $\frac{\partial [e(k)^2]}{\partial w} = 2e(k)\frac{\partial y}{\partial w}$. Формируется матрица наблюдений H(k):

$$H(k) = \left[\frac{\partial \tilde{y}}{\partial w_1} \quad \frac{\partial \tilde{y}}{\partial w_2} \quad \dots \quad \frac{\partial \tilde{y}}{\partial w_N} \right]^T.$$
 (8)

3) Определяется текущая ошибка работы сети e(k) по формуле (7), формируется матрица отклонений E(k) размера $1 \times L$:

$$E(k) = [e(k)] \tag{9}$$

4)Вычисляются новые значения весов нейросети w(k+1) и матрицы корреляции P(k+1) по формулам:

$$K(k) = P(k)H(k)^{T}[H(k)P(k)H(k)^{T} + R]^{-1},$$
(10)

$$P(k+1) = P(k) - K(k)H(k)P(k) + Q,$$
(11)

$$w(k+1) = w(k) + K(k)e(k), (12)$$

где K(k) – матрица усиления Калмана, ее размерность $N \times L$.

Действия 1) – 4) выполняются для всех элементов обучающей выборки.

Обновляющаяся на каждом такте корреляционная матрица P содержит информацию второго порядка о поверхности ошибок, что обеспечивает методу расширенного фильтра Калмана преимущество по сравнению с методами обучения первого порядка, такими как градиентный спуск и его модификации.

Обучение нейроконтроллера

После того, как нейроэмулятор обучен, его можно использовать для обучения нейроконтроллера. Для этого нейроконтроллер последовательно подключается к нейроэмулятору, как показано на рис. 1 и рис. 2.

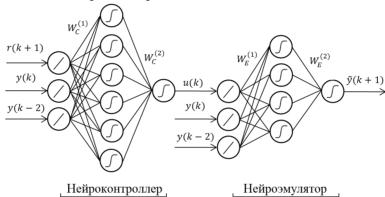


Рисунок 2 – Нейроэмулятор и нейроконтроллер как единая нейросеть

Обучение нейроконтроллера выполняется в режиме он-лайн, параллельно с управлением объектом. На такте k нейроконтроллер получает на вход уставку r(k+1), вектор состояния S(k) (3) и генерирует управляющее воздействие u(k). Сигнал u(k) поступает на объект управления, переводя его в положение y(k+1), и, параллельно, на обученный нейроэмулятор, который генерирует оценку нового положения $\widetilde{y}(k+1)$. Если нейроэмулятор хорошо обучен, то всегда $\|y(k+1)-\widetilde{y}(k+1)\| < \varepsilon$, где ε – малое значение. Также уставка r(k+1) поступает на эталонную модель, которая генерирует целевое значение для обучения нейроконтроллера rm(k+1). В роли эталонной модели обычно используется устойчивая линейная динамическая система небольшого порядка. На основании выходного значения эталонной модели rm(k+1) и нового положения объекта управления y(k+1) формируется текущая ошибка управления e(k):

$$e(k) = rm(k+1) - v(k+1). (13)$$

Далее происходит этап коррекции весов нейроконтроллера. Идея обучения нейроконтроллера состоит в том, что последовательно соединенные модули нейроконтроллера и нейроэмулятора, каждый из которых представляет трехслойную нейросеть с весами W_C и W_E соответственно, образуют новую шестислойную нейросеть (рис. 2), которая обучается минимизировать ошибку (13). При этом корректируются только веса нейроконтроллера W_C , веса нейроэмулятора W_E считаются «заморо-

женными» и не изменяются. Для расчета производных, необходимых для коррекции весов нейроконтроллера, используется метод обратного распространения ошибки, который применяется к объединенной нейросети «нейроконтроллер + нейроэмулятор». В случае, если для обучения нейроконтроллера применяется метод градиентного спуска [7], [9, с. 168], [12], [13], через объединенную нейросеть пропускается текущая ошибка управления (13), что позволяет получить необходимые градиенты $\frac{\partial [e(k)^2]}{\partial w_C^{(1)}}$ и $\frac{\partial [e(k)^2]}{\partial w_C^{(2)}}$. Если для обучения нейроконтроллера используется метод расширенного фильтра Калмана [1], [8], [12], [13], через объединенную нейросеть пропускается константа 1, что позволяет получить необходимые якобианы $\frac{\partial \widetilde{y}}{\partial w_C^{(1)}}$ и $\frac{\partial \widetilde{y}}{\partial w_C^{(2)}}$, которые формируют матрицу наблюдений H(k). Матрица отклонения E(k) составляется из текущей ошибки управления (13), после чего выполняется коррекция весов нейрокон-

Максимизация абсолютных значений локальных управляющих градиентов нейроэмуляторов

троллера согласно формулам (10) – (12).

