

К ВОПРОСУ МОДЕЛИРОВАНИЯ ДИНАМИКИ ПНЕВМОМЕХАНИЧЕСКОГО УСТРОЙСТВА

М.С. Зеленов
Н.В. Атамасов
А.В. Чернышев

mszelenov@gmail.com
n.atamasov@yandex.ru
av-chernyshev@yandex.ru

МГТУ им. Н.Э. Баумана, Москва, Российская Федерация

Аннотация

Рассмотрены этапы разработки искусственной нейронной сети (нейроэмулятора), предсказывающей изменение параметров состояния пневматической пружины, работающей в условиях изменяющейся внешней нагрузки. Приведенная математическая модель прогнозирования рабочих процессов служит для разработки нейросетевых алгоритмов управления пневматическими приводами. Для исследования эффективности данного подхода разработана программа обучения искусственной нейронной сети на основании обучающих выборок, полученных в вычислительных экспериментах с использованием математической модели рабочих процессов, построенной на базе дифференциальных уравнений первого порядка. Описаны структура примеров обучения и принципы формирования обучающих выборок. Обучение сети выполнено с помощью алгоритма Левенберга — Марквардта. Обученный нейроэмулятор проверен по результатам серий экспериментов со случайными начальными параметрами из заданной ограниченной области. Эффективность предсказания оценена по интегральному критерию — среднему коэффициенту детерминации, рассчитанному отдельно для каждой дальности прогноза и каждого выходного параметра модели — положения поршня, его скорости и перепада давлений между полостями пневматической пружины. По результатам сравнительных тестовых экспериментов выявлено совпадение данных, полученных с помощью двух математических моделей

Ключевые слова

Пневматические системы, прогноз динамики, нейронная сеть, нейроэмулятор, обучающая выборка, математическое моделирование

Поступила в редакцию 30.08.2018
© МГТУ им. Н.Э. Баумана, 2018

Принципы разработки нейросетевых регуляторов для позиционных пневматических приводов представлены в [1], где рассмотрены основные понятия теории нейронных сетей в применении к алгоритмам управления, обоснована настройка данного алгоритма по методу Левенберга — Марквардта, приведены этапы разработки алгоритма. Одним из этапов является разработка нейроэмулятора — искусственной нейронной сети (ИНС), моделирующей работу объекта управления. Целью его применения является определение инверсной функции объекта управления [2, 3], т. е. пневматического привода.

Предлагаемое применение нейронных сетей для моделирования динамического режима работы пневматического привода связано с простотой математического аппарата и его высокими возможностями при аппроксимации нелинейных зависимостей [4], которыми описываются механические и газодинамические процессы, протекающие в данных устройствах.

Для исследования эффективности такого подхода разработаны алгоритм и программа обучения ИНС, определяющей будущие значения переменных параметров пневмомеханического устройства на заданном временном интервале. Данные для обучения составлялись с помощью разработанной программы, выполняющей расчет рабочих процессов в пневмомеханическом устройстве с использованием математической модели, основанной на классических законах механики и газодинамики. В настоящей работе приведены результаты тестирования ИНС, полученной в результате обучения.

В качестве объекта моделирования выбран частный случай пневматического привода — пневматическая пружина. В таком устройстве динамические процессы зависят только от внутренних параметров состояния системы и внешней нагрузки. Расчетная схема пневматической пружины приведена на рис. 1. Это пневмомеханическое устройство представляет собой замкнутый цилиндрический корпус, внутри которого свободно перемещается поршень со штоком. Между корпусом, поршнем и штоком имеются уплотнительные устройства, препятствующие перетеканию газа между полостями А и В и окружающей средой. Параметры, описывающие данную расчетную схему:




Рис. 1. Расчетная схема пневматической пружины

$D_п$ — диаметр поршня; $d_ш$ — диаметр штока; $t_п$ — толщина поршня; l — полный ход поршня. Пружина закреплена вертикально на неподвижной поверхности.

В каждый момент времени динамика данной системы характеризуется следующими переменными параметрами: x — координата положения поршня относительно крайнего нижнего положения; v — скорость поршня; p_A , p_B — давление в полостях А и В; $F_н$ — сила внешней нагрузки, действующая на шток. Также на поршень со штоком действует сила тяжести $F_т$.

Согласно второму закону Ньютона, динамика движения поршня в данной системе описывается следующим уравнением:

$$m \frac{d^2x}{dt^2} = F_т - F_т - F_н, \quad (1)$$

где m — масса поршня со штоком; $F_т = \frac{\pi}{4} (D_п^2 p_B - (D_п^2 - d_ш^2) p_A - d_ш^2 p_{атм})$ — сила давления газа; $F_т = mg$ — сила тяжести.

Следует отметить характерные отличия данных силовых факторов с точки зрения математического моделирования. Сила тяжести F_T — величина постоянная. Сила давления газа является внутренней переменной, зависящей от других внутренних переменных и от внешней нагрузки F_H , которая, в свою очередь, не зависит от параметров пневматической пружины и изменяется только в зависимости от внешних условий. Параметр F_H чаще всего изменяется неконтролируемым образом. Поэтому представляет интерес возможность прогнозирования динамического процесса работы устройства без использования данных о внешней нагрузке в явном виде.

