

УДК 681.518

ЭФФЕКТИВНАЯ НЕЙРОСЕТЕВАЯ ИДЕНТИФИКАЦИЯ ИНВЕРСНОЙ ДИНАМИКИ ОБЪЕКТА УПРАВЛЕНИЯ ДЛЯ СИНТЕЗА ПРОГНОЗИРУЮЩИХ СИСТЕМ УПРАВЛЕНИЯ

Б.С. Ноткин

Дальневосточный государственный технический университет (ДВПУ им. В.В. Куйбышева)
Россия, 690950, Владивосток, ул. Пушкинская, 10
E-mail: Boris_Notkin@mail.ru

К.В. Змеу

Дальневосточный государственный технический университет (ДВПУ им. В.В. Куйбышева)
Россия, 690950, Владивосток, ул. Пушкинская, 10
E-mail: k.zmeu@ieee.org

Ключевые слова: нейроуправление, нейросетевая идентификация, прогнозирующее управление, инверсная модель

Key words: neurocontrol, plant identification, predictive control, inverse model

В работе рассматривается новый подход к синтезу регуляторов систем автоматического управления (САУ), основанный на нейросетевой идентификации обратной динамики объекта управления, выполняемой по специальным правилам формирования обучающей выборки. Это позволяет придать регулятору прогнозирующие свойства во многом аналогичные системам прогнозирующего управления с моделью (Model-Based Predictive Control), но при существенно меньших затратах вычислительных ресурсов, упрощении общей структуры системы и естественной близости к системам с адаптацией в реальном времени. Преимущества предложенного подхода показаны на численных моделях САУ.

POWER NEURAL NETWORKS IDENTIFICATION OF PLANT INVERSE DYNAMIC FOR PREDICTIVE CONTROL SYSTEMS DESIGN / B.S. Notkin (Far Eastern State Technical University, 10 Pushkinskaya, Vladivostok 690950, Russia, E-mail: Boris_Notkin@mail.ru), K.V. Zmeu (Far Eastern State Technical University, 10 Pushkinskaya, Vladivostok 690950, Russia, E-mail: k.zmeu@ieee.org). The paper presents a new approach to systems controller design, which is based on neural networks identification. Special rules for network training are developed. The aim is to increase predictive behaviors of neural network dynamic model. Such system is close to model-based predictive control, but needs much less computational resources. Advantages are shown by computer modeling.

1. Введение

Задача идентификации является фундаментальной в теории систем и, в частности, теории автоматического управления. Благодаря своим универсальным аппроксимирующим свойствам, искусственные нейронные сети (ИНС) представляют собой мощный инструмент для решения задачи идентификации нелинейных динамических объектов управления. Принято выделять прямые и обратные (инверсные) нейросетевые модели динамики объектов управления. Ме-

тоды синтеза таких моделей появились более двадцати лет назад, практически одновременно с рождением самого нейронаправления в теории регулирования, и с тех пор не претерпели принципиальных изменений. Наиболее распространенный способ получения нейросетевых моделей – идентификация в режиме off-line по снятой с объекта выборке (вход/выход). В зависимости от того, какие данные этой выборки подаются на вход искусственной нейронной сети (ИНС), а какие на выход, получают либо прямую модель, либо инверсную модель динамики объекта. Модели объекта могут быть получены и в режиме on-line. В этом случае, для получения прямой модели, ИНС ставят параллельно объекту управления и обучают по ошибке между фактическим и восстановленным сетью выходом объекта. Для получения инверсной модели, ИНС включают последовательно с объектом управления и обучают по ошибке между сигналом на входе сети и сигналом с выхода объекта (их равенство будет достигнуто в случае соответствия последовательного соединения ИНС – объект единичному коэффициенту) [1].

Прямые и обратные модели служат основными «строительными блоками» большинства систем нейрорегулирования [2]. На их основе могут строиться как стационарные, так и адаптивные и прогнозирующие системы нейрорегулирования. В данной работе предложен новый подход к формированию нейросетевых прогнозирующих инверсных моделей динамики объектов управления.

2. Предварительные замечания

2.1. О прогнозирующем управлении

В широком смысле прогнозу может подлежать множество свойств управляемого процесса. Прогноз аварийных ситуаций с целью их предотвращения (перегревы, поломки узлов оборудования и инструмента, вибрации и т.д.), прогноз с целью оптимизации ресурсопотребления (расхода топлива, износа инструмента и т.д.), прогноз возмущающих воздействий, прогноз изменений параметров объектов управления и т.п. Но применительно к замкнутым САУ, под термином «прогнозирующее управление» понимают метод, именуемый в зарубежной литературе “Model-Based Predictive Control” (MPC) [3, 4]. Эта техника охватывает достаточно широкий диапазон методик и алгоритмов. Она требует наличия модели динамики объекта управления (ОУ) и относится к классу методов дискретного локально-оптимального управления с удаляющимся горизонтом прогноза.

Основной принцип MPC состоит в нахождении на каждом интервале дискретности n такой последовательности управляющих воздействий $\hat{y}[n] \dots \hat{y}[n + \lambda]$, которая, будучи приложена к объекту, обеспечит максимальное совпадение последовательности прогнозируемых значений выхода $\hat{x}[n] \dots \hat{x}[n + \lambda]$ с последовательностью его желаемых значений $x_r[n] \dots x_r[n + \lambda]$, зависящих от сигнала задания $u(t)$ (рис. 1, (а)). Прогнозируемая последовательность управляющих воздействий $\hat{y}[n] \dots \hat{y}[n + \lambda]$ определяется путем минимизации (численной или безусловной) целевого функционала, одна из простейших форм которого может иметь вид:

$$J = \sum_{i=0}^{\lambda} (x_r[n+i] - \hat{x}[n+i])^2,$$

где λ – горизонт прогноза.