Рассмотрим нейроэмулятор, в нашем случае представляющий собой многослойный персептрон с линейными функциями активации для входного слоя нейронов и функциями активации гиперболического тангенса для скрытого и выходного слоев нейронов, прямая динамика которого определяется формулой (4).

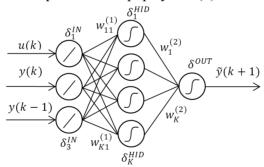


Рисунок 3 – Вычисление локальных градиентов для нейроэмулятора

При выполнении процедуры обратного распространения, проводится расчет локальных градиентов для скрытого слоя $\delta^{{\it HID}}$ и входного слоя нейронов $\delta^{{\it IN}}$ нейронов:

$$\delta_{j}^{HID} = f'(z_{j}) \sum_{m=1}^{L} w_{mj}^{(2)} \delta_{m}^{OUT}, \tag{14}$$

$$\delta_i^{IN} = \sum_{n=1}^K w_{ni}^{(1)} \delta_n^{HID}, \tag{15}$$

где $w^{(1)}$ — веса нейронов скрытого слоя, $f(\cdot)$ — активационные функции нейронов скрытого слоя, z_j — значения постсинаптических потенциалов скрытого слоя, K — количество нейронов скрытого слоя, $w^{(2)}$ — веса нейронов выходного слоя, L — количество выходных нейронов (для упрощения дальнейших выкладок мы примем L=1).

Управляющий локальный градиент δ_u соответствует тому входному нейрону, который получает управляющий сигнал от нейроконтроллера u(k). Если нейроэмулятор сконструирован так, как показано на рис. 3, то $\delta_u = \delta_1^{IN}$,

$$\delta_{u} = \sum_{n=1}^{K} w_{j1}^{(1)} f'(z_{j}) \sum_{m=1}^{L} w_{mj}^{(2)} \delta_{m}^{OUT}.$$
(16)

Хорошо обученные нейроэмуляторы, обладающие среднеквадратичной ошибкой моделирования прямой динамики объекта управления менее 10^{-5} , не всегда обеспечивают хорошее качество обучения нейроконтроллера [12], [13]. Анализ локальных градиентов входных нейронов нейроэмуляторов, показал, что у менее успешных в смысле качества управления нейроэмуляторов абсолютные значения управляющих локальных градиентов δ_u относительно малы. При этом, точность как у успешных, так и у неуспешных нейроэмуляторов в смысле среднеквадратичной ошибки моделирования прямой динамики объекта управления может быть приблизительно одинакова.

Обучение нейроэмуляторов с псевдорегуляризацией

В настоящей работе мы предлагаем метод обучения нейроэмуляторов с оптимизацией локальных управляющих градиентов, названный нами псевдорегуляризацией. Суть псевдорегуляризации состоит в минимизации в процессе обучения нейроэмулятора функционала Q(w):

$$Q(w) = e(w) + \lambda (1 - \delta_{u}(w)^{2}), \tag{17}$$

где e(w) – среднеквадратичная ошибка моделирования объекта (7), δ_u – управляющий локальный градиент (16), λ – заданная априори константа псевдорегуляризации.

Целью данной статьи является обучение нейроэмулятров прямой динамике объекта управления с максимизацией абсолютных значений управляющих градиентов в среднем (18),

$$\Omega = \frac{1}{n} \sum_{k=1}^{n} \delta_u^2(k),\tag{18}$$

при этом учитывается, что в реальных системах вследствие эффекта исчезновения градиента $\delta_u(w)^2 << 1$. В формуле (18) n – количество элементов обучающей выборки.

Для минимизации функционала (17) в настоящем работе нами предлагается обобщение метода оптимизации расширенного фильтра Калмана для многокритериального случая.

Теперь выходом модели динамического процесса обучения на каждом такте является не только результат прямого прохода выход нейросети \widetilde{y} , а и вычисляемая во время выполнения обратного прохода величина δ_u^2 .

Соответственно, для дополнительного выхода рассчитываются якобианы $\frac{\partial (\delta_u^2)}{\partial w}$ для включения в матрицу наблюдений H, а второе слагаемое функционала O(w) добавляется в матрицу отклонений E.