Предположим, что внешняя нагрузка изменяется незначительно, а само изменение линейное: $dF_H / dt = \text{const}$.

Представим это выражение в конечных разностях:

$$F_{Hi} = 2F_{H(i-1)} - F_{H(i-2)}. \quad (2)$$

Поскольку скорость поршня может быть определена как производная положения, то выражение (1) можно переформулировать в конечных разностях следующим образом:

$$m \frac{v_{(i+1)} - v_i}{\Delta t} = F_{Ti} - F_T - F_{Hi}. \quad (3)$$

Из выражений (2) и (3) можно определить скорость поршня на следующей итерации:

$$v_{(i+1)} = 3v_i - 3v_{(i-1)} + v_{(i-2)} + \frac{\Delta t}{m} (F_{Ti} - 2F_{T(i-1)} + F_{T(i-2)}). \quad (4)$$

На основании зависимости (4) и в результате анализа расчетной схемы для разработки программы моделирования динамики пневмомеханического устройства были выбраны следующие параметры: положение x , скорость v и разность давлений между полостями ($p_A - p_B$), а число запоминаемых шагов равно трем. Тогда в общем виде разрабатываемую зависимость можно представить как

$$\begin{aligned} x_{(i+1)} &= f_1 \left(\begin{matrix} x_i, v_i, (p_A - p_B)_i, x_{(i-1)}, v_{(i-1)}, (p_A - p_B)_{(i-1)} \\ x_{(i-2)}, v_{(i-2)}, (p_A - p_B)_{(i-2)} \end{matrix} \right); \\ v_{(i+1)} &= f_2 \left(\begin{matrix} x_i, v_i, (p_A - p_B)_i, x_{(i-1)}, v_{(i-1)}, (p_A - p_B)_{(i-1)} \\ x_{(i-2)}, v_{(i-2)}, (p_A - p_B)_{(i-2)} \end{matrix} \right); \\ (p_A - p_B)_{(i+1)} &= f_3 \left(\begin{matrix} x_i, v_i, (p_A - p_B)_i, x_{(i-1)}, v_{(i-1)}, (p_A - p_B)_{(i-1)} \\ x_{(i-2)}, v_{(i-2)}, (p_A - p_B)_{(i-2)} \end{matrix} \right), \end{aligned} \quad (5)$$

где i — номер шага расчета.

Алгоритм и программа обучения ИНС. В соответствии с приведенной зависимостью для прогнозирования значений переменных параметров пневмо-

механического устройства на следующих шагах требуется использовать ИНС с обратными связями. Общий вид подобной сети приведен на рис. 2, а. Данный тип ИНС называется сетью Джордана [5, 6].

На рис. 2 приняты следующие обозначения: $Y = (y_1, \dots, y_M)$ — вектор выходных сигналов размерности M ; $U = (u_1, \dots, u_S)$ — вектор внешних сигналов размерности S ; $W^{<1>}$, $W^{<2>}$ — матрицы весовых коэффициентов первого и второго перехода; $Q = M + S$ — размерность вектора входных сигналов; R — число нейронов входного слоя.

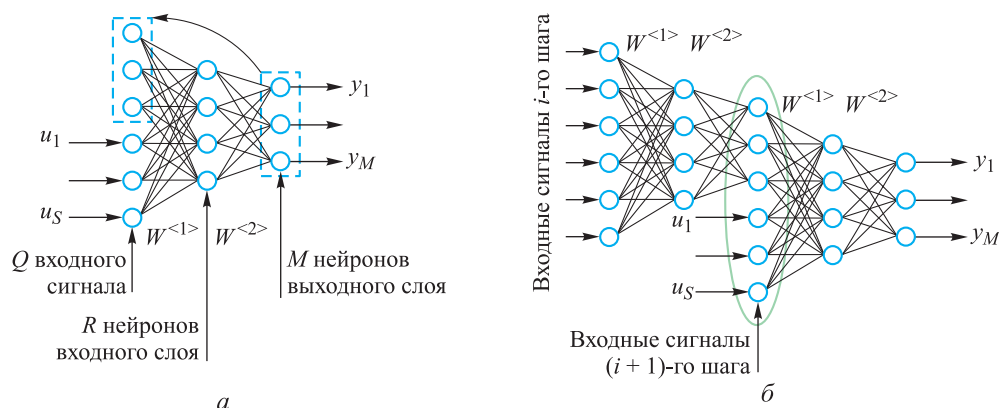


Рис. 2. Общий вид ИНС Джордана с одной обратной связью (а) и прямого прохождение (б)

Обучение ИНС представляет собой поиск минимума целевой функции в пространстве весовых коэффициентов. В настоящем исследовании в качестве целевой функции выбрано среднеквадратическое отклонение выходных сигналов ИНС от требуемых выходных сигналов:

$$C = \frac{1}{2PMN} \sum_i^P \sum_j^N \sum_k^M (D_{i,j,k} - Y_{i,j,k})^2,$$

где $D_{i,j}$ — вектор требуемых выходных сигналов j -го шага i -го обучающего примера; $Y_{i,j}$ — вектор выходных сигналов ИНС j -го шага i -го обучающего примера; P — число примеров в обучающей выборке; N — число шагов в i -м примере обучающей выборки; M — число элементов вектора выходных сигналов.