МРС использует принцип удаляющего горизонта, который устанавливает, что только первое значение из вычисленной последовательности управляющих воздействий прикладывается к ОУ в момент времени n ($y[n] = \hat{y}[n]$). На следующем интервале управления весь объем вычисления повторяется для новых фактических значений выхода ОУ и уставки, с определением новой образцовой траектории.

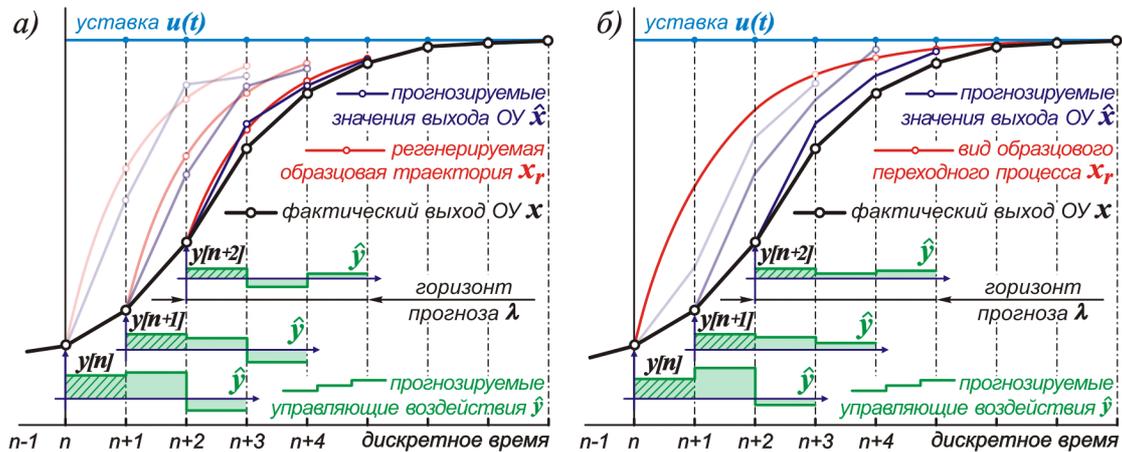


Рис. 1. Методы прогнозирующего управления: а) общий принцип; б) частное решение.

Существуют и упрощенные варианты прогнозирующего управления в рамках МРС. Графическая иллюстрация к одному из таких частных решений представлена на рис. 1, (б). Этот подход оперирует не совпадением на каждом шаге просчитываемого горизонта прогноза, а лишь совпадением прогнозируемого \hat{x} и желаемого x_r состояния объекта в крайней (наиболее удаленной) точке горизонта прогноза, при этом, также как и в расширенном варианте, управляющие воздействия $\hat{y}[n] \dots \hat{y}[n + \lambda]$ рассчитываются для всего интервала λ , но лишь первое из них подается на вход ОУ.

2.2. Взаимосвязь размерности векторов, структур ИНС и динамических свойств объектов управления

Не смотря на то, что реализация ИНС может быть выполнена как в дискретном, так и в непрерывном варианте, в структурах систем управления обычно используются дискретные ИНС. Поэтому для таких систем справедливы все основные положения дискретных САУ.

В дискретном пространстве состояние динамического объекта описывается разностным уравнением общего вида:

$$(1) \quad x[n] = \sum_{i=1}^m a_i x[n-i] + \sum_{i=q}^r b_i y[n-i], \quad r > q,$$

где a_i и b_i – постоянные коэффициенты, $x[n] \dots x[n-m]$ – текущий дискретный выход объекта и m его предыдущих (задержанных на величину дискретности) значений, m – порядок соответствующей непрерывной передаточной функции, $y[n-q] \dots y[n-r]$ – задержанные дискретные значения на входе динамического объекта. Значения q и r зависят не только от порядка числителя соответствующей непрерывной передаточной функции, но и от способа дискретизации и наличия запаздывания в объекте.

Поскольку фундаментальные свойства линейного динамического объекта определяются его характеристическим уравнением, можно рассматривать задержанные значения $x[n-1] \dots x[n-m]$, как несущие информацию об основных свойствах объекта, другими словами, самую существенную роль играет предыстория выходной координаты объекта. Поэтому предполагается, что, для рассматриваемых здесь целей, поведение динамического объекта может описываться упрощенным разностным уравнением вида:

$$(2) \quad x[n] = \sum_{i=1}^m a_i x[n-i] + by[n-1].$$

Это уравнение отражает минимум данных, необходимых для воспроизведения прямой динамики объекта. Дальнейшее его упрощение приведет к резкому ухудшению качества воспроизведения. Для получения дискретной инверсной модели динамического объекта запишем уравнение (2) относительно $y[n]$:

$$(3) \quad y[n] = \frac{x[n+1] - \sum_{i=0}^{m-1} a_i x[n-i]}{b},$$

где $x[n+1]$ – желаемое значение выхода объекта на $n+1$ шаге.