Продифференцируем квадрат управляющего локального градиента (16) по весам скрытого и выходного слоя (здесь и далее мы принимаем L=1):

$$\begin{cases} \frac{\partial(\delta_u^2)}{\partial w^{(1)}_{J1}} = 2\delta_u f'(z_J) & w_J^{(2)} \delta^{OUT}, \\ \frac{\partial(\delta_u^2)}{\partial w^{(1)}_{Jn}} = 0, & \partial \pi & n \neq 1, \end{cases}$$

$$(19)$$

$$\frac{\partial(\delta_u^2)}{\partial w^{(2)}} = 2\delta_u f'(z_I) \ w_{II}^{(1)} \delta^{OUT}. \tag{20}$$

На этапе инициализации зададим ковариационные матрицы шума измерения $\widetilde{R}=\eta I$ и динамического шума обучения $Q=\mu I$, размер матрицы \widetilde{R} в многокритериальной версии фильтра становится равным $(L+M)\times (L+M)$, размер матрицы Q остается $N\times N$, здесь: L — количество выходных нейронов, N — количество весовых коэффициентов нейросети, M — количество управляющих входов. Размер матрицы наблюдений \widetilde{H} становится равным $(L+M)\times N$, размер матрицы усиления Калмана \widetilde{K} теперь $N\times (L+M)$, размер матрицы корреляции процесса обучения P остается равным $N\times N$.

На такте k выполняются следующие действия.

- 1) Выполняется «прямой проход» нейросети, вычисляется выход нейросети $\mathfrak{F}(k)$ согласно формуле (4).
- 2) Выполняется «обратный проход» нейросети: методом обратного распространения вычисляются якобианы $\frac{\partial \widetilde{y}}{\partial w}$. В процессе расчета якобианов, параллельно вычисляются локальные градиенты для скрытого и входного слоя нейронов (14) (15), определяются управляющие локальные градиенты δ_u (16), вычисляются якобианы $\frac{\partial (\delta_u^2)}{\partial w_i}$, $i=\overline{1,N}$ по формулам (19) (20). Формируется многокритериальная матрица наблюдений $\widetilde{H}(k)$:

$$\widetilde{H}(k) = \begin{bmatrix} \frac{\partial \widetilde{y}}{\partial w_1} & \frac{\partial \widetilde{y}}{\partial w_2} & \dots & \frac{\partial \widetilde{y}}{\partial w_N} \\ \frac{\partial (\delta_u^2)}{\partial w_1} & \frac{\partial (\delta_u^2)}{\partial w_2} & \dots & \frac{\partial (\delta_u^2)}{\partial w_N} \end{bmatrix}^T.$$
(21)

3) Формируется многокритериальная матрица отклонений $\widetilde{E}(k)$ размера $1\times(L+M)$:

$$\widetilde{E}(k) = [e(k) \quad \lambda(1 - \delta_u^2)].$$
 22)

4) Вычисляются новые значения весов нейросети w(k+1) и матрицы корреляции P(k+1) по формулам (10)-(12).

Действия 1) – 4) выполняются для всех элементов обучающей выборки.

Предлагаемая здесь техника многокритериальной оптимизации методом расширенного фильтра Калмана не встречалась нами ранее в литературе. Она может использоваться и для других многокритериальных задач вида (17), для которых можно ввести функцию ошибки и вычислить соответствующие якобианы, например, для регуляризации нейросетей по Тихонову.

Результаты экспериментов

Численные эксперименты состояли из двух частей: обучение нейроэмуляторов и обучение нейроконтроллеров. В ходе обучения нейроэмуляторов было взято множество из 250 нейросетей, их веса были инициализированы случайными небольшими значениями и зафиксированы, после чего было проведено обучение нейроэмуляторов без псевдорегуляризации и с псевдорегуляризацией. Во второй части эксперимента обученые нейроэмуляторы были использованы для обучения нейроконтроллеров для управления нелинейным динамическим объектом 2-го порядка, было проведено сравнение показанного качества управления.

Объект управления. В нашей работе в качестве объекта управления мы использовали нелинейный динамический объект второго порядка из [17], который, в свою очередь, является слегка модифицированной версией объекта управления из классической работы [7]. Объект управления задается формулой:

$$y(k+1) = \frac{y(k)y(k-1)y(k-2)u(k-1)[y(k-2)-1] + u(k)}{1 + y(k-1)^2 + y(k-2)^2},$$
(23)

где u(k) – входной сигнал, v(k+1) – выходной сигнал на такте k.

