

**МОДЕЛИРОВАНИЕ ОПЕРАЦИЙ
ТЕХНОЛОГИЧЕСКОГО ПРОЕКТИРОВАНИЯ
С ИСПОЛЬЗОВАНИЕМ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ**

*Л.В. Кремлева**, *О.И. Бедердинова**, *А.Н. Елисеев**

*Северный (Арктический) федеральный университет имени М.В. Ломоносова

Приведено описание подхода к анализу конструкторско-технологической информации с помощью искусственной нейронной сети (ИНС) и классического алгоритма обратного распространения при ее обучении, на основе которого разработано программное обеспечение для создания, обучения и функционирования полносвязной ИНС произвольной топологии. Проанализированы технологические данные испытаний фрез для контурной обработки древесины, полученные с применением метода аппроксимации экспериментальных зависимостей регрессионными формулами. Описаны результаты численных экспериментов с использованием ИНС. При проведении первого эксперимента применялась полносвязная ИНС для комбинации «обрабатываемый материал – направление подачи», включающая 3 нейрона; при проведении второго эксперимента произведено обучение ИНС, включающей 6 нейронов. Оценена точность данных, полученных при помощи метода ИНС, в сравнении с классическими способами обработки и использования экспериментальных данных. Установлено, что прогноз выходных параметров, в частности уровня вибраций и качества получаемой поверхности, с помощью ИНС обладает более высокой точностью, чем оценка, которую дают феноменологические модели. Использование метода на основе ИНС позволяет подобрать режимы резания при заданной комбинации «обрабатываемый материал – направление подачи» для обеспечения требуемых параметров технологической операции. Показано, что ИНС практически не имеет ограничений по количеству анализируемых факторов, может обрабатывать числовой, текстовый или логический тип данных и отражать субъективные оценки объекта исследования проектировщиком, что невозможно при классическом экспериментальном подходе с применением регрессионных моделей. Поэтому ИНС с накопленными и проанализированными знаниями способна генерировать значения количественных характеристик проектируемых технологических операций с учетом особенностей конкретного производства, что позволило сделать вывод о перспективности дальнейших исследований в области использования ИНС при анализе и хранении производственных данных, а также для получения новых знаний.

Ключевые слова: *искусственная нейронная сеть, алгоритм обучения искусственной нейронной сети, проектирование технологических операций, регрессионная модель, нейрон, синаптическая связь, численный эксперимент.*

Контактное лицо: Кремлева Людмила Викторовна, *адрес:* 164520, Архангельская область, г. Северодвинск, ул. Воронина, д. 6; *e-mail:* L.Kremleva@narfu.ru

Для цитирования: Кремлева Л.В., Бедердинова О.И., Елисеев А.Н. Моделирование операций технологического проектирования с использованием искусственных нейронных сетей // Вестн. Сев. (Арктич.) федер. ун-та. Сер.: Естеств. науки. 2016. № 3. С. 97–105. doi: 10.17238/issn2227-6572.2016.3.97

Синтез технологических процессов (ТП) как совокупности операций заключается в последовательном принятии проектных решений технологом-проектировщиком. Для выполнения требований, предъявляемых к разрабатываемым ТП, обычно проводятся процедуры анализа имеющейся организационно-технологической информации. Получаемые при этом данные способствуют целенаправленному выполнению процедур синтеза ТП. Синтез и анализ, как основа любого проектирования, неразрывно связаны.

Существует ряд подходов к обобщенному описанию задач принятия проектных решений в процессе создания ТП. Задача принятия решений (ЗПР) формулируется следующим образом [1]:

$$\text{ЗПР} = \langle A, K, \text{Мод}, \Pi \rangle, \quad (1)$$

где A – множество альтернатив проектного решения (входные параметры); $K = (K_1, K_2, K_3, \dots, K_n)$ – множество критериев (выходных параметров), по которым оценивается соответствие альтернативы поставленным целям; Мод: $A \rightarrow K$ – математическая модель, позволяющая для каждой альтернативы рассчитать вектор критериев; Π – решающее правило для выбора наиболее подходящей альтернативы в многокритериальной ситуации.

Каждой альтернативе ставятся в соответствие значения упорядоченного или неупорядоченного множества атрибутов: $X = \langle x_1, x_2, \dots, x_n \rangle$. Особенность технологического проектирования заключается в том, что атрибуты альтернатив могут иметь нечисловой характер, например «обрабатываемый материал», «инструментальный материал», «вид обработки» и др. Присущая технологическим задачам нечеткость исходных данных, связанная с недостаточной изученностью физических процессов, происходящих в технологической среде, приводит к неопределенности соответствующих математических моделей. Технологию постоянно приходится использовать накопленную производственную информацию: таблицы, эмпирические формулы, технические условия и нормы. Но чаще проектировщик при выборе

структуры ТП и параметров операций руководствуется собственной интуицией, основанной на предыдущем опыте.