Для обучения ИНС применен алгоритм Левенберга — Марквардта [7, 8]. Данный алгоритм является итерационным, и на каждом шаге новый комплект весовых коэффициентов определяется по формуле

$$W_{n+1}^* = W_n^* - (J_n^T J_n + \mu I) J_n^T e_n,$$

где $W_n^* = (W_{n,1}, W_{n,2}, \dots, W_{n,A})$ — вектор весовых коэффициентов, рассчитанных на n -й итерации обучения (вектор формируется из элементов матриц весовых коэффициентов всех переходов);

$$e = \begin{pmatrix} D_{1,1,1} - Y_{1,1,1} \\ D_{1,1,2} - Y_{1,1,2} \\ \dots \\ D_{1,1,M} - Y_{1,1,M} \\ D_{1,2,1} - Y_{1,2,1} \\ \dots \\ D_{1,2,M} - Y_{1,2,M} \\ \dots \\ D_{1,N,M} - Y_{1,N,M} \\ D_{2,1,1} - Y_{2,1,1} \\ \dots \\ D_{P,N,M} - Y_{P,N,M} \end{pmatrix}$$

— вектор абсолютных отклонений выходных сигналов ИНС относительно выходных сигналов, описанных в обучающей выборке;

$$J = \begin{pmatrix} \frac{\partial e_{1,1,1}}{\partial W_{n,1}^*} & \frac{\partial e_{1,1,1}}{\partial W_{n,2}^*} & \dots & \frac{\partial e_{1,1,1}}{\partial W_{n,A}^*} \\ \frac{\partial e_{1,1,2}}{\partial W_{n,1}^*} & \frac{\partial e_{1,1,2}}{\partial W_{n,\dots,2}^*} & \dots & \frac{\partial e_{1,1,2}}{\partial W_{n,A}^*} \\ \dots & \dots & \dots & \dots \\ \frac{\partial e_{1,1,M}}{\partial W_{n,1}^*} & \frac{\partial e_{1,1,M}}{\partial W_{n,2}^*} & \dots & \frac{\partial e_{1,1,M}}{\partial W_{n,A}^*} \\ \frac{\partial e_{1,2,1}}{\partial W_{n,1}^*} & \frac{\partial e_{1,2,1}}{\partial W_{n,2}^*} & \dots & \frac{\partial e_{1,2,1}}{\partial W_{n,A}^*} \\ \dots & \dots & \dots & \dots \\ \frac{\partial e_{1,2,M}}{\partial W_{n,1}^*} & \frac{\partial e_{1,2,M}}{\partial W_{n,2}^*} & \dots & \frac{\partial e_{1,2,M}}{\partial W_{n,A}^*} \\ \dots & \dots & \dots & \dots \\ \frac{\partial e_{1,N,M}}{\partial W_{n,1}^*} & \frac{\partial e_{1,N,M}}{\partial W_{n,2}^*} & \dots & \frac{\partial e_{1,N,M}}{\partial W_{n,A}^*} \\ \frac{\partial e_{2,1,1}}{\partial W_{n,1}^*} & \frac{\partial e_{2,1,1}}{\partial W_{n,2}^*} & \dots & \frac{\partial e_{2,1,1}}{\partial W_{n,A}^*} \\ \dots & \dots & \dots & \dots \\ \frac{\partial e_{P,N,M}}{\partial W_{n,1}^*} & \frac{\partial e_{P,N,M}}{\partial W_{n,2}^*} & \dots & \frac{\partial e_{P,N,M}}{\partial W_{n,A}^*} \end{pmatrix}$$

— матрица Якоби; μ — регулирующий параметр; I — единичная матрица.

Общая блок-схема обучения ИНС по алгоритму Левенберга — Марквардта приведена на рис. 3.