Обучение нейроэмуляторов. Обучение нейроэмуляторов проводилось в среде МАТLAB без использования пакета Neural Network Toolbox. На объект подавался идентификационный сигнал $u(k) = \sin(2\pi k/300)$ и производилось протоколирование выходов y(k). На основе записанных данных была сформирована обучающая и тестовая выборки примеров динамики в количестве 500 и 100 примеров соответственно. На них были обучено 6 множеств по 250 нейроэмуляторов методами глобального расширенного фильтра Калмана без псевдорегуляризации и методом многокритериального глобального расширенного фильтра Калмана с псевдорегуляризацией с различными значениями параметра λ (табл. 1). Отметим, что перед обучением веса всех множеств нейросетей были идентичны, варьировались только алгоритмы обучения для каждого из множеств. Для всех слоев нейросетей были использованы активационные функции гиперболического тангенса, количество нейронов в скрытом слое варьировалось от 3 до 7.

Таблица 1 — Сравнительные характеристики обученных нейроэмуляторов: без псевдорегуляризации и с псевдорегуляризацией с различными значениями веса λ

Метод обучения	Без псевдо- регуляризации	λ=0.01	λ=0.015	λ=0.02	λ=0.025	λ=0.03
Ошибка MSE, мин.	1.62E-06	2.6E-06	6.1E-06	3.3E-06	1.9E-05	2.5E-05
Ошибка MSE, сред.	2.1E-06	3.0E-05	5.7E-05	8.1E-05	1.3E-04	8.8E-03
Ω, мин.	2.5E-04	4.0E-04	4.8E-04	2.7E-03	1.8E-02	2.4E-02
Ω, сред.	2.9E-04	2.0E-02	1.1E-01	1.4E-01	4.5E-01	5.3E-01

Здесь была использована формула расчета среднеквадратичной ошибки: $MSE=\langle (\widetilde{y}_k-t_k)^2 \rangle$, где \widetilde{y}_k — выход нейросети, t_k — целевое значение. Параметр Ω , характеризующий среднюю величину квадратов управляющих локальных градиентов нейроэмуляторов, вычисляется по формуле (18). Как видно из табл. 1, использование многокритериального расширенного фильтра Калмана обеспечило рост абсолютных

значений управляющих локальных градиентов Ω за счет некоторого понижения качества моделирования прямой динамики объекта управления MSE.

Обучение нейроконтроллеров. После обучения нейроэмуляторов было проведено обучение нейроконтроллеров, для чего нейросети и алгоритмы их обучения были смоделированы в среде Simulink, без использования пакета Neural Network Blockset. В качестве эталонной модели была взята устойчивая линейная динамическая система первого порядка с передаточной функцией $T(s) = \frac{1}{0.004s+1}$. Для оценки качества управления использовалась интегральная абсолютная ошибка (Integral Absolute Error, IAE),

$$IAE = \sum_{k=1}^{n} (y(k) - rm(k))^{2},$$
(24)

где y(k) — выход объекта управления, y(k) — выход эталонной модели, n — количество тактов на участке.

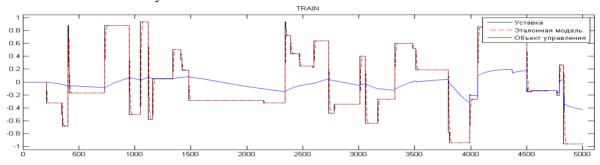


Рисунок 4 – Обучающий участок, начало обучения

Копия нейроконтроллера, показавшая лучшее качество управления на тестовом участке за все итерации дополнительно тестировалась на валидационном участке (рис. 5, справа).

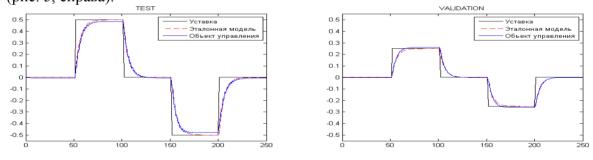


Рисунок 5 – Тестирующий участок (слева), валидационный участок (справа)

Результаты, показанные на валидационном участке, считаются окончательными и представлены в табл. 2.

