

А. Н. Поляков, д-р техн. наук, проф., e-mail: anp_temos@mail.ru,
В. В. Позевалкин, аспирант, e-mail: pozevalkinvv@mail.ru,
Оренбургский государственный университет

Применение нейронной сети прямого распространения к прогнозированию тепловых характеристик станков*

Представлена методика исследования устойчивости результатов моделирования на основе искусственной нейронной сети применительно к тепловым характеристикам металлорежущих станков. Методика базируется на предложенной базовой математической модели, основанной на модальном подходе. Представлена архитектура типового программного средства, разработанного для изучения эффективности моделирования искусственной нейронной сети. Приведены результаты натурного и машинного экспериментов.

Ключевые слова: искусственная нейронная сеть, машинный эксперимент, тепловые характеристики станков, модальные параметры

Введение

Современные станки с ЧПУ используют методы искусственного интеллекта на различных этапах их жизненного цикла. Так, на этапе их проектирования методы искусственного интеллекта позволяют создавать оптимальную конфигурацию несущей системы станка, учитывающую относительные движения инструмента и заготовки [1]. На этапе эксплуатации и проведения опытно-конструкторских работ для достижения высокого уровня надежности станков создают различные системы диагностики, построенные на интеллектуальных моделях на основе нейронных сетей [2, 3]. Для компенсации флуктуации мощности резания, обусловленной традиционными факторами при механической обработке (колебания припуска и неоднородность механических свойств обрабатываемого материала), создают системы стабилизации на основе искусственных нейронных сетей [4, 5].

Сегодня современное высокотехнологичное производство активно использует высокоскоростные станки с ЧПУ. Применение современных систем смазывания, систем охлаждения, новых материалов, инновационных конструкторских решений позволяет создавать станки, работающие с большими скоростями резания. Однако даже сегодня проблема температурной погрешности станков остается актуальной и является предметом исследований и поиска новых технических и технологических разработок. Например, при испытании высоко-

скоростного обрабатывающего центра горизонтальной компоновки HDBS-63 (DALIAN MACHINE TOOLS GROUP Corp., КНР) даже на небольших частотах вращения (3000 мин^{-1}) была зафиксирована избыточная температура на переднем конце моторизованного шпинделя около $22 \text{ }^\circ\text{C}$ и температурные смещения в осевом направлении около 35 мкм [6]. На максимальной частоте вращения шпинделя $24\,000 \text{ мин}^{-1}$ температурные смещения в осевом направлении составили более 110 мкм .

Особое место в достижении точности обработки на станках с ЧПУ занимают исследования в области систем компенсации температурной погрешности станков, создаваемых на основе искусственных нейронных сетей [7–15]. По разным оценкам применение таких систем позволяет сокращать до 80% температурной погрешности станка, а в отдельных случаях их эффективность еще выше. Так, в работе [15] приведен результат компенсации температурной погрешности токарного обрабатывающего центра, что позволило уменьшить температурные смещения шпинделя от 19 до 1 мкм . Таким образом, снижение температурной погрешности станков с ЧПУ является одной из приоритетных задач современного высокотехнологичного производства, а применение методов искусственного интеллекта, в частности, искусственных нейронных сетей, в области обеспечения теплоустойчивости станков является одним из эффективных направлений решения этой задачи. Искусственные нейронные сети характеризуются тремя базовыми проблемами: необходимостью наличия экспериментальной базы данных, используемой для обучения сети; необходимостью применения

*Исследование выполнено при финансовой поддержке РФФИ в рамках научного проекта № 20-38-90045.

оптимизационной процедуры для отыскания весовых коэффициентов нейронов; необходимостью выбора среди многообразия архитектур искусственных нейронных сетей. Эти проблемы не позволяют безоговорочно говорить о превосходстве методов искусственного интеллекта над традиционными методами. Поэтому время от времени появляются исследования, посвященные анализу эффективности нейросетевых моделей, по сравнению, например, с регрессионным [16].

Необходимость использования нейросетевых технологий в режиме реального времени для управления станками накладывает строгие ограничения на однозначность генерируемых нейронной сетью результатов. Поэтому в данной работе было проведено исследование устойчивости получаемых решений по построению тепловых характеристик станка с ЧПУ на основе нейросетевой модели. Ранее построение таких моделей проводилось в работах [17, 18]. Были получены локальные результаты, которые не позволили выявить закономерности формирования устойчивого решения для построения тепловых характеристик.

1. Постановка задачи исследования устойчивости решения нейронной сети при построении тепловых характеристик станков

Несмотря на разнообразие архитектур искусственных нейронных сетей [19, 20] практика их применения к решению задач аппроксимации и прогнозирования показала, что сети прямого распространения с одним скрытым слоем нейронов достаточно эффективны. Поэтому в данном исследовании рассмотрена только одна архитектура искусственной нейронной сети.

Принятая архитектура нейронной сети. Многослойная сеть прямого распространения состоит из трех слоев: входного, одного скрытого и одного выходного. Входной сигнал распространяется только в прямом направлении. Для обучения сети используется алгоритм обратного распространения ошибки. Каждый нейрон скрытого слоя имеет сигмоидальную функцию активации. В этом случае выход нейрона может быть представлен в виде

$$y_j = \frac{1}{1 + \exp(-v_j)}, \quad (1)$$

где v_j — индуцированное локальное поле нейрона j .

При этом индуцированное локальное поле нейрона j для n -й итерации обучения сети имеет вид

$$v_j(n) = \sum_{i=1}^{m_1} w'_{ji}(n)x_i(n) + b_{1j}, \quad (2)$$

где m_1 — общее число входов; $x_i(n)$ — входной сигнал; $w'_{ji}(n)$ — вес синапса в скрытом слое; b_{1j} — значение смещения для нейрона скрытого слоя.