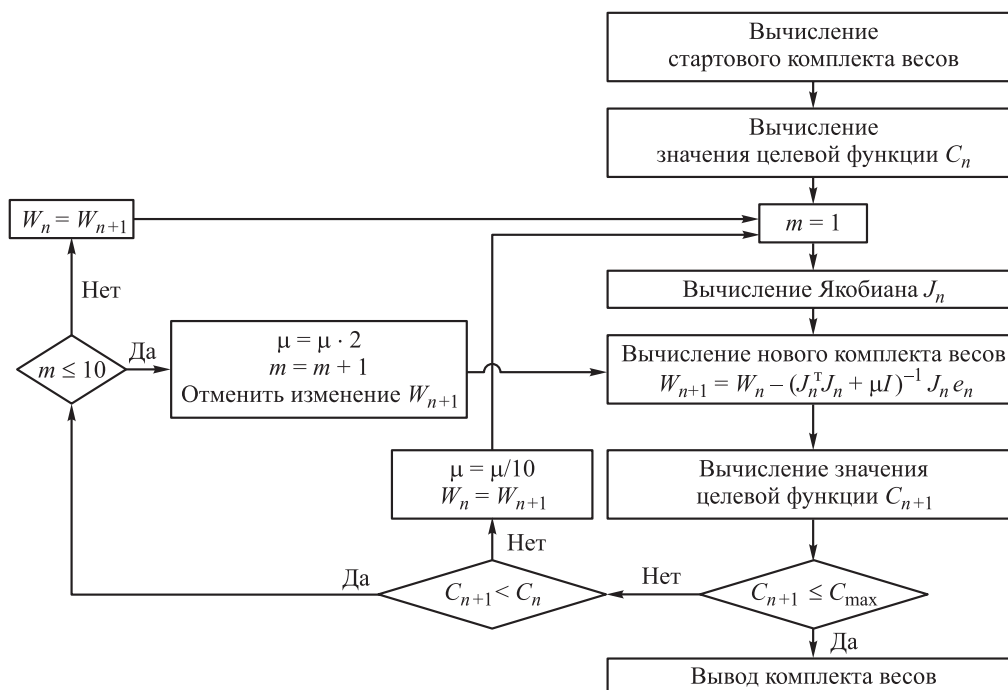


Рис. 3. Общая блок-схема обучения ИНС по алгоритму Левенберга — Марквардта

Основная сложность заключается в вычислении матрицы Якоби, поскольку при использовании структуры Джордана каждый весовой коэффициент влияет на выходные сигналы ИНС не только напрямую, но и через контуры обратных связей. Для вычисления элементов матрицы сеть Джордана приведена к виду ИНС прямого прохождения (рис. 2, б) и разработан алгоритм расчета производных.

Для трехслойной ИНС, представленной на рис. 2, формулы для вычисления производных имеют вид

$$\frac{\partial e_k}{\partial W_{k,r}^{<2>}} = f'_{2,k}(z) \left(f_{1,r}(z) + \sum_{r=1}^R \left(W_{k,r}^{<2>} f'_{1,r}(z) \sum_{q=1}^Q \left(W_{r,q}^{<1>} \frac{\partial X_q}{\partial W_{k,r}^{<2>}} \right) \right) \right)$$

— для весовых коэффициентов второго перехода $W^{<2>}$;

$$\frac{\partial e_k}{\partial W_{r,q}^{<1>}} = f'_{2,k}(z) \sum_{r=1}^R \left(W_{k,r}^{<2>} f'_{1,r}(z) \left(X_q + \sum_{q=1}^Q \left(W_{r,q}^{<1>} \frac{\partial X_q}{\partial W_{r,q}^{<1>}} \right) \right) \right)$$

— для весовых коэффициентов первого перехода $W^{<1>}$,

где $f_{2,k}(z)$ и $f_{1,r}(z)$ — функции активации выходного и входного слоя;

$$\mathbf{X} = \begin{pmatrix} y_1 \\ \dots \\ y_M \\ u_1 \\ \dots \\ u_S \end{pmatrix}$$

— вектор входных сигналов, в котором (y_1, \dots, y_M) — выходные сигналы предыдущего шага, а (u_1, \dots, u_S) — внешние сигналы.

Поскольку в ИНС имеется обратная связь, то весовые коэффициенты влияют на значения входных сигналов, подаваемых с выхода ИНС. Для внешних сигналов производная по весовым коэффициентам равна нулю:

$$\frac{\partial X}{\partial W_i} = \begin{pmatrix} \frac{\partial y_1}{\partial W_i} \\ \dots \\ \frac{\partial y_M}{\partial W_i} \\ 0 \\ \dots \\ 0 \end{pmatrix}.$$

На основании данных зависимостей и алгоритма Левенберга — Марквардта разработана программа обучения ИНС с возможностью следующих регулировок: числа параметров состояния, равного M — числу выходных сигналов ИНС; числа обратных связей N и внешних параметров S ; типа функции активации: сигмоидальная и тангенциальная; числа нейронов в каждом слое.

Структура сети описывается выражением

$$Q : B_1 : B_2 : \dots : B_{K-1} : M,$$

где $Q = MN + S$ — число входных сигналов; B_1, B_2, \dots, B_{K-1} — количество нейронов в 1, 2, ..., $K-1$ слоях соответственно; M — число выходных сигналов.

Данный алгоритм обучения был протестирован на тривиальной задаче предсказания значений тригонометрических функций, объединенных в систему:

$$\begin{aligned} y_1 &= a \sin(x); \\ y_2 &= a \cos(x). \end{aligned}$$

В рамках поставленных условий для каждой рассчитываемой последовательности параметр $a \in [-1; 1]$ выбирался случайным образом и оставался неизменным в течение всего расчета. Для тестового обучения выбрана ИНС с тангенциальными функциями активации и со структурой 7 : 10 : 10 : 2, в которой 7 — число