Поскольку уравнения (2) и (3) являются теоретической реализацией дискретных прямых и инверсных моделей динамических объектов, то по их структуре можно судить о требованиях к формированию входного вектора и структуре ИНС решающих подобные задачи. А именно, входной вектор ИНС должен содержать как минимум m задержанных значений выхода объекта. Поскольку преобразования, выполняемые уравнениями (2) и (3) (взвешенная сумма составляющих входного вектора) соответствуют преобразованиям, выполняемым линейной сетью (адалин), то применение для этих целей более сложных ИНС с нелинейными активационными функциями можно считать избыточным. Здесь необходимо уточнить, что эти положения в полном объеме справедливы лишь для тех объектов, динамика которых с достаточной точностью может описываться линейными разностными уравнениями. Если удовлетворительной точности такого описания можно добиться лишь при помощи нелинейных уравнений, то и ИНС, скорее всего, придется использовать нелинейную.

3. Синтез инверсных моделей и систем управления

3.1. Теоретическая часть

По структурам уравнений (2) и (3) видно, что состояние динамического объекта определяется не только текущим значением на его выходе, но и некоторой совокупностью его задержанных значений, количество которых связано с порядком непрерывной передаточной функции динамического объекта. Это достаточно очевидно, тем не менее, разработчики систем управления динамическими объектами иногда пренебрегают этим правилом, особенно в отношении формирования целевого состояния системы управления [2]. Ведь если текущее состояние динамического объекта определяется вектором, содержащим некоторую предысторию процесса, то и состояние, в которое необходимо перевести этот объект, должно определяться вектором близкой размерности. Следовательно, в общем случае, формулировка задачи управления, представленная как: за h дискрет перевести объект из состояния $A\{x[n], x[n-1], \dots, x[n-m]\}$ в состояние,

заданное значением $x_r[n+h]$ (рис. 2), является недоопределенной. Действительно, в момент времени $n+h$ состояние системы, описываемое вектором $B\{x[n+h], x[n+h-1], \dots, x[n+h-m]\}$, даже при выполнении условия $x[n+h]=x_r[n+h]$, может иметь бесконечное число вариантов значений $x[n+h-1], \dots, x[n+h-m]$ и соответствовать совершенно различным динамическим режимам (торможение, разгон, колебательность и т.д.).

Естественно, что ИНС, или любой другой дискретный вычислительный механизм, имея в исходных данных текущее состояние A и целевое значение на выходе объекта $x_r[n+h]$, имеет излишнюю вариантность при вычислении управляющего воздействия, и часто именно она не позволяет достичь действительной цели управления. Как правило, при синтезе систем нейруправления пытаются бороться с проявлениями этой свободы (обычно ведущей к нежелательной колебательности переходного процесса), а не с ее причинами. Отметим, что далеко не каждая дискретная система управления нуждается в таком способе задания целевых векторов в явном виде. Кроме этого, при управлении объектами первого порядка, состояние которых определяется вектором, содержащим одно задержанное значение выхода объекта, описанная выше проблема отсутствует.

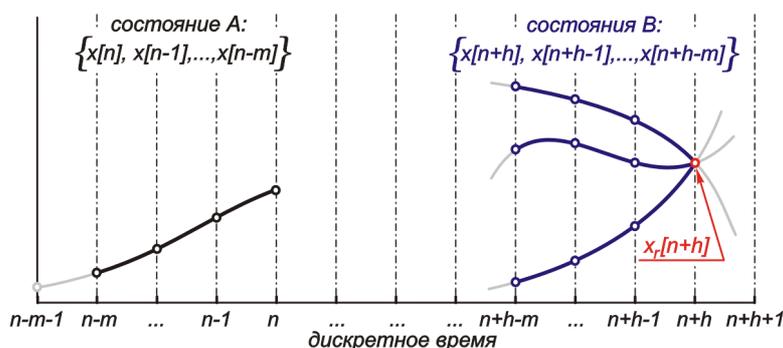


Рис. 2. Вариантность движения объекта управления.

3.2. От классических к прогнозирующим инверсным моделям динамических объектов

Перед тем как перейти к структурным схемам синтеза классических и предлагаемых в работе прогнозирующих инверсных нейросетевых моделей объектов управления, рассмотрим эти задачи на наглядном примере. На рис. 3 представлена выборка, снятая с динамического объекта второго порядка ($m=2$). Эта выборка состоит из некоторого случайного дискретного тестового сигнала y на входе объекта и соответствующей этому сигналу реакции $x(t)$ объекта управления. Так как, в соответствии с вышеизложенным, дискретное состояние динамического объекта определяется вектором размерностью m , то и каждое из дискретных состояний выхода объекта изображено в виде вектора.

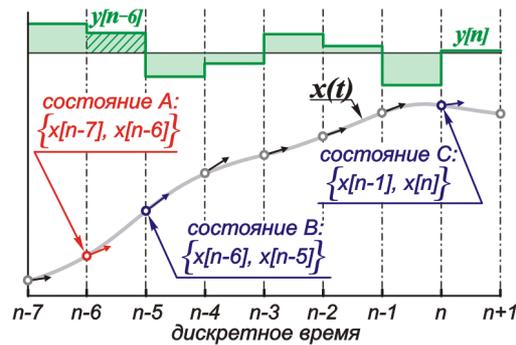


Рис. 3. Пояснения к схемам идентификации инверсных моделей динамических объектов.