Выходной слой построен на одном линейном нейроне и описывается выражением

$$y_j(n) = \sum_{i=1}^{m_2} w''_{ji}(n)z_i(n) + b_{2j}, \quad (3)$$

где m_2 — число нейронов выходного слоя; $z_i(n)$ — входной сигнал для нейрона выходного слоя, который описывается выражением (1); $w''_{ji}(n)$ — вес синапса в выходном слое; b_{2j} — значение смещения для нейрона скрытого слоя.

В результате обучения сети генерируются веса синапсов и смещения для обоих слоев и соответствующих нейронов на основе выражений (2) и (3). Используемый при обучении сети алгоритм обратного распространения ошибки позволяет минимизировать функцию ошибки обучения вида

$$E = \frac{1}{2N} \sum_{n=1}^N \sum_{k=1}^M (d_k(n) - y_k(n))^2, \quad (4)$$

где N — число эпох или итераций обучения сети; M — число нейронов выходного слоя; $d_k(n)$ — желаемый отклик сети; $y_k(n)$ — фактический отклик сети.

2. Методы решения поставленной задачи

Особенности реализации тепловой модели станка. Для решения проблемы теплоустойчивости конкретного станка его тепловая модель может быть представлена своими тепловыми характеристиками [21].

Без учета запаздывания тепловая характеристика в конкретной точке несущей системы станка для температуры может быть представлена в виде

$$T_{ij}(t_j) = \sum_{k=1,4,\dots,3m-2} x_{k,i}(1 - e^{-t_j/x_{k+1,i}}) + \sum_{k=1,4,\dots,3m-2} x_{k+2,i} e^{-t_j/x_{k+1,i}}, \quad (5)$$

$$i = 1, \dots, N; j = 1, \dots, L,$$

где $x_{k,i}$, $x_{k+1,i}$, $x_{k+2,i}$ — модальные параметры; m — число температурных мод; i — номер датчика температуры; t_j — отдельный интервал времени, в который проводились измерения;

N — общее число термодатчиков; L — число интервалов времени, составляющих рассматриваемый диапазон времени $t \in [t_1, t_L]$.

Для температурных перемещений тепловая характеристика имеет вид

$$\delta_n(t_j) = \sum_{k=1,4,\dots,3m-2} x_{k,n} (1 - e^{-t_j/x_{k+1,n}}) + \sum_{k=1,4,\dots,3m-2} x_{k+2,n} e^{-t_j/x_{k+1,n}}, \quad (6)$$

где n может принимать значения X, Y, Z ; $\delta_n(t_j)$ — оцениваемое координатное перемещение вдоль оси n .

В выражениях (5), (6) модальные параметры для любой k -й моды с подстрочным первым индексом "1" соответствуют амплитуде соответствующей k -й экспоненциальной функции (максимальному значению этой функции или соответствующему значению ординаты ее асимптоты). Модальные параметры с подстрочным первым индексом "2" соответствуют тепловой постоянной времени. Начальный уровень соответствующей функции описывается модальным параметром с подстрочным первым индексом "3".

Вид выражений (5) и (6) объясняет выбор входного и выходного сигналов для нейронной сети. Представим множество наблюдаемых и прогнозируемых интервалов времени единым вектором t :

$$t = \{0, t_1, \dots, t_m, t_{m+1}, \dots, t_L\}, \quad (7)$$

где t_m — предельный момент времени, для которого сформирована обучающая выборка; t_L — предельный момент времени прогнозирования.

Аналогичные векторы можно сформировать для температур и температурных перемещений

$$T = \{0, T_1, \dots, T_m, T_{m+1}, \dots, T_L\} \\ \text{и } \delta = \{0, \delta_1, \dots, \delta_m, \delta_{m+1}, \dots, \delta_L\}, \quad (8)$$

где T_m и T_L — значения температуры в моменты времени t_m и t_L .

Если принять в качестве входного сигнала вектор t , а в качестве выходного сигнала принять или вектор температуры или вектор температурных перемещений, то при успешном решении с помощью нейронной сети задачи прогнозирования это позволит решить известную задачу сокращения длительности натурального эксперимента [22].

Скользящее окно. Очевидно, что в качестве входного сигнала можно принять вектор температуры или температурных перемещений вида

$$T = \{0, T_1, \dots, T_m\} \text{ или } \delta = \{0, \delta_1, \dots, \delta_m\}, \quad (9)$$

а в качестве выходного сигнала соответственно принять векторы вида

$$T = \{T_{m+1}, \dots, T_L\} \text{ и } \delta = \{\delta_{m+1}, \dots, \delta_L\}. \quad (10)$$

Для практической реализации (9) и (10) предложено использовать метод скользящего окна [23, 24]. Идея метода заключается в том, что задается некоторый интервал времени, в течение которого осуществляется наблюдение за процессом, в виде

$$t = \{0, t_1, \dots, t_m\}. \quad (11)$$

В течение этого интервала времени формируется вектор данных вида (9). Используя понятие скользящего окна, вводим ширину скользящего окна p , его смещение b и горизонт прогнозирования Γ . Ширина скользящего окна p соответствует длине вектора входных данных — известных значений температуры или температурных перемещений. Размер смещения окна b определяет длину вектора целей или выходного сигнала в архитектуре нейронной сети. Обобщенный вектор X длиной m с учетом параметров p и b можно представить в виде матрицы:

$$\{X\} \rightarrow [X] = \begin{bmatrix} x_1 & x_{1+b} & \dots & x_{m-b-p+1} \\ x_2 & x_{2+b} & \dots & x_{m-b-p+2} \\ \dots & \dots & \dots & \dots \\ x_p & x_{p+b} & \dots & x_{m-b} \\ x_{p+1} & x_{p+b+1} & \dots & x_{m-b+1} \\ \dots & \dots & \dots & \dots \\ x_{p+b} & x_{p+2b} & \dots & x_m \end{bmatrix}. \quad (12)$$