Классические подходы для создания математических моделей процессов, происходящих в технических системах, хорошо известны. Все они имеют свои преимущества и недостатки, а также область применения. Наиболее распространены методы аппроксимации экспериментальных данных – феноменологические (регрессионные) модели, сформированные методами планирования активных экспериментов. Эти модели, несмотря на высокую достоверность, имеют два существенных недостатка. Во-первых, область их адекватности распространяется только на диапазоны значений атрибутов, которые определяются условиями проведения экспериментов. Во-вторых, в регрессионном анализе невозможно использовать информацию нечислового характера.

Аналитические детерминированные модели физических процессов в технологических системах используются значительно реже, поскольку имеют, как правило, невысокую количественную достоверность, что связано с различного рода ограничениями и упрощениями. Комбинированные методы, сочетающие детерминированные или вероятностные модели с экспериментально определенными коэффициентами, могут снять некоторые ограничения аналитических моделей, но полностью устранить недостаточную количественную достоверность не позволяют.

В настоящее время при математическом моделировании распространен подход, основанный на использовании искусственных нейронных сетей (ИНС), который нашел широкое применение в таких науках, как биология, психология, мехатроника, и некоторых других.

ИНС – это системы, которые способны сами анализировать имеющуюся и вновь поступающую информацию, находить в ней закономерности, производить прогнозирование и выдавать неизвестные параметры, в т. ч. и в условиях недостаточности или нечеткости исходных или выходных данных [2]. Это обу-

чаемые системы, имитирующие деятельность человеческого мозга. Фактически ИНС представляет собой «черный ящик» с N входами и M выходами. Несмотря на большое разнообразие, ИНС имеют общие черты. Так, все они состоят из большого числа однотипных элементов – нейронов. Каждый нейрон характеризуется текущим состоянием по аналогии с нервными клетками головного мозга, которые могут быть возбуждены или заторможены. Он обладает группой синапсов – однонаправленных входных связей, соединенных с выходами других нейронов, а также имеет аксон – выходную связь данного нейрона, с которой сигнал (возбуждения или торможения) поступает на синапсы следующих нейронов [2].

Каждый синапс характеризуется величиной синаптической связи, или ее весом (W_i).

Текущее состояние нейрона (NET) определяется как взвешенная сумма его входов:

$$NET = \sum_{i=1}^n W_i \cdot X_i, \quad (2)$$

где W_i – весовой коэффициент синаптической связи i -го нейрона; X_i – входной вектор i -го нейрона.

Выход (OUT) нейрона – это функция его состояния:

$$OUT = F(NET). \quad (3)$$

Нелинейная функция F называется активационной и может представляться функциями единичного скачка, гиперболическим тангенсом, логистической функцией (сигмоидом) и др. [2]. Нейроны в ИНС объединяются в слои, которые соединены друг с другом посредством связей. Следует отметить, что в настоящее время не существует единой терминологии в области ИНС, а в областях промышленного производства, связанных с информацией технологического характера, ИНС практически не применяются.

В исследованиях, независимо от области науки, ИНС используются для решения задач двух типов: регрессии и классификации. В представленных исследованиях при решении задачи регрессии реализована схема ИНС об-

ратного распространения. Алгоритм обучения, подробно описанный в [3], предполагает распространение ошибки от выходного слоя к входному, т. е. в направлении, противоположном направлению распространения сигнала при нормальном функционировании сети. Нейронная сеть обратного распространения состоит из нескольких слоев нейронов, причем каждый нейрон слоя i связан с каждым нейроном слоя $i + 1$, т. е. речь идет о полносвязной ИНС. В общем случае задача обучения ИНС сводится к нахождению некой функциональной зависимости $Y = F(X)$, где X – входной вектор альтернативы, а Y – выходной критериальный вектор, значения которых берутся из известных данных экспериментального, расчетного или иного характера. Таким образом, в результате обучения система приобретает некоторые «знания». В общем случае эта задача, при ограниченном наборе входных данных, имеет бесконечное множество решений. Для ограничения пространства поиска при обучении ставится задача минимизации целевой функции ошибки $E(W)$ ИНС, которая находится методом наименьших квадратов:

$$E(W) = \frac{1}{2} \sum_{j,p} (OUT_{j,p}^{(n)} - D_{j,p})^2, \quad (4)$$

где $OUT_{j,p}^{(n)}$ – реальное выходное состояние нейрона j -го выходного слоя n при подаче на входы сети p -го образа; $D_{j,p}$ – идеальное (желаемое) состояние этого нейрона.

Классический алгоритм обучения ИНС включает следующую последовательность действий [3]:

1. Подать на входы сети один из возможных образов, определить значения выходов согласно формулам (5)–(7):

$$NET_j^{(n)} = \sum_{i=1}^M W_{i,j}^{(n)} \cdot OUT_i^{(n-1)}, \quad (5)$$

где M – число нейронов в слое $n - 1$; $OUT_i^{(n-1)} = X_{i,j}^{(n)}$ – i -й вход j -го нейрона слоя n ;

$$OUT_j^{(n)} = F(NET_j^{(n)}), \quad (6)$$

где $F(NET_j^{(n)})$ – активационная функция входа;

$$OUT_q^{(0)} = X_q, \quad (7)$$

где X_q – q -я компонента вектора входного образа.