Рассмотрим задачу синтеза классической инверсной модели динамического объекта. Такая модель позволяет восстановить управляющее воздействие на входе объекта по его текущему и заданному желаемому состоянию на выходе. Рассмотрим два состояния А и В в дискретные моменты времени $n-6$ и $n-5$. Пусть состояние А является текущим, а В заданным (целевым). Тогда управляющее воздействие $y[n-6]$ и есть то значение, которое в идеальном случае определит модель инверсной динамики этого объекта, поскольку именно под его воздействием был выполнен переход от состояния А к состоянию В:

$$y[n-6] = ИНС(A, B) = ИНС(x[n-7], x[n-6], x[n-5]).$$

Процесс обучения инверсной модели этого объекта является поиском именно такой функциональной зависимости, но по всей выборке, т.е. в общем случае поиск зависимости:

$$(4) \quad y[n] = ИНС(x[n+1], x[n], x[n-1], \dots, x[n-m]),$$

где m -порядок динамического объекта. Запись (4) полностью соответствует структуре дискретного инверсного разностного уравнения (3), рассмотренного ранее.

Далее, с помощью этого же рисунка, рассмотрим принцип построения предлагаемых прогнозирующих инверсных моделей динамических объектов. Так же как и в предыдущем случае, прогнозирующая инверсная модель служит для вычисления управляющего воздействия на входе объекта по его текущему и желаемому состоянию на выходе. Но, в соответствии с ранее изложенными принципами построения прогнозирующих систем управления, это управление должно перевести объект из текущего состояния в желаемое не одним управляющим воздействием, а некоторой их последовательностью, в интервале, равном горизонту прогноза λ . Напомним, что сколь бы далеким не был горизонт прогноза, и, соответственно, прогнозируемая серия управляющих воздействий, востребованным является лишь первое управляющее воздействие из этой серии, подаваемое на объект.

Рассмотрим переход из состояния А в состояние С. Отметим, что если в предыдущем случае состояние В опережало состояние А на одну дискрету, то в этом случае состояние С опережает во времени состояние А на 6 дискрет. Пусть состояние А является текущим, а состояние С является желаемым через 6 дискрет управления. Такая задача полностью соответствует одной из возможных реализаций прогнозирующего управления, рассмотренной ранее (рис. 2, (б)). Очевидно, что если бы эта задача решалась средствами такой прогнозирующей системы, то, в идеальном случае, найденная ею серия управляющих воздействий полностью соответствовала бы серии управлений $y[n-6] \dots y[n-1]$, под

воздействием которой был в действительности выполнен этот переход. Соответственно $y[n-6]$ – есть то управление, которое такая идеальная система прогнозирующего управления вычислила бы по представленным ей исходным данным о текущем A и целевом C состояниях. Для нейросетевой аппроксимации такого закона прогнозирующего управления необходимо найти зависимость:

$$y[n-6] = ИНС(A, C) = ИНС(x[n-7], x[n-6], x[n-1], x[n]).$$

В общем виде эта запись будет выглядеть:

$$(5) \quad y[n] = ИНС(x[n], \dots, x[n-m], x[n+\lambda], \dots, x[n+\lambda-m]),$$

где λ – величина горизонта прогноза.

3.3. Пример синтеза классической и прогнозирующей инверсной модели динамического объекта

Рассмотрим структурные схемы синтеза классических и прогнозирующих инверсных нейросетевых моделей на примере объекта второго порядка с передаточной функцией:

$$(6) \quad W_{ov}(p) = \frac{1}{p^2 + 0.5p + 1}.$$

На рис. 4, (а) представлена классическая схема обучения модели инверсной динамики. Эта схема соответствует структуре разностного уравнения (3), поскольку ИНС в ней представлена адалином. На рис. 3, (б) представлена схема обучения прогнозирующей инверсной модели для этого же объекта. В этой схеме ИНС так же представлена адалином. Дискретность обеих схем $\Delta t=0.01$ с, что отражено в настройках экстраполяторов нулевого порядка, присутствующих в этих схемах.

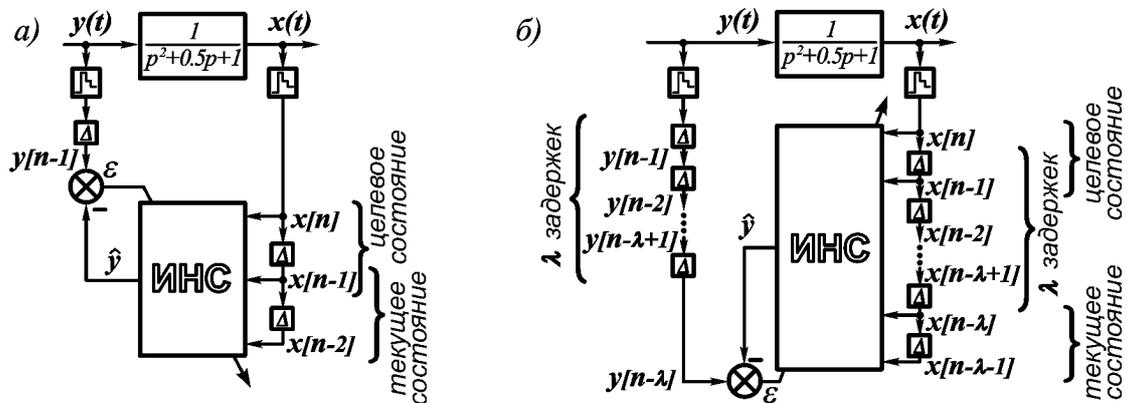


Рис. 4. Синтез нейросетевых моделей обратной динамики.