Выражение (12) позволяет перейти от вектора длиной m к матрице размера $[(p + b) \times q]$. Очевидно, что число столбцов q зависит от соотношений трех чисел: m, p, b . Так как число столбцов — это натуральное число, то при соответствующем соотношении чисел m, p, b для параметра q можно записать соотношение вида

$$q = (m - p)/b. \quad (13)$$

Таким образом, имеющаяся выборка экспериментальных данных длиной m разбивается на q пар векторов: длиной p и b . На практике это означает, что прогнозирование искомым значений температуры или температурных перемещений в некоторые последующие b -е моменты времени осуществляется по соответствующим

p -м предшествующим по времени значениям температур или температурных перемещений. На первом шаге процедуры после определения первых b значений температур или температурных перемещений окно смещается именно на это число значений в выборке. Тем самым, спрогнозированные b значений искомой функции теперь попадают внутрь скользящего окна и принадлежат входному вектору, а последующие b значений искомой функции предстоит спрогнозировать, и они принадлежат выходному вектору данных. Используемая структура данных приводит к изменению архитектуры сети: входной слой сети будет представлен p нейронами; выходной слой — b нейронами. Проведя обучение нейронной сети, можно сформировать горизонт прогнозирования Γ за пределы обучающей выборки длиной m . При этом, следуя изложенной выше концепции метода скользящего окна, каждые b элементов нового ряда Γ прогнозируются последовательно, а весь ряд Γ формируется итерационно с последовательным смещением на b элементов.

Результаты экспериментальных исследований. Чтобы сформировать представление о зависимости тепловых характеристик от начальных условий, на рис. 1–3 приведено по пять реализаций экспериментальных тепловых характеристик температур и температурных перемещений. Испытания проводились в разные дни. Кривые температуры и температурного перемещения, сформированные в одном испытании, имеют совпадающие номера. Тепловые характеристики приведены для двух частот вращения шпинделя: 2500 и 4000 мин^{-1} .

Анализ экспериментальных кривых показал, что существует разброс экспериментальных данных как для температур, так и температурных смещений. На рис. 3 приведены тепловые характеристики, сформированные по данным термодатчика, фиксирующего изменение температуры кабинетной системы станка, и зависящие только от флуктуации температуры среды, окружающей станок, но не зависящие от режимов его работы. Их анализ показал

отсутствие жесткой зависимости разброса экспериментальных данных по температуре или температурным перемещениям от флуктуации начальных условий.

Сглаживание тепловых характеристик. Особенностью использования электронных измерительных приборов в натуральных испытаниях является формирование ступенчатых тепловых характеристик. Это объясняется тем,




Рис. 1. Тепловые характеристики (температуры) для двух частот вращения шпинделя при различных начальных условиях:
 a — 2500 мин^{-1} ; b — 4000 мин^{-1}




Рис. 2. Тепловые характеристики (температурные перемещения вдоль оси Z) для двух частот вращения шпинделя при различных начальных условиях:
 a — 2500 мин^{-1} ; b — 4000 мин^{-1}




Рис. 3. Изменение начальных условий в процессе тепловых испытаний станка для двух частот вращения шпинделя при различных начальных условиях:
 a — 2500 мин^{-1} ; b — 4000 мин^{-1}

что опрос и запись измеренных данных в файл выполняется с фиксированным шагом по времени. Поэтому непосредственное использование этих данных для обучения сети может создавать дополнительную ошибку, не связанную с реализацией тепловых процессов в станке. Для минимизации этой ошибки предлагается использовать процедуру сглаживания тепловых характеристик.

Для экспериментальных тепловых характеристик процедура сглаживания эквивалентна известной процедуре аппроксимации. Выше выражениями (5) и (6) уже представлен вид функции, который описывает эти кривые.

Однако все неудобство этих функций заключается в большой неопределенности искомым коэффициентов, что порождает бесконечное множество решений [21, 22], в том числе и ошибочных. Поэтому для сглаживания экспериментальных кривых использована аппроксимация алгебраическими многочленами. В этом случае аппроксимирующая функция имеет вид

$$P_q(t) = \sum_{j=0}^q a_j t^j, \quad (14)$$

где $q \leq m - 1$ — степень полинома; m — число интервалов времени, в которые проводились измерения; t — аргумент аппроксимируемой функции (время).

Программное средство. Решение поставленной в работе задачи исследования устойчивости решения на основе нейросетевой модели для тепловых характеристик станка осуществлялось на основе машинного эксперимента. Для решения поставленной задачи было разработано программное средство (ПС) "Нейросетевое тепловое моделирование станков" в системе MATLAB. Главное окно ПС приведено на рис. 4. Архитектуру разработанного ПС можно отнести к слоистой. Каждый из слоев представляет собой комплекс программ, одинаковых по функциональности и на практике реализуемый в виде одного рабочего окна с элементами управления (рис. 4 и 5).

Основными модулями каждого слоя программ являются: модуль формирования исходных данных, расчетный модуль, модуль графического представления исходных данных, модуль графического и численного представления результатов обучения нейронной сети (промежуточный результат), модуль графического представления результатов имитационного моделирования сети для нового варианта данных в виде тепловых характеристик.