2. Определить ошибку ИНС $\delta^{(n)}$ и изменение веса на предыдущей итерации $\Delta W^{(n)}$ для выходного слоя n по формулам (8), (9):

$$\delta_j^{(n)} = (OUT_j^{(n)} - D_j) \frac{dOUT_j}{dNET_j}; \quad (8)$$

$$\Delta W_{i,j}^{(n)} = -\eta(\mu \Delta W_{i,j}^{(n)}(t-1) + (1-\mu) \delta_j^{(n)} OUT_i^{(n-1)}), \quad (9)$$

где η – коэффициент скорости обучения, $0 < \eta < 1$; μ – коэффициент инерционности; t – номер текущей операции.

3. Определить ошибку ИНС $\delta^{(n)}$ и изменения веса $\Delta W^{(n)}$ для всех остальных слоев по формулам (9), (10):

$$\delta_j^{(n)} = \left[\sum_k \delta_k^{(n+1)} W_{j,k}^{(n+1)} \right] \frac{dOUT_j}{dNET_j}. \quad (10)$$

4. Скорректировать веса ИНС по формуле

$$W_{i,j}^{(n)}(t) = \Delta W_{i,j}^{(n)}(t) + W_{i,j}^{(n)}(t-1). \quad (11)$$

5. Если ошибка существенна, перейти на шаг 1, иначе – завершение.

Приведенный алгоритм был положен в основу разработанного нами программного обеспечения для конструирования, обучения и функционирования ИНС произвольной топологии. Виды интерфейсных форм программы «Эмулятор искусственных нейронных сетей» приведены на рис. 1, 2.

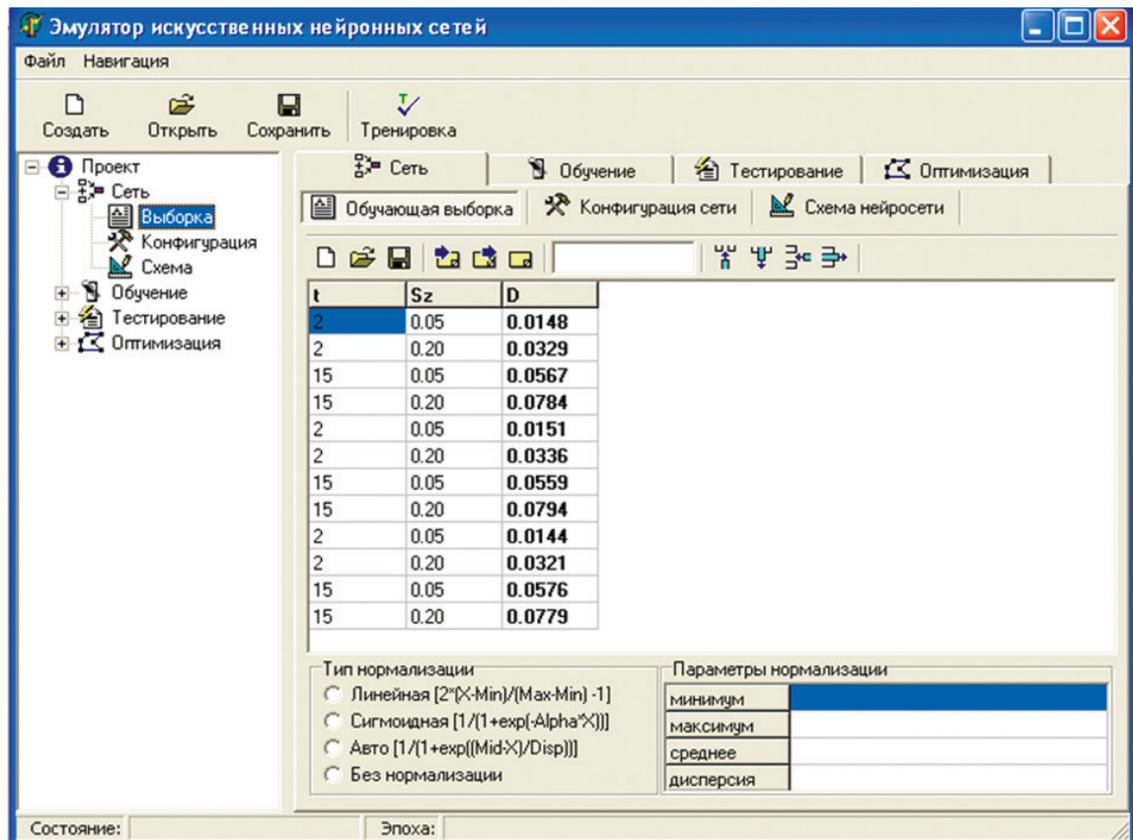


Рис. 1. Вид пользовательской формы «Обучающая выборка»