Обе представленные схемы соответствуют аналитическим выражениям (4) и (5). Для того, чтобы избавиться от необходимости в информации из «будущего» присутствующей в этих записях, с помощью элементов задержки выполнена подмена «настоящего» на «будущее», а «прошлого» на «настоящее».

Можно отметить, что классическую схему синтеза моделей обратной динамики можно считать частным случаем схемы синтеза прогнозирующих обратных моделей, поскольку при горизонте прогноза $\lambda=1$ прогнозирующая обратная модель превращается в классическую.

Оценим качество обучения классических и прогнозирующих моделей. Для этого поместим обученную классическую нейросетевую модель обратной дина-

мики в схему подготовки обучающего множества на рис. 4, (а). На рис. 5, (а) показан тестовый входной сигнал $y[n-1]$, соответствующая этому сигналу реакция объекта $x[n]$ и соответствующий этой реакции восстановленный нейросетью входной сигнал объекта $\hat{y}[n]$. Результат тестирования: высокая точность, что выражается в совпадении графиков фактического и восстановленного сетью входного сигнала по сигналу с выхода объекта.

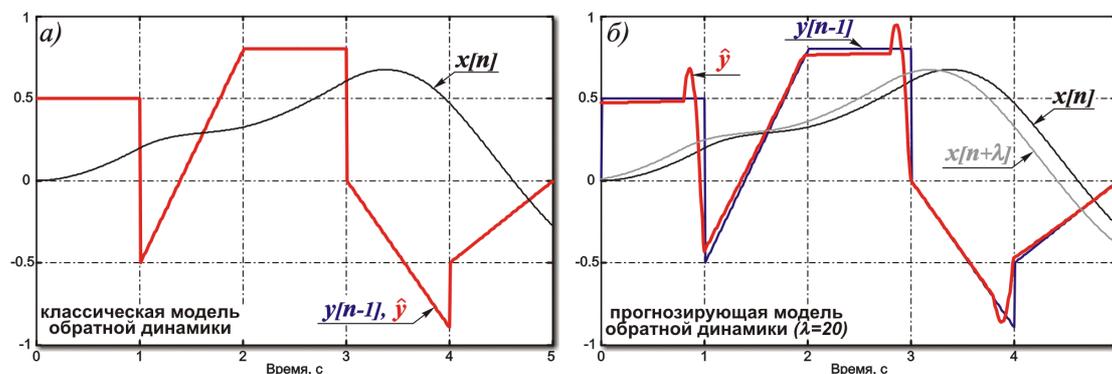


Рис. 5. Тестирование моделей обратной динамики.

Выполним аналогичный эксперимент для тестирования прогнозирующей модели обратной динамики. Примем величину горизонта прогноза равную 20 дискретам, что соответствует 0.2 с. Результат эксперимента представлен на рис. 5, (б). На этом рисунке $x[n]$ – текущий выход объекта, $x[n+\lambda]$ – желаемый выход объекта через λ дискрет, а $\hat{y}[n]$ – восстановленное нейронной сетью первое управляющее воздействие на пути перехода от состояния $x[n]$ к состоянию $x[n+\lambda]$. Необходимо отметить, что для этого объекта, принятой дискретности и горизонте прогноза $\lambda=10\dots12$, точность нейросетевого воспроизведения тестового входного воздействия соизмерима с точностью предыдущего эксперимента. Снижение качества воспроизведения по мере роста параметра λ обусловлено возрастанием возможных комбинаций последовательностей управляющих воздействий, переводящих выход объекта из состояния $x[n]$ в состояние $x[n+\lambda]$. Из-за такого многообразия возможных переходов сеть восстанавливает некоторое обобщенное управляющее воздействие, и это, естественно, влияет на точность воспроизведения конкретного тестового сигнала. Опыты показали, что прогнозирующие способности возрастают пропорционально значению горизонта прогноза λ , а точность регулирования при этом не снижается. Значение параметра λ может достигать величин, соизмеримых с постоянной времени объекта регулирования.

3.4. Системы управления на основе классических и прогнозирующих моделей инверсной динамики объектов управления: численные эксперименты и анализ

3.4.1. Структурные схемы непосредственного инверсного управления (direct inverse control). Рассмотрим схемы управления, построенные на основе представленных моделей обратной динамики (рис. 6).

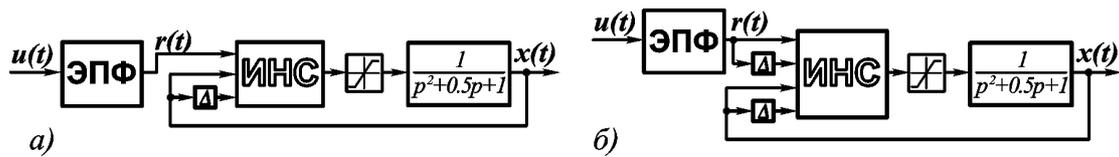


Рис. 6. Структурные схемы систем управления на основе моделей обратной динамики: а) с классической моделью обратной динамики; б) с прогнозирующей моделью обратной динамики.