входных сигналов (значения функций y_1 и y_2 на предыдущих трех шагах и внешний параметр a). Обучение проводилось на основании выборки объемом 4140 примеров с горизонтом предсказания на 3 шага. Размер шага 3° . В результате было достигнуто значение целевой функции $C = 3,1 \cdot 10^{-6}$. Тестирование полученных результатов обучения выполнялось на 300 последовательностях длиной 360° со случайным выбором стартового значения x и параметра $a \in [-1; 1]$. Точность моделирования оценивалась по среднему коэффициенту детерминации для каждой функции и для каждой дальности прогноза отдельно. Формула расчета коэффициента детерминации имеет вид

$$R_{k,p}^2 = 1 - \frac{\sum_i^P \sum_j^N (D_{i,j,k,p} - Y_{i,j,k,p})^2}{\sum_i^P \sum_j^N (D_{i,j,k,p} - \overline{D_{i,k,p}})^2}, \quad (6)$$

где P — число экспериментов; N — число точек в одном эксперименте; M — число элементов вектора выходных сигналов; $\overline{D_{i,k,p}}$ — среднее значение параметра $D_{k,p}$ в i -м эксперименте.

Данный коэффициент изменяется в пределах $[-\infty; 1]$ и характеризует адекватность построенной модели по отношению к тестовым данным. В случае $R^2 = 1$ предсказание является абсолютно точным; в случае $R^2 = 0$ можно сказать, что предсказательная способность модели совпадает в каждом эксперименте с предсказательной способностью простейшей постоянной функции $y_k = \overline{d_k}$; в случае $R^2 \rightarrow \infty$ построенная модель может считаться абсолютно неадекватной.

В результате моделирования получены значения коэффициентов детерминации, приведенные в табл. 1.

Таблица 1

Значения коэффициентов детерминации R^2

Параметр	R^2 при прогнозе		
	на 1 шаг	на 2 шага	на 3 шага
y_1	0,999	0,999	0,999
y_2	0,999	0,999	0,999

Программа для составления обучающих и тестовых выборок данных, описывающих динамические процессы в пневматической пружине. Проведенные тесты на тривиальной задаче показали работоспособность разработанной программы обучения ИНС. Для проведения исследований пневматической пружины с использованием этой программы необходимы данные, описывающие ряд динамических процессов. В соответствии с зависимостью (5) в течение некоторого промежутка времени записываются значения положения и скорости поршня и разность давлений между полостями A и B . Для проведения ис-

следования эти значения получены на основании вычислительных экспериментов. Для их проведения разработана программа с использованием математической модели рабочих процессов, протекающих в пневматической пружине. В данной модели приняты следующие допущения [9]: для описания параметров рабочего тела в полостях использовано приближение сосредоточенных параметров; рабочее тело — идеальный газ; газодинамические процессы в полостях считаются изотермическими; сила трения не учитывается.

Закон перемещения поршня описывается уравнением (1). Для определения слагаемых в данном уравнении требуется найти давление воздуха в полостях в каждый момент времени. На основании принятых допущений и закона сохранения энергии для закрытой термодинамической системы давление в полости можно описать уравнением

$$\frac{dp}{dt} = \frac{pS}{V} \frac{dh}{dt},$$

где S , V и h — эффективная площадь поршня, объем и длина полости.

В соответствии с данной зависимостью изменение давления в полостях A и B зависит от скорости поршня в каждый момент времени:

$$\frac{dp_A}{dt} = \frac{p_A S_A}{V_A} v;$$

$$\frac{dp_B}{dt} = -\frac{p_B S_B}{V_B} v.$$

Зависимость для расчета скорости имеет вид

$$\frac{dv}{dt} = -g + \frac{F_H}{m} + \frac{\pi}{4m} (D_{II}^2 p_B - (D_{II}^2 - d_{III}^2) p_A - d_{III}^2 p_{атм}).$$

В модели также учитывается наличие мертвого объема в полостях пружины и эффект отскока при соударении поршня о торцевые стенки цилиндра при достижении крайнего положения.

Для имитационного моделирования процессов использован итерационный метод Эйлера, и на его основе разработана программа расчета рабочих процессов в пневматической пружине. Шаг по времени составляет 0,01 мс, что обусловлено погрешностью численного метода. Расчет выполняли с использованием начальных данных о положении поршня, его скорости и давлении в полостях.

Обучение ИНС строится на основании примеров. В данном случае под примером понимается соответствие между вектором входных сигналов и последовательностью векторов выходных сигналов, описывающих изменения параметров пневматической пружины на некоторое время вперед. В качестве шага по времени между двумя последовательными итерациями выбран интервал 5 мс. В соответствии с выведенной зависимостью (5), число стартовых входных сигналов в каждом примере равно девяти. Число выходных сигналов на каждой

итерации равно трем. Число элементов в последовательности групп выходных сигналов в каждом примере выбрано равным трем, т. е. ИНС должна предсказывать поведение пневматической пружины через 5, 10 и 15 мс.

Для качественного обучения ИНС требуется группа примеров (выборка), описывающих пространство состояний параметров системы. Определение объема обучающей выборки является сложной задачей, поскольку недостаточный объем снижает качество обучения, а чрезмерный объем увеличивает продолжительность обучения. Отобранные примеры должны полно характеризовать пространство состояний, поскольку поведение ИНС в «слепых» зонах непредсказуемо. Однако в случае выявления таких зон сеть может быть дообучена с их учетом, что является важной особенностью такого метода моделирования.