В качестве исходных данных для обучения нейронной сети могут использоваться экспериментальные данные, представляющие собой файл измеренных тепловых характеристик или температур в двенадцати точках несущей системы станка или температурных смещений

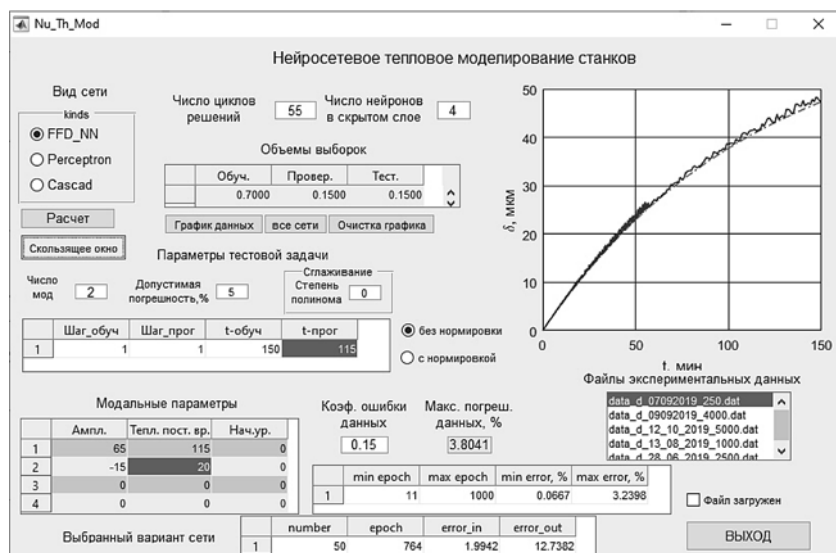


Рис.4. Главное окно программного средства "Нейросетевое тепловое моделирование станков"

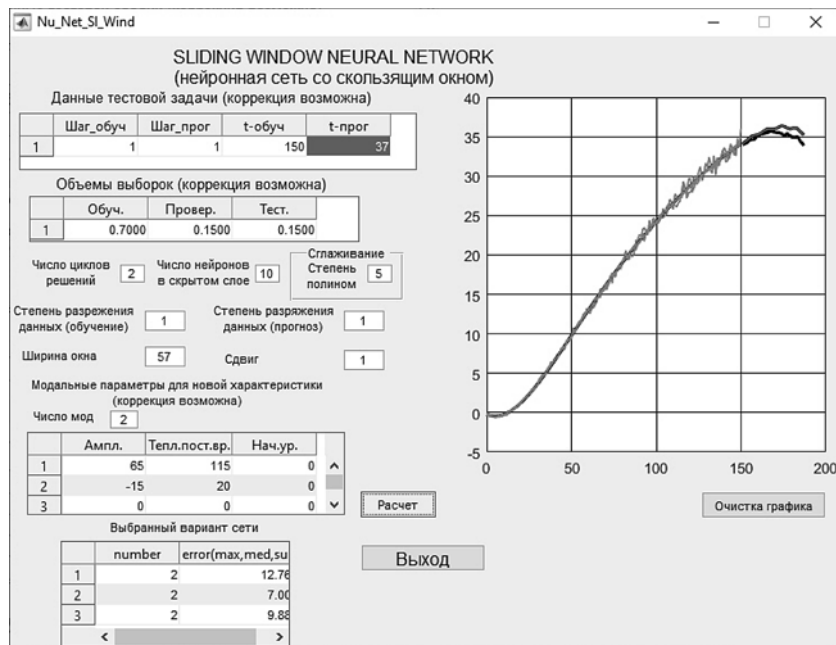


Рис. 5. Окно модуля "Скользящее окно"

шпиндельной головки, измеренных вдоль осей X , Y и Z . Погрешность исходных данных формируется автоматически из измерений. Также предусмотрено программное формирование исходных данных в соответствии с выражениями (5) и (6). В этом случае погрешность исходных данных задается программно.

С учетом этого коэффициента выражение (6) принимает вид

$$\delta_n(t_j) = \sum_{k=1,4,\dots,3m-2} x_{k,n} (1 - e^{-t_j/x_{k+1,n}}) + \sum_{k=1,4,\dots,3m-2} x_{k+2,n} e^{-t_j/x_{k+1,n}} + k\Delta_r t_j, \quad (15)$$

где Δr — случайная ошибка данных, генерируемая случайным образом, $\Delta r \in [0, 1]$, k — масштабный коэффициент.

Исходные данные, задаваемые в виде (15), позволяют однозначно задать погрешность исходных данных и, соответственно, однозначно определить погрешность моделирования и установить соответствующие зависимости.

При реализации метода скользящего окна из главного окна ПС вызывается новое программное средство (рис. 5), включающее несколько программных модулей.

Машинный эксперимент. Машинный эксперимент проводили для двух вариантов входных данных. Для первого варианта на вход нейросети подавали вектор времени, а выходом являлись температуры или перемещения (ранее их вид описан в уравнениях (7) и (8)).

Во втором варианте исследовали метод скользящего окна, поэтому входной и выходной векторы имели один физический смысл: температура или температурные перемещения. В данном машинном эксперименте в качестве входного и выходного векторов сети были использованы температурные перемещения.

Для каждого варианта входных данных сети проводилась вариация следующих параметров: число нейронов в скрытом слое; размер входного и выходного вектора; погрешность входных векторов; размер обучающей, проверочной и тестовой выборки; функциональные особенности тепловых характеристик, подаваемые на вход сети или их мультимодальность; наличие и отсутствие нормировки входного вектора.