За исключением используемых в них нейросетевых моделей обратной динамики представленные схемы тождественны. Один и тот же объект (6), одна и та же дискретность $\Delta t = 0.01$, одинаковые уровни ограничения амплитуды управляющего сигнала ± 1 и одинаковые эталонные передаточные функции (ЭПФ):

$$W_{\text{ЭПФ}}(p) = \frac{1}{p+1}.$$

Из-за наличия в этих схемах функции ограничения амплитуды управляющего сигнала, которая в большинстве последующих экспериментов имеет существенное влияние, эти системы управления являются нелинейными.

Вопрос о способностях нелинейных ИНС к управлению нелинейными динамическими объектами уже давно перешел в плоскость вопроса о выборе адекватной методики нейроуправления и структуры ИНС. Поэтому, чтобы не загромождать работу еще и этими вопросами, рассмотрим отличия прогнозирующих моделей инверсной динамики от классических на примерах простых схем инверсного нейроуправления линейными объектами.

3.4.2. Управление колебательным звеном второго порядка: сравнение результатов. На рис. 7, (а) и 7, (б) показаны результаты функционирования представленных выше систем нейроуправления. Полученные результаты не следует рассматривать как подтверждение неспособности классических моделей обратной динамики к управлению рассматриваемым классом объектов. Они демонстрируют лишь проявление одной из основных проблем синтеза классических систем инверсного нейроуправления (рис. 7, (а)) и практически ее полное отсутствие в случае построения такой системы на основе прогнозирующей модели (рис. 7, (б)). Эту проблему можно сформулировать следующим образом. Известно, что для надежной работы ИНС необходимо обеспечить ее эксплуатацию в условиях близких к условиям, в которых эта сеть была обучена. Естественно, что динамические режимы колебательного объекта второго порядка, на которых, собственно, и было выполнено обучение, существенно отличаются от «навязываемых» этому объекту режимов инерционного звена первого порядка. К тому же, по отношению к тем условиям, в которых эксплуатируется ИНС в контуре управления, условия обучения можно считать идеализированными, поскольку на этапе обучения не учитываются ошибки управления на предыдущих тактах, возникающие в реальной системе управления. Эти ошибки могут быть вызваны как несовершенством самой нейросетевой модели обратной динамики, так и, например, ограничениями амплитуды управляющего сигнала или возмущающими воздействиями, что также вносит существенные отличия от идеализированных условий, в которых выполнялось обучение. Таким образом, основной сложностью синтеза систем классического нейросетевого инверсного управления является формирование таких условий функционирования ИНС, которые бы на каждом такте, с одной стороны как можно меньше отличались от

условий, в которых была обучена модель обратной динамики, а с другой стороны отвечали бы желаемым качественным показателям системы регулирования.

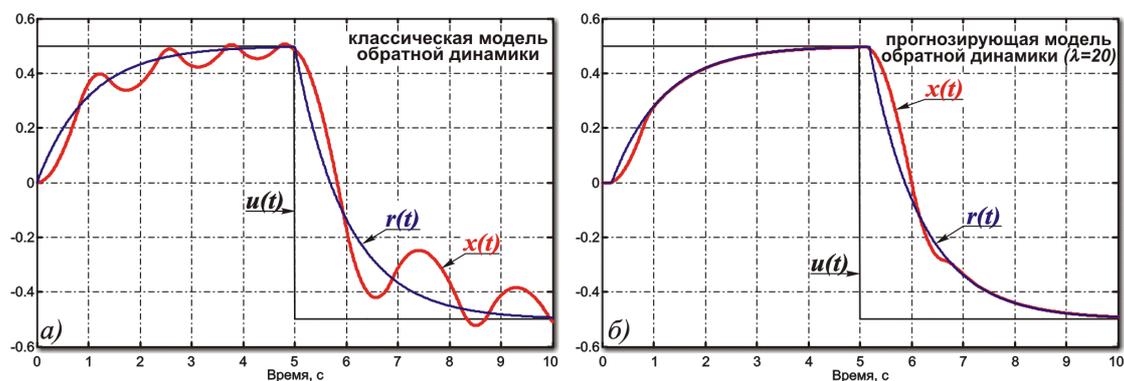


Рис. 7. Реакции нейросетевых систем управления объектом второго порядка.

Предлагаемый тип прогнозирующих моделей обратной динамики лишен этого недостатка, поскольку синтез систем на их основе не требует определения оптимального состояния выхода объекта управления на каждом шаге с учетом фактической динамики объекта и цели управления. На вход прогнозирующей модели подается некоторое желаемое состояние объекта, которое необходимо достичь на горизонте прогноза, и она уже сама в соответствии с динамикой объекта «выбирает» оптимальную стратегию управления, а соответственно и оптимальную последовательность состояний выхода объекта регулирования, точность отработки которых можно оценить по рис. 7, (б). Здесь необходимо отметить, что поскольку в принятом способе прогнозирующего управления, сигнал на выходе объекта регулирования запаздывает от сигнала выхода ЭПФ на горизонт прогноза λ , то для возможности оценки качества регулирования в визуализации этого и последующих экспериментов сигналы $r(t)$ с выхода ЭПФ сдвинуты по шкале времени на λ дискрет в «будущее».