Результаты каждого вычислительного эксперимента зависят от стартового состояния системы и параметров внешней нагрузки. Перед выполнением экспериментов ограничивается область стартовых значений параметров:

$$x_0 \in [0; l]; \quad v_0 \in [-v_{\max 0}; v_{\max 0}]; \\ p_{A0} = [1 \text{ атм}; p_{\max 0}]; \quad p_{B0} = [1 \text{ атм}; p_{\max 0}].$$

В очерченной области равномерно распределяются точки $(x_0, v_0, p_{A0}, p_{B0})$, число которых равно N^4 , где N — число точек разбиения в каждом указанном интервале. Сила внешней нагрузки для каждого эксперимента определяется случайным образом и характеризуется двумя параметрами: стартовым значением $F_{H0} \in [-F_{\max 0}; F_{\max 0}]$ и коэффициентом изменения нагрузки $k \in [-k_{\max}; k_{\max}]$. Помимо данного множества точек выборка может быть дополнена характерными точками, по выбору оператора.

Для каждой точки проводится вычислительный эксперимент длительностью 70 мс, в течение которых с шагом 5 мс записываются значения параметров $x, v, (p_A - p_B)$. Для работы с ИНС с тангенциальными функциями активации значения входных и выходных сигналов должны быть пронормированы. Функция нормировки [10] для каждого из параметров имеет вид

$$y_{\text{норм}i} = 0,9 \frac{2y_i - y_{\max} - y_{\min}}{(y_{\max} - y_{\min})},$$

где y_i — значение параметра; $y_{\text{норм}i}$ — нормированное значение параметра; y_{\max}, y_{\min} — максимальное и минимальное значения параметра, полученные в результате моделирования. Все значения параметра y принадлежат интервалу $[-0,9; 0,9]$.

Нормированный массив данных обрабатывается процедурой формирования примеров обучения для приведения к указанному ранее формату. Комплект примеров обучения перемешивается и делится на две части. Первая часть (две трети от первоначального числа примеров) представляет собой обучающую выборку, а вторая (оставшаяся треть) — тестовую выборку.

Обучение ИНС, предсказывающей поведение пневматической пружины.

Для обучения ИНС, позволяющей предсказывать значения параметров пневматической пружины через 5, 10 и 15 мс, проведен комплекс из 1727 вычислительных экспериментов. Область стартовых значений параметров ограничена следующим образом:

$$x_0 \in [0; 200] \text{ мм}; v_0 \in [-0,5; 0,5] \text{ м/с}; p_{A0} = [1; 2] \text{ атм}; p_{B0} = [1; 2] \text{ атм}.$$

Параметры внешней нагрузки: $F_{H0} \in [-32; 32] \text{ Н}$ и $k \in [-20; 20] \text{ Н/с}$.

Использование заявленных процедур позволило сформировать обучающую выборку из 7258 примеров и тестовую выборку из 3629 примеров.

Для обучения выбрана ИНС с тангенциальными функциями активации и структурой 9 : 20 : 8 : 3. Обучение ИНС на их основе проводилось до достижения среднеквадратической погрешности на обучающей выборке $C_{об} = 1,67 \cdot 10^{-4}$. При этом отсутствие переобучения отслеживалось по среднеквадратической погрешности на тестовой выборке. К моменту окончания обучения $C_{тест} = 1,54 \cdot 10^{-4}$.

Тестирование полученных результатов обучения выполнялось на 300 экспериментах продолжительностью 0,3 с. На рис. 4 приведен типовой график изменения положения поршня, а также прогноз положения на один, два и три шага вперед.