Таблица 2 – Качество управления для нейроконтроллеров, обученных с помощью нейроэмуляторов без псевдорегуляризации и с псевдорегуляризацией

Метод	Без	λ=0.01	λ=0.015	λ=0.02	λ=0.025	λ=0.03
обучения	псевдорегуляризации					
Ошибка	0.00373	0.00218	0.00222	0.00221	0.00220	0.00166
ІАЕ, мин.	0.00373	0.00210	0.00222	0.00221	0.00220	0.00100
Ошибка IAE, сред.	0.06995	0.01757	0.01342	0.03545	0.02039	0.03245

Как видно из табл. 2, использование предлагаемого метода псевдорегуляризации, обеспечило повышение качества обучения нейроконтроллеров в среднем в 2-3 раза.

Выводы

В работе предложен новый метод обучения нейроэмуляторов для обучения нейроконтроллеров для метода нейроуправления с эталонной моделью. Было проведено экспериментальное исследование предлагаемого метода псевдорегуляризации с обучением 1500 нейроэмуляторов и 1500 нейроконтроллеров, показавшее эффективность нового метода по сравнению с традиционным обучением нейроэмуляторов по методу наименьшей среднеквадратичной ошибки моделирования прямой динамики объекта управления. Использование псевдорегуляризации обеспечило уменьшение ошибки управления в среднем в 2 – 3 раза. Для решения задачи псевдорегуляризации была предложена многокритериальная версия расширенного фильтра Калмана и была экспериментально подтверждена его работоспособность.

Литература

- 1. Danil V. Prokhorov. Toyota Prius HEV Neurocontrol and Diagnostics // Neural Networks. 2008. No. 21. P. 458-465.
- 2. Gundy-Burlet K., Krishnakumar K., Limes G., Bryant D. Augmentation of an Intelligent Flight Control System for a Simulated C-17 Aircraft // J. of Aerospace Computing, Information, and Communication. 2004. Vol. 1, N 12. P. 526-542.
- 3. Никифорова Л. Н., Петросян Э. А., Якеменко Г. В. Нейрокомпьютеры в управлении вертолетами // Искусственный интеллект. 2000. № 3. С. 290-298.
- 4. Venayagamoorthy G.K., Harley R.G., Wunsch D.C. Implementation of Adaptive Critic-based Neurocontrollers for Turbogenerators in a Multimachine Power System // IEEE Transactions on Neural Networks. 2003. Vol. 14, Issue 5. P. 1047-1064.
- 5. Кузнецов Б. И., Василец Т. Е., Варфоломеев А. А. Синтез нейроконтроллера с предсказанием для двухмассовой электромеханической системы // Электротехника и электромеханика. 2008. Т. 3. С. 27-32.
- 6. А.Н. Чернодуб, Д.А. Дзюба. Обзор методов нейроуправления // Проблемы программирования . 2011 N 2 С 79-94
- 2011. N. 2. C. 79-94.
 7. Narendra K.S., Parthasarathy K.K. Identification and control of dynamical systems using neural networks // IEEE Transactions on Neural Networks. 1990. N 1. P. 4- 27.
- 8. Feldkamp L.A. Training controllers for robustness: multi-stream DEKF / L.A. Feldkamp, G.V. Puskorius // Proceedings of International Conference on Neural Networks, Orlando, FL, USA. 27 Jun 2 Jul 1994. V. 4. P. 2377-2382.
- 9. Омату С. Нейроуправление и его приложения: / С. Омату, М. Халид, Р. Юсоф ; [пер. с англ.]. М.: ИПРЖР, 2000. 272 с.
- 10. Хайкин С. Нейронные сети: полный курс / Хайкин С. М.: Вильямс, 2006. 1104 с.
- 11. Prokhorov D. and Adaptive Critic Designs / D. Prokhorov, D. Wunsch // IEEE Transactions on Neural Networks. − 1997. − Vol. 8, № 5. − P. 997-1007.
- 12. Чернодуб А.Н. Критерий выбора нейроэмуляторов на основе локальных градиентов в методе управления с эталонной моделью // XIV Всероссийская конференция «Нейроинформатика-2012»: сб. научных трудов. Часть 3. М.: НИЯУ МИФИ, 2012. С. 214-223.
- 13. Chernodub A.N. Local Control Gradients Criterion for Selection of Neuroemulators for Model Reference Adaptive Neurocontrol / A.N. Chernodub // Optical Memory and Neural Networks (Information Optics). − 2012. − V. 21. − №. 2. − P. 126-131.
- 14. Alessandri A. On the convergence of EKF-based parameters optimization for Neural Networks / A. Alessandri M. Cuneo, S. Pagnan // Proceedings of the 42nd IEEE Conference on Decision and Control. Maui, Hawaii, USA, December 2001. V. 6. P. 6181-6186.
- 15. Li S. Comparative analysis of backpropagation and extended Kalman filter in pattern and batch forms for training neural networks / S. Li // Proceedings International Joint Conference on Neural Networks, IJCNN '01, Washington, DC, July 15 19. 2001. V 1. P. 144-149.