Особенностью построения искусственной нейронной сети (ИНС) являлась их циклическая генерация. Для этого в программном средстве предусмотрен параметр "Число циклов решений". Наличие различных вариантов ИНС обусловлено тем, что синаптические веса и смещение для каждого нейрона сети опре-

деляются из решения задачи оптимизации. Симуляция ИНС применительно к прогнозированию тепловых характеристик станков показала, что сложно найти стабильные, мало различающиеся решения. Поэтому для выбора одного варианта ИНС предложено использовать два похожих критерия вида

$$Kp_1 = \frac{1}{N_\lambda} \sum_{\zeta=1}^{N_\lambda} [(\delta_{\text{пр},\zeta} - \delta_{\lambda,\zeta})/\delta_{\lambda,\zeta}] \cdot 100; \quad (16)$$

$$Kp_2 = \max\{[(\delta_{\text{пр},\zeta} - \delta_{\lambda,\zeta})/\delta_{\lambda,\zeta}]\} \cdot 100, \quad \zeta = \overline{1, N_\lambda}, \quad (17)$$

где $\delta_{\text{пр},\zeta}$, $\delta_{\lambda,\zeta}$ — прогнозные (по ИНС) и расчетные значения температурного перемещения; N_λ — число прогнозируемых элементов вектора $\delta_{\text{пр},\zeta}$.

Аналитические исследования и практика тепловых испытаний показали, что после 100 мин непрерывной работы станка все высокочастотные моды, характеризующиеся малым значением тепловой постоянной времени, уже не оказывают влияние на кинетику формирования тепловой характеристики [21, 22]. Поэтому в любой точке тепловой характеристики справедливо:

$$y = A_1(1 - e^{-\lambda_1 t}) + B_1 e^{-\lambda_1 t} + C + \varepsilon, \quad (18)$$

где A_1 , B_1 — амплитуда и начальный уровень первой температурной моды в физических координатах исследуемой функции y ; λ_1 — обратное значение тепловой постоянной времени первой моды; C — сумма амплитуд всех высокочастотных мод; ε — небольшая погрешность, обусловленная продолжающимися во времени процессами стабилизации высокочастотных мод.

Учитывая малость величины ε для станков с температурной погрешностью, существенно большей одного микрона, этой величиной можно пренебречь. Тогда можно аналитически определить тепловую постоянную времени тепловой характеристики как обратное значение от λ_1 по известным значениям ординаты тепловой характеристики в моменты времени t_1 и t_2 :

$$\lambda_1 = \ln(Y_1/Y_2)/(t_2 - t_1), \quad (19)$$

где $Y_1 = (A_1 + C - y_1)/(A_1 - B_1)$ и $Y_2 = (A_1 + C - y_2)/(A_1 - B_1)$.

Моменты времени t_1 и t_2 выбираются на участке тепловой характеристики, используемой для обучения сети, а момент времени t_2 разграничивает этот участок и участок прогнозирования. В этом случае любое прогно-

зируемое значение исследуемой функции y_3 в момент времени t_3 имеет вид

$$y_3 = A_1 + C - e^{\ln((A_1+C-y_2)/(A_1-B_1))-\lambda_1(t_3-t_2)}(A_1 - B_1). \quad (20)$$

Таким образом, при расчете критериев (16) и (17) в качестве прогнозных значений тепловой характеристики $\delta_{пр, \zeta}$ используются компоненты выходного вектора обученной ИНС, а расчетные значения $\delta_{\lambda, \zeta}$ определяются зависимостями (19) и (20).

Моделирование ИНС при различных комбинациях исходных данных осуществлялось при последовательном изменении одного параметра, но фиксации остальных и удовлетворении критериев (16) и (17).

Это позволило установить следующие результаты и закономерности.

Для первого варианта входных данных ИНС:

- для одномодальной функции наилучшие результаты моделирования ИНС достигаются при использовании одного нейрона в скрытом слое;

- при наличии двух мод предпочтительно использование для скрытого слоя нескольких нейронов, при этом не было выявлено строгих закономерностей о соответствии роста числа нейронов в скрытом слое и стабильности получаемых результатов моделирования ИНС;

- для одномодальной функции эффективность прогнозирования незначительно, но выше, так как размер входного вектора формировался за время, меньшее одной тепловой постоянной времени (устойчивые результаты фиксировались при построении прогнозной характеристики по входному вектору, полученному из наблюдений, по длительности составляющих 90 % тепловой постоянной времени тестовой тепловой характеристики); при моделировании двухмодальной функции устойчивые результаты фиксировались при построении прогнозной характеристики по входному вектору, полученному из наблюдений, по длительности составляющих 130 % тепловой постоянной времени первой моды тестовой тепловой характеристики;

- использование нормированных входных данных не способствовало повышению стабильности моделирования ИНС;

- при исследовании соотношений размеров обучающей, проверочной и тестовой выборок было установлено, что минимальный размер обучающей выборки составил 60 % длины вектора входных данных; минимальный размер проверочной и тестовой выборок не может быть менее 10 % длины вектора входных данных.

В качестве иллюстрации эффективности моделирования ИНС на рис. 6 приведены кривые для четырех вариантов вариации параметров моделирования ИНС: кривая 1 — зашумленный исходный вектор с известными модальными параметрами, сформированный в соответствии с формулой (15); кривая 2 — теоретическая тепловая характеристика, сформированная в соответствии с формулой (6); кривая 3 — прогнозная тепловая характеристика — результат моделирования ИНС, выделенный из множества решений критерием (17); кривая 4 — также прогнозная тепловая характеристика, представляющая результат моделирования ИНС и выделенная критерием (16). Рис. 6, а, б иллюстрируют эффективность моделирования ИНС для одномодальной тепловой характеристики, рис. 6, в, г — для двухмодальной. Из рис. 6, а видно, что в зависимости от выбранного критерия (16) или (17) можно получить различный результат. Однако на сегодняшний день обоснованного решения по приоритетности критерия (16) относительно (17) не существует. Поэтому при прочих равных условиях необходимо добиваться близких вариантов моделирования при использовании критериев (16) и (17), например,




Рис. 6. Результаты моделирования ИНС:

а — 1 мода, длительность эксперимента $0,5\tau - 1$ нейрон (в скрытом слое), $\Gamma > 3\tau$; б — 1 мода, 1τ , 1 нейрон, $\Gamma > 3\tau$; в — 2 моды, $1,3\tau$, $\Gamma > 3\tau$, 2 нейрона; г — 2 моды, $1,3\tau$, $\Gamma > 3\tau$, 3 нейрона (Γ — горизонт прогнозирования, т. е. интервал времени, на который осуществляется прогнозирование искомой функции; τ — тепловая постоянная времени первой моды тестовой тепловой характеристики)

за счет выбора длительности базового эксперимента, в ходе которого формируется обучающая выборка. Так, для тепловых характеристик, представленных на рис. 6, б, длительность базового эксперимента, в ходе которого формировалась обучающая выборка, была выбрана равной тепловой постоянной времени тестовой тепловой характеристики. Для тепловых характеристик, представленных на рис. 6, в, г, длительность базового эксперимента составляла 130 % тепловой постоянной времени первой моды тестовой тепловой характеристики.

Для второго варианта входных данных ИНС при использовании метода скользящего окна также были получены инвариантные результаты и закономерности:

- независимо от модальности исследуемой тепловой характеристики наилучшие результаты моделирования ИНС достигаются при использовании более двух нейронов в скрытом слое, но устойчивого снижения погрешности моделирования с ростом числа нейронов в скрытом слое установлено не было;

- для одномодальной тепловой характеристики при сопоставимой погрешности прогнозирования двухмодальной тепловой характеристики горизонт прогнозирования больше, но сопоставим с тепловой постоянной времени первой моды;

- для одномодальной тепловой характеристики более стабильные результаты моделирования ИНС достигаются при большем размере скользящего окна, для двухмодальной тепловой характеристики оптимальные соотношения для размера скользящего окна, горизонта прогнозирования и длительности базового эксперимента не однозначны и подбираются экспериментально.

На рис. 7 приведены пять кривых: кривые 1 — зашумленные тепловые характеристики на длине базового эксперимента. Длительность базового эксперимента на рис. 7, а составляла одну тепловую постоянную времени первой моды, а на рис. 7, б — 130 % тепловой постоянной времени первой моды тестовой тепловой характеристики. Чрезмерное увеличение длительности базового эксперимента автоматически приводит к снижению эффективности моделирования ИНС, так как из теории теплопроводности известно, что длительность базового эксперимента, равная 3τ , определяет более 95 % амплитуды тепловой характеристики. Поэтому в работе базовый эксперимент большой длительности не рассматривался. Кривая 2 — теоретическая тепловая ха-




Рис. 7. Результаты моделирования ИНС:

а — 1 мода, $\Gamma = 0,9\tau$, 4 нейрона; б — 2 моды, $\Gamma = 0,65\tau$, 10 нейронов

рактеристика, сформированная в соответствии с (6); кривые 3 и 4 — прогнозные тепловые характеристики, полученные по результатам моделирования ИНС с использованием критериев (16) и (17), соответственно; кривые 5 — аппроксимированные функции с использованием соотношения (14).

Для обоих представленных на рис. 7 результатов моделирования ИНС ширина скользящего окна принята равной $0,5\tau$, горизонт прогнозирования Γ для одномодальной тепловой характеристики имеет чуть большие размеры. Представленные на рис. 7 результаты моделирования являются типовыми и показывают качество моделирования ИНС с использованием метода скользящего окна применительно к тепловым характеристикам станков.

Заключение

Представлена новая методика исследования устойчивости моделирования ИНС для тепловых характеристик станка. Новая методика позволила сформировать обобщенную концепцию изучения эффективности применения нейросетевых технологий в тепловом моделировании станков. Эта концепция определяет типовой набор варьируемых параметров моделирования, базовую математическую модель, основанную на модальном подходе, и архитектуру типового программного средства, которое может быть разработано для изучения эффективности моделирования ИНС. В работе исследован только один тип архитектуры ИНС, а с учетом их многообразия представленная методика показывает перспективность исследований ИНС в тепловом моделировании станков.

Практическим результатом использования нейронной сети прямого распространения в решении задачи прогнозирования тепловых харак-

теристик является возможность дальнейшего сокращения длительности натурального эксперимента станка; это сокращение оценивается приблизительно в 30 % от длительности натурального эксперимента, реализуемого в соответствии с подходом, основанном на экспериментальном модальном анализе, при котором устойчивые прогнозные решения получаются при длительности натурального эксперимента, равной удвоенному времени тепловой постоянной времени первой моды.

Представленная методика относится к решению задачи прогнозирования, но также может быть адаптирована к решению задачи идентификации тепловой модели и построению цифровых двойников. Однако при решении этих задач неизбежно появятся особенности, учет которых является предметом последующего изучения ИНС.