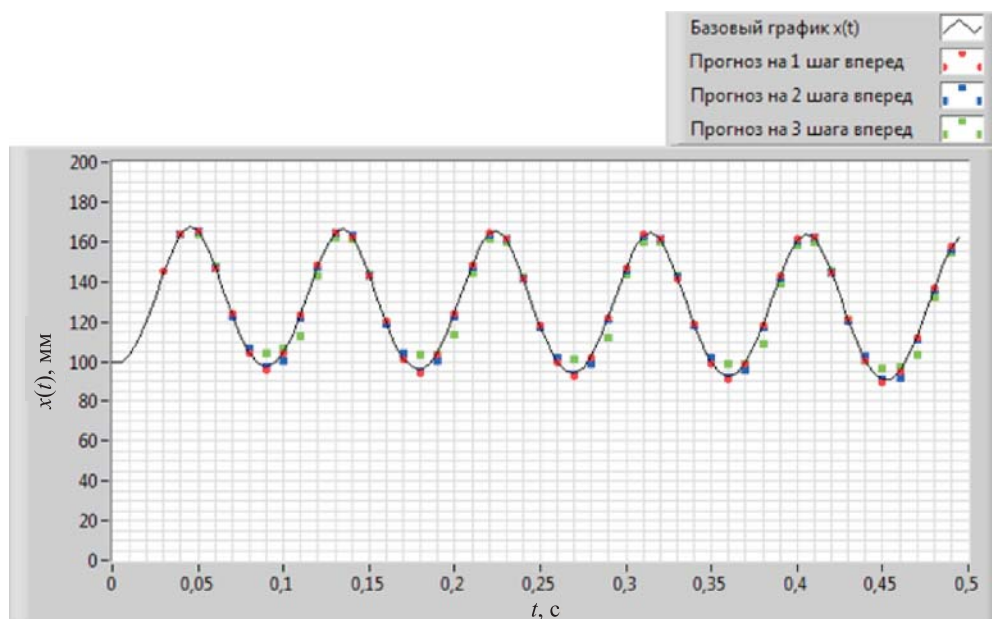


Рис. 4. Типовой график изменения положения поршня с фронтами предсказания положения на один-три шага вперед

Точность моделирования оценивалась по среднему коэффициенту детерминации R^2 (6), который рассчитывался для каждого параметра и на каждую глубину прогноза отдельно (табл. 2).

Средние значения коэффициента детерминации R^2

Параметр	R^2 при прогнозе		
	на 1 шаг	на 2 шага	на 3 шага
Положение x	0,993	0,994	0,96
Скорость v	0,995	0,991	0,95
Разность давлений ($p_A - p_B$)	0,994	0,985	0,928

Выводы. В результате проведенных исследований и моделирования динамики пневмомеханического устройства с использованием ИНС обоснована структура входного сигнала для ИНС, предсказывающей поведение пневматической пружины, работающей при условии линейно изменяющейся внешней нагрузки;

– описаны принципы обучения нейронной сети на основании результатов численного моделирования пневматической пружины;

– проведено обучение нейронной сети со структурой Джордана, предсказывающей поведение пневматической пружины на три итерации расчета вперед.

Близкие к единице значения коэффициента детерминации при сравнении двух математических моделей рабочих процессов в пневматической пружине (первая — основанная на классических законах механики и газодинамики; вторая — основанная на математическом аппарате ИНС) позволяют сделать вывод о возможности использования ИНС при исследовании пневмомеханических устройств. Применение данного подхода упрощает определение зависимости управляющих воздействий от требуемых выходных параметров объекта управления.

ЛИТЕРАТУРА

1. Зеленов М.С., Чернышев А.В., Крылов В.И. О принципах разработки нейросетевых регуляторов для позиционных пневматических приводов // Компрессорная техника и пневматика. 2017. № 4. С. 28–33.
2. Елисеев В.Л. Разработка и исследование нейросетевых алгоритмов управления стационарными и нестационарными объектами. Дисс. ... канд. техн. наук. М.: МЭИ, 2012. 208 с.
3. Сигеру Омату, Марзуки Халид, Рубия Юсоф. Нейроуправление и его приложения. М.: ИПРЖР, 2000. 272 с.
4. Горбань А.Н. Обобщенная аппроксимационная теорема и вычислительные возможности нейронных сетей // Сиб. журн. вычисл. матем. 1998. Т. 1. № 1. С. 11–24.
5. Mohajerin N. Identification and predictive control using recurrent neural networks: International Master's Thesis. Sweden, Örebro, 2012. 103 p.
6. Mańdziuk J., Mikołajczak R. Chaotic time series prediction with feed-forward and recurrent neural nets // Control and Cybernetics. 2002. Vol. 31. No. 2. P. 383–406.
7. Друки А.А. Алгоритмы нейросетевого детектирования и распознавания символов на сложном фоне. Дисс. ... канд. техн. наук. Томск: ТПУ, 2015. 216 с.
8. Hao Yu. Marquardt training // Industrial electronics handbook. Intelligent systems. Vol. 5. CRC Press, 2011. P. 12-1–12-15.

9. Зеленов М.С., Чернышев А.В. Разработка математической модели позиционного электропневматического привода // Сб. докл. Восьмой Всеросс. конф. молодых ученых и специалистов. 2015. С. 609–610.

10. Бураков М.В. Нейронные сети и нейроконтроллеры. СПб.: ГУАП, 2013. 284 с.

Зеленов Михаил Сергеевич — аспирант кафедры «Вакуумная и компрессорная техника» МГТУ им. Н.Э. Баумана (Российская Федерация, 105005, Москва, 2-я Бауманская ул., д. 5, стр. 1).

Атамасов Никита Владимирович — аспирант кафедры «Вакуумная и компрессорная техника» МГТУ им. Н.Э. Баумана (Российская Федерация, 105005, Москва, 2-я Бауманская ул., д. 5, стр. 1).

Чернышев Андрей Владимирович — д-р техн. наук, профессор кафедры «Вакуумная и компрессорная техника» МГТУ им. Н.Э. Баумана (Российская Федерация, 105005, Москва, 2-я Бауманская ул., д. 5, стр. 1).