3.4.3. Управление неустойчивым звеном третьего порядка. В следующем эксперименте рассмотрим качество управления неустойчивым линейным объектом третьего порядка:

$$(7) \quad W_{ov}(p) = \frac{1}{0.2p^3 + p^2 + 0.1p + 1}.$$

Общий вид схем нейроуправления этим объектом аналогичен виду схем показанных на рис. 6. В качестве эталонной передаточной функции примем апериодическое звено второго порядка:

$$W_{эф}(p) = \frac{1}{(p+1)(p+1)}.$$

Для этих экспериментов классическая и прогнозирующая модели инверсной динамики были получены в соответствии с теоретическим требованием размерности их входного вектора для объектов третьего порядка ($m=3$), которые соответственно равны $m+1$ и $2m$ входных линий. Величина горизонта прогноза λ при синтезе прогнозирующей модели, также как и в предыдущих экспериментах выбрана равной 20 дискретам.

На рис. 8, (а) и 8, (б) представлены результаты нейроуправления объектом (7). Здесь можно отметить, что задача выбора эталонной передаточной функции в системах классического инверсного нейроуправления усложняется с ростом

порядка объекта управления. В отличие от предыдущего эксперимента здесь динамика эталонной передаточной функции позволяет в условиях ограничения амплитуды управляющего сигнала реализовать эту же динамику на выходе объекта, что подтверждается результатом эксперимента на рис. 8, (б). Тем не менее, качество функционирования системы управления на основе классической инверсной модели трудно назвать удовлетворительным, в то время как точность функционирования этой же системы управления, но на основе прогнозирующей инверсной модели такова, что график выхода объекта практически совпадает с графиком выхода ЭПФ.

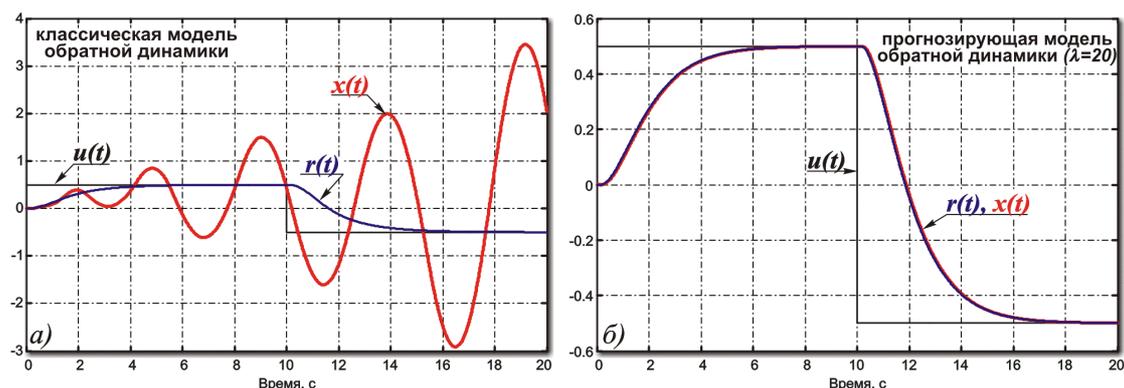


Рис. 8. Реакции нейросетевых систем управления объектом третьего порядка.

3.4.4. Работа в условиях возмущений. Выше отмечалось существенное влияние вида эталонной передаточной функций на качество регулирования классической системы инверсного управления. Рассмотрим эксперимент, в котором это влияние исключено. На рис. 9, (а) представлены результаты функционирования ранее рассмотренных систем управления объектом второго порядка (рис. 6). В отличие от предыдущих экспериментов в этом эксперименте на вход системы подается постоянное нулевое задание (тем самым исключается влияние выбора ЭПФ), но оказываются возмущающие воздействия $f(t)$ (рис. 9, (б)). Результаты этого эксперимента не требуют особых комментариев: очевидно преимущество системы основанной на прогнозирующей модели.

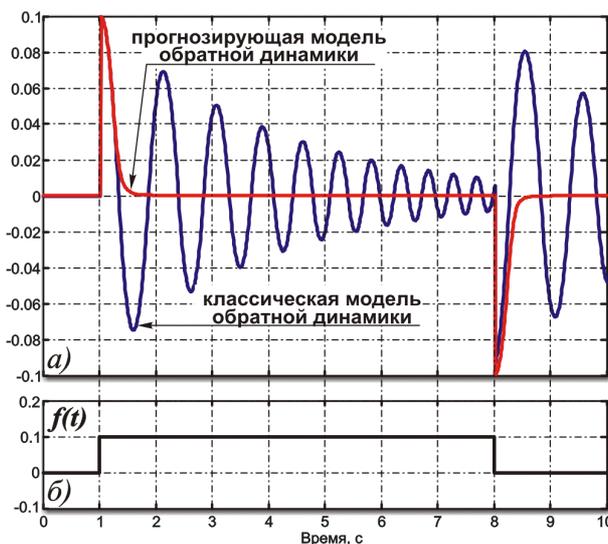


Рис. 9. Реакции систем нейроуправления на возмущающие воздействия.

3.4.5. Системы, в которых классическое инверсное управление не работает. Следующие эксперименты призваны продемонстрировать потенциал применения прогнозирующих инверсных моделей в существенно более жестких условиях, когда классические системы с инверсными моделями оказываются неработоспособными и поэтому теряют смысл, как база для сравнения. Эксперименты выполнены для объектов второго порядка (б) с глубиной прогноза $\lambda=50$ (0.5 с).

На рис. 10 представлен результат функционирования системы управления, изображенной на рис. 6, (б), но без блока ЭПФ (сигнал задания непосредственно подается на вход ИНС). В этом эксперименте качество переходного процесса обеспечивается исключительно благодаря прогнозирующим способностям инверсного регулятора без опоры на сигнал с выхода ЭПФ. С ростом значения горизонта прогноза λ вид переходного процесса приближается к аperiodическому, и если такой вид и является целью управления, то необходимость в ЭПФ постепенно отпадает.