Список литературы

1. Heisel U., Pasternak S., Storchak M. et al. Optimal configurations of the machine tool structure by means of neural networks // *Prod. Eng. Res. Devel.* 2011. Vol. 5. P. 219–226.
2. Мунасыпов Р. А., Идрисова Ю. В., Масалимов К. А., Кудояров Р. Г., Фецак С. И. Способ оперативной диагностики модулей металлорежущих станков с использованием рекуррентных нейронных сетей с долгой краткосрочной памятью // *СТИН.* 2019. № 12. С. 5–11.
3. Масалимов К. А., Мунасыпов Р. А. Интеллектуальные модели на основе нейронных сетей с долгой кратковременной памятью для диагностики состояния станков в машиностроении // *Вестник Уфимского государственного авиационного технического университета.* 2018. Т. 22. № 2 (80). С. 138–145.
4. Белов М. П., Носиров И. С., Белов А. М. Исследование системы стабилизации мощности и усилия резания токарного станка с использованием нейронных сетей // *Известия СПбГЭТУ ЛЭТИ.* 2019. № 4. С. 77–84.
5. Белов М. П., Носиров И. С., Зувайдуллоев Ф. З., Бадалов Н. Ш. Система управления электроприводом подачи фрезерного станка с нейронными сетями // *Вестник Бохтарского государственного университета имени Носира Хусрава. Серия естественных наук.* 2017. № 2-2 (46). С. 41–45.
6. Du Z., Yao S., Yang J. Thermal behavior analysis and thermal error compensation for motorized spindle of machine tools // *Int. J. Precis. Eng. Manuf.* 2015. Vol.16. P. 1571–1581.
7. Yang J., Shi H., Feng B. et al. Thermal error modeling and compensation for a high-speed motorized spindle // *Int. J. Adv. Manuf. Technol.* 2015. Vol. 77. P. 1005–1017.
8. Li Y., Zhao J., Ji S. Thermal positioning error modeling of machine tools using a bat algorithm-based back propagation neural network // *Int. J. Adv. Manuf. Technol.* 2018. Vol. 97. P. 2575–2586.
9. Ziegert J. C., Kalle P. Error compensation in machine tools: a neural network approach // *J. Intell. Manuf.* 1994. Vol. 5. P. 143–151.
10. Zhang Y., Yang J., Jiang H. Machine tool thermal error modeling and prediction by grey neural network // *Int. J. Adv. Manuf. Technol.* 2012. Vol. 59. P. 1065–1072.
11. Ma C., Zhao L., Mei X. et al. Thermal error compensation of high-speed spindle system based on a modified BP neural network // *Int. J. Adv. Manuf. Technol.* 2017. Vol. 89. P. 3071–3085.
12. Shi H., Jiang C., Yan Z. et al. Bayesian neural network-based thermal error modeling of feed drive system of CNC machine tool // *Int. J. Adv. Manuf. Technol.* 2020. Vol. 108. P. 3031–3044.
13. Guo Q., Yang J., Wu H. Application of ACO-BPN to thermal error modeling of NC machine tool // *Int. J. Adv. Manuf. Technol.* 2010. Vol. 50. P. 667–675.
14. Fu G., Gong H., Gao H. et al. Integrated thermal error modeling of machine tool spindle using a chicken swarm optimization algorithm-based radial basic function neural network // *Int. J. Adv. Manuf. Technol.* 2019. Vol. 105. P. 2039–2055.
15. El Ouafi A., Guillot M., Barka N. An Integrated Modeling Approach for ANN-Based Real-Time Thermal Error Compensation on a CNC Turning Center // *Advanced Materials Research.* 2013. Vol. 664. P. 907–915.
16. Majumder H., Maity K. P. Predictive Analysis on Responses in WEDM of Titanium Grade 6 Using General Regression Neural Network (GRNN) and Multiple Regression Analysis (MRA) // *Silicon.* 2018. Vol. 10. P. 1763–1776.
17. Поляков А. Н., Дьяконов П. И. Исследование теплового состояния станков с помощью нейронных сетей // *СТИН.* 2006. № 10. С. 10–11.
18. Поляков А. Н., Дьяконов П. И. Прогнозирование теплоустойчивости станков с помощью нейросетевого подхода // *Технология машиностроения.* 2003. № 6. С. 29–33.
19. Чичков Б. А., Раков П. И. Классификация искусственных нейронных сетей // *Научный вестник МГТУ ГА.* 2005. № 85. С. 82–87.
20. Хайкин С. Нейронные сети: полный курс / Пер. с англ. М.: Издательский дом "Вильямс", 2008. 1104 с.
21. Поляков А. Н., Гончаров А. Н., Марусич К. В. Исследование тепловых деформаций в металлорежущих станках // *Технология машиностроения.* 2011. № 2. С. 16–22.
22. Поляков А. Н. Методика сокращенных тепловых испытаний металлорежущих станков // *Техника машиностроения.* 2002. № 1 (35). С. 4–10.
23. Chou J.-S., Truong T. T. H. Sliding-window metaheuristic optimization-based forecast system for foreign exchange analysis // *Soft Comput.* 2019. P. 3545–3561.
24. Vafaiepour M., Rahbari O., Rosen M. A. et al. Application of sliding window technique for prediction of wind velocity time series // *Int. J. Energy Environ Eng.* 2014. Vol. 5. P. 105.

A. N. Polyakov, Professor, e-mail: anp_temos@mail.ru,
V. V. Pozevalkin, Postgraduate, e-mail: pozevalkinvv@mail.ru,
Orenburg State University, Orenburg, Russian Federation

Application of a Feedforward Neural Network to Predicting the Thermal Characteristics of Machine Tools

The paper presents a procedure for studying the stability of modeling an artificial neural network as applied to the thermal characteristics of machine tools. The topicality of this procedure is dictated by the ambiguity of the results generated by the neural network when constructing the predicted thermal characteristics of machine tools. Therefore, to select one of the possible solutions generated by the neural network, it was proposed to use two criteria. The effectiveness of their use is confirmed by the presented machine experiments. The methodology proposed in this work has made it possible to form a generalized concept for studying the effectiveness of the use of neural network technologies in thermal modeling of machine tools. This concept defines a typical set of variable modeling parameters, a basic mathematical model based on a modal approach, and an architecture of a typical software tool that can be developed to study the effectiveness of artificial neural network modeling. For each variant of the input data of the network, the following parameters were varied: the number of neurons in the hidden layer; the size of the input and output vectors; input vectors error; the size of the training, validation and test sample; functional features of thermal characteristics supplied to the network input or their multimodality; the presence and absence of normalization of the input vector. The paper presents experimental thermal characteristics for two spindle speeds of a vertical CNC machine. The results of the machine experiment are presented for six variants of the variable parameters of the mathematical model. The software tool used to carry out the machine experiment was developed in Matlab.