Просьба сослаться на эту статью следующим образом:

Зеленов М.С., Атамасов Н.В., Чернышев А.В. К вопросу моделирования динамики пневмомеханического устройства // Вестник МГТУ им. Н.Э. Баумана. Сер. Машиностроение. 2018. № 6. С. 20–33. DOI: 10.18698/0236-3941-2018-6-20-33

ON THE ISSUE OF SIMULATING DYNAMICS OF A PNEUMO-MECHANICAL DEVICE

M.S. Zelenov

N.V. Atamasov

A.V. Chernyshev

mszelenov@gmail.com

n.atamasov@yandex.ru

av-chernyshev@yandex.ru

Bauman Moscow State Technical University, Moscow, Russian Federation

Abstract

The paper considers the stages of developing an artificial neural network (a neural emulator) that predicts variation in parameters of state for a pneumatic spring operating under variable external loads. We present a mathematical model for predicting work cycles that is used to develop neural network algorithms for controlling pneumatic drives. In order to investigate the efficiency of this approach, we developed a program of artificial neural network training based on training datasets derived from numerical experiments using the work cycle model built on the basis of first-order differential equations. We describe the training sample structure and the principles behind generating training datasets. We used the Levenberg — Marquardt algorithm to train our network and tested the trained neural emulator on the results of series of experiments with random initial parameters taken from a specific bounded domain. We estimated prediction efficiency by an integral criterion: the average coefficient of determination, computed separately

Keywords

Pneumatic systems, dynamics prediction, neural network, neural emulator, training dataset, mathematical simulation

for each prediction distance and every model output parameter, such as piston position, piston velocity and pressure difference between the pneumatic spring chambers. Comparative test experiment results show that the data obtained by means of two mathematical simulations match

Received 30.08.2018

© BMSTU, 2018

REFERENCES

- [1] Zelenov M.S., Chernyshev A.V., Krylov V.I. In reference to the neural control system development for position pneumatic drive. *Kompressornaya tekhnika i pnevmatika*, 2017, no. 4, pp. 28–33 (in Russ.).
- [2] Eliseev V.L. Razrabotka i issledovanie neyrosetevykh algoritmov upravleniya statsionarnymi i nestatsionarnymi ob"ektami. Diss. kand. tekhn. nauk [Development and study on control algorithms for stationary and non-stationary objects. Cand. tech. sc. diss.]. Moscow, MEI Publ., 2012. 208 p.
- [3] Sigeru Omatu, Marzuki Khalid, Rubiyah Yusof. Neuro-control and its applications. Springer, 1996. 255 p. DOI: 10.1007/978-1-4471-3058-1
- [4] Gorban' A.N. Generalized approximation theorem and computational capabilities of neural networks. *Sib. zhurn. vychisl. matem.*, 1998, vol. 1, no. 1, pp. 11–24 (in Russ.).
- [5] Mohajerin N. Identification and predictive control using recurrent neural networks: International Master's Thesis. Sweden, Örebro, 2012. 103 p.
- [6] Mańdziuk J., Mikołajczak R. Chaotic time series prediction with feed-forward and recurrent neural nets. *Control and Cybernetics*, 2002, vol. 31, no. 2, pp. 383–406.
- [7] Druki A.A. Algoritmy neyrosetevogo detektirovaniya i raspoznavaniya simvolov na slozhnom fone. Diss. kand. tekhn. nauk [Neural network detection and recognition algorithms for symbols on complex ground. Cand. tech. sc. diss.]. Tomsk, TPU Publ., 2015. 216 p.
- [8] Hao Yu. Marquardt training. In: Industrial electronics handbook. Intelligent systems. Vol. 5. CRC Press, 2011. P. 12-1–12-15.
- [9] Zelenov M.S., Chernyshev A.V. [Mathematical model development for positioning electro-pneumatic drive]. *Sb. dokl. Vos'moy Vseross. konf. molodykh uchenykh i spetsialistov* [Proc. 8th Russ. Conf. of Young Scientists and specialists]. 2015, pp. 609–610 (in Russ.).
- [10] Burakov M.V. Neyronnye seti i neyrokontrollery [Neural networks and controllers]. Sankt-Petersburg, GUAP Publ., 2013. 284 p.

Zelenov M.S. — post-graduate student, Department of Vacuum and Compressor Technology, Bauman Moscow State Technical University (2-ya Baumanskaya ul. 5, str. 1, Moscow, 105005 Russian Federation).

Atamasov N.V. — post-graduate student, Department of Vacuum and Compressor Technology, Bauman Moscow State Technical University (2-ya Baumanskaya ul. 5, str. 1, Moscow, 105005 Russian Federation).

Chernyshev A.V. — Dr. Sc. (Eng.), Professor, Department of Vacuum and Compressor Technology, Bauman Moscow State Technical University (2-ya Baumanskaya ul. 5, str. 1, Moscow, 105005 Russian Federation).

Please cite this article in English as:

Zelenov M.S., Atamasov N.V., Chernyshev A.V. On the Issue of Simulating Dynamics of a Pneumo-Mechanical Device. *Vestn. Mosk. Gos. Tekh. Univ. im. N.E. Baumana, Mashinostr.* [Herald of the Bauman Moscow State Tech. Univ., Mech. Eng.], 2018, no. 6, pp. 20–33 (in Russ.). DOI: 10.18698/0236-3941-2018-6-20-33