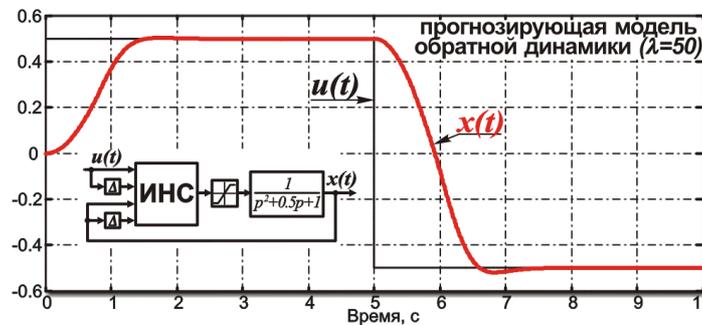


Рис. 10. Функционирование прогнозирующей системы управления без ЭПФ.

Следующий эксперимент демонстрирует способность прогнозирующих инверсных моделей решения задачи управления объектом с транспортным запаздыванием. На рис. 11 представлены результаты функционирования все той же схемы управления показанной на рис. 6, (б), но в этом случае в математическую модель объекта введено транспортное запаздывание, равное 0.2 секундам. Экспериментально выявлено, что для качественного функционирования не требуется точного знания величины запаздывания τ , достаточно лишь обеспечить выполнение условия $\lambda \cdot \Delta t > 2\tau$. Не смотря на наличие запаздывания в объекте, система прогнозирующего инверсного регулирования обеспечила совпадение прогнозируемых и фактических состояний объекта, что и демонстрируют результаты эксперимента на рис. 11.

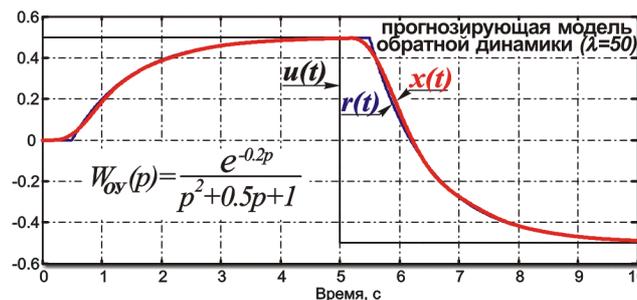


Рис. 11. Прогнозирующее управление объектом с запаздыванием.

4. Заключение

В работе предложен новый подход к синтезу САУ на основе нейросетевой идентификации инверсной динамики объекта управления с приданием полученной модели прогнозирующих свойств.

С позиции теории прогнозирующего управления (Model-Based Predictive Control), предложенный тип инверсных моделей сочетает в себе как функцию модели обратной динамики объекта управления, так и функцию процедуры оптимизации, что ведет не просто к экономии вычислительных ресурсов, но и к отсутствию зависимости затрат этих ресурсов от горизонта прогноза.

Предложенный подход значительно упрощает, формализует и унифицирует процедуру синтеза САУ.

С точки зрения требуемого объема априорных знаний, сложности подготовки обучающего множества и расчетных затрат на обучение ИНС, предложенные модели не отличаются от классических инверсных моделей.

На примере наиболее ярких из множества проведенных численных экспериментов показаны следующие положительные отличия представленного подхода:

- управление объектами высокого порядка, в том числе неустойчивыми;
- управление объектами при наличии существенных возмущающих воздействий;
- управление объектами с неопределенным запаздыванием.

За рамками настоящего изложения остались вопросы распространения предложенных подходов на существенно нелинейные и нестационарные системы, использования нелинейных ИНС, адаптации в реальном времени и ряд других важных аспектов, находящихся в настоящее время в процессе исследования.

В работе не был затронут вопрос о связи вида тестового управляющего сигнала, на основе которого выполняется обучение ИНС, со свойствами получаемой при этом прогнозирующей модели. Проведенные эксперименты показали наличие этой связи. Ее существование позволяет в рамках предложенного нейросетевого метода прогнозирующего управления, получать системы управления с различными свойствами.

Кроме этого, на основе расширенного варианта принципа построения прогнозирующих систем управления, упомянутого в данной работе, строятся системы управления с адаптивно изменяющимся значением горизонта прогноза, что позволит отказаться от использования эталонной функции в структуре системы управления, повысить ее быстродействие и значительно снизить динамические ошибки.

Список литературы

1. Терехов В. А., Ефимов Д. В., Тюкин И. Ю. Нейросетевые системы управления / Кн. 8: Учеб. Пособие для вузов. М.: ИПРЖР, 2002. 480 с.
2. Сигеру О., Марзуки Х., Рубия Ю. Нейроуправление и его приложения / Кн. 2. Пер. с англ. Н.В. Батина под ред. А. И. Галушкина, В.А. Птичкина. М.: ИПРЖР, 2000. 272 с.
3. Rossiter J.A.. Model-based predictive control: a practical approach. New York: CRC Press, 2003. 318 p.

4. Zmeu K.V., Shipitko E.A., Perevozchikov A.S. Linear Neural Model-Based Predictive Controller Design for Flexible Link Robot // Proceedings of the 2004 IEEE International Symposium on Intelligent Control (ISIC '04). Taipei: National Taiwan University, 2004. P. 293-298.