Keywords: artificial neural network, machine experiment, thermal characteristics of machine tools, modal parameters

Acknowledgments: The reported study was funded by RFBR according to the research project № 20-38-90045.

DOI: 10.17587/it.27.202-211

References

1. Heisel U., Pasternak S., Storchak M. et al. Optimal configurations of the machine tool structure by means of neural networks, *Prod. Eng. Res. Devel.*, 2011, vol. 5, pp. 219–226.
2. Munasyrov R. A., Idrisova U. V., Masalimov K. A., Kudoyarov R. G., Fecak S. I. Technique for on-line diagnostics of metal-cutting machine tool modules using recurrent neural networks with long short-term memory, *STIN*, 2019, no. 12, pp. 5–11 (in Russian).
3. Masalimov K. A., Munasyrov R. A. Intelligent models based on neural networks with long short-term memory for diagnosing the state of machine tools in mechanical engineering, *Bulletin of the Ufa State Aviation Technical University*, 2018, vol. 22, no. 2 (80), pp. 138–145 (in Russian).
4. Belov M. P., Nosirov I. S., Belov A. M. Investigation of the power and cutting force stabilization system of a lathe using neural networks, *Proceedings of Saint Petersburg Electrotechnical University*, 2019, no. 4, pp. 77–84 (in Russian).
5. Belov M. P., Nosirov I. S., Zuvaydullov F. Z., Badalov N. S. Control system for electric drive of milling machine with neural networks, *Bulletin of Bokhtar State University named after Nosir Khusrav. Natural Science Series*, 2017, no. 2(46), pp. 41–45.
6. Du Z., Yao S., Yang J. Thermal behavior analysis and thermal error compensation for motorized spindle of machine tools, *Int. J. Precis. Eng. Manuf.*, 2015, vol.16, pp. 1571–1581.
7. Yang J., Shi H., Feng B. et al. Thermal error modeling and compensation for a high-speed motorized spindle, *Int. J. Adv. Manuf. Technol.*, 2015, vol. 77, pp. 1005–1017.
8. Li Y., Zhao J., Ji S. Thermal positioning error modeling of machine tools using a bat algorithm-based back propagation neural network, *Int. J. Adv. Manuf. Technol.*, 2018, vol. 97, pp. 2575–2586.
9. Ziegert J. C., Kalle P. Error compensation in machine tools: a neural network approach, *J. Intell. Manuf.*, 1994, vol. 5, pp. 143–151.
10. Zhang Y., Yang J. & Jiang H. Machine tool thermal error modeling and prediction by grey neural network, *Int. J. Adv. Manuf. Technol.*, 2012, vol. 59, pp.1065–1072.
11. Ma C., Zhao L., Mei X. et al. Thermal error compensation of high-speed spindle system based on a modified BP neural network, *Int. J. Adv. Manuf. Technol.*, 2017, vol. 89, pp. 3071–3085.
12. Shi H., Jiang C., Yan Z. et al. Bayesian neural network-based thermal error modeling of feed drive system of CNC machine tool, *Int. J. Adv. Manuf. Technol.*, 2020, vol. 108, pp. 3031–3044.
13. Guo Q., Yang J., Wu H. Application of ACO-BPN to thermal error modeling of NC machine tool, *Int. J. Adv. Manuf. Technol.*, 2010, vol. 50, pp. 667–675.
14. Fu G., Gong H., Gao H. et al. Integrated thermal error modeling of machine tool spindle using a chicken swarm optimization algorithm-based radial basic function neural network, *Int. J. Adv. Manuf. Technol.*, 2019, vol. 105, pp. 2039–2055.
15. El Ouafi A., Guillot M., Barka N. An Integrated Modeling Approach for ANN-Based Real-Time Thermal Error Compensation on a CNC Turning Center, *Advanced Materials Research*, 2013, vol.664, pp.907–915.
16. Majumder H., Maity K. P. Predictive Analysis on Responses in WEDM of Titanium Grade 6 Using General Regression Neural Network (GRNN) and Multiple Regression Analysis (MRA), *Silicon*, 2018, vol. 10, pp. 1763–1776.
17. Polyakov A. N., Dyakonov P. I. Investigation of the thermal state of machine tools using neural networks, *STIN*, 2006, no. 10, pp. 10–11 (in Russian).
18. Polyakov A. N., Dyakonov P. I. Predicting the thermal stability of machine tools using a neural network approach, *Tekhnologiya Mashinostroeniya*, 2003, no. 6, pp. 29–33 (in Russian).
19. Chochkov B. A., Rakoc P. I. Classification of artificial neural networks, *Scientific Nauchnyi Vestnik MSTU GA*, 2005, no. 85, pp. 82–87 (in Russian).
20. Haykin S. *Neural Networks: A Comprehensive Foundation*, Moscow, Williams Publishing House. 2008, 1104 p. (in Russian).
21. Polyakov A. N., Goncharov A. N., Marusich K. V. Investigation of thermal deformations in metal-cutting machine tools, *Tekhnologiya Mashinostroeniya*, 2011, no. 2, pp. 16–22 (in Russian).
22. Polyakov A. N. Methodology for reduced thermal testing of metal-cutting machine tools, *Tekhnika Mashinostroeniya*, 2002, no. 1(35), pp. 4–10 (in Russian).
23. Chou J-S, Truong T. T. H. Sliding-window metaheuristic optimization-based forecast system for foreign exchange analysis, *Soft Comput.*, 2019, pp. 3545–3561.
24. Vafaeipour M., Rahbari O., Rosen M. A. et al. Application of sliding window technique for prediction of wind velocity time series, *Int. J. Energy Environ. Eng.*, 2014, vol. 5, p. 105.