- 16. Haykin S. Neural Networks and Learning Machines, Third Edition / Haykin S. New York: Prentice Hall, 2009. 936 p.
- 17. Venelinov Topalov. O. Online learning in adaptive neurocontrol schemes with a sliding mode algorithm / Venelinov Topalov, A. Kaynak // IEEE Transactions on Systems, Man, and Cybernetics. Part B: Cybernetics. 2001. V. 31. I. 3. P. 445-450.

Literatura

- 1. Danil V. Prokhorov. Neural Networks. 2008. № 21. P. 458-465.
- 2. Gundy-Burlet K. J. of Aerospace Computing, Information, and Communication. 2004. Vol. 1. № 12. P. 526-542.
- 3. Nikiforova L. N. Iskusstvennyj intellekt. 2000. № 3. S. 290-298.
- 4. Venayagamoorthy G.K. IEEE Transactions on Neural Networks, 2003. Vol. 14. Issue 5. P. 1047-1064.
- 5. Kuznecov B. I. Jelektrotehnika i jelektromehanika. 2008. T. 3. S. 27-32.
- 6. Chernodub A.N. Problemy programmirovanija. 2011. № 2. S. 79-94.
- 7. Narendra K.S. IEEE Transactions on Neural Networks. 1990. № 1. P. 4-27.
- 8. Feldkamp L.A. Proceedings of International Conference on Neural Networks. Orlando. FL. USA. 27 Jun-2 Jul 1994. V. 4. P. 2377-2382.
- 9. Omatu S. Nejroupravlenie i ego prilozhenija: per. s angl. M: IPRZhR. 2000. 272 s.
- 10. Hajkin S. Nejronnye seti: polnyj kurs. M.: Vil'jams. 2006. 1104 s.
- 11. Prokhorov D. IEEE Transactions on Neural Networks. 1997. Vol. 8. № 5. P. 997-1007.
- 12. Chernodub A.N. XIV Vserossijskaja konferencija "Nejroinformatika-2012". Sbornik nauchnyh trudov. Chast' 3. M.: NIJaU MIFI. 2012. S. 214-223.
- 13. Chernodub A.N. Optical Memory and Neural Networks (Information Optics). 2012. V. 21. № 2. P. 126-131.
- 14. Alessandri A. Proceedings of the 42nd IEEE Conference on Decision and Control. Maui, Hawaii, USA. December 2001. V. 6. P. 6181-6186.
- 15. Li S. Proceedings International Joint Conference on Neural Networks, IJCNN '01. Washington. DC. July 15-19. 2001. V. 1. P. 144-149.
- 16. Haykin S. Neural Networks and Learning Machines, Third Edition. New York: Prentice Hall. 2009. 936 p.
- 17. Venelinov Topalov. IEEE Transactions on Systems, Man, and Cybernetics. Part B: Cybernetics. 2001. V. 31. I. 3. P. 445-450.

REZUME

A.N. Chernodub

Training of Neuroemulators with Use of Pseudoregularization for Model Reference Adaptive Neurocontrol

Nowadays, artificial neural networks are widely used for nonlinear adaptive control purposes. Industrial applications include aircraft and hybrid engine control, power plants. military armed vehicles, etc. Efficient training algorithms for problems of identification and control for nonlinear plants using neural networks are still actual. In the given paper, the Model Reference Adaptive Neurocontrol method that is also known as "neuroemulator and neurocontroller scheme" is considered. The stages of training of neuroemulator and neurocontroller are described; the problem of training neuroemulator in means of modeling of direct plant's dynamics is discussed; the Extended Kalman Filter method for neural networks training is also considered; the pseudoregularizaion problem for neuroemulators as the problem of maximization of local control gradients is set; the multicriteria Extended Kalman Filter method for solving pseudoregularization problem is proposed. The experimental results with well-known nonlinear dynamic plant proposed by Narendra are provided. The results of numerical simulations are presented. The experiments included training of 1500 neuroemulators and 1500 neurocontrollers. Comparative results of training of neuroemulators and neurocontrollers are presented. Simulations show double or thrice increase of control accuracy for neurocontrollers trained on the base of pseudoregularized neuroemulators in comparison to neuroemulators trained traditionally.

Статья поступила в редакцию 01.06.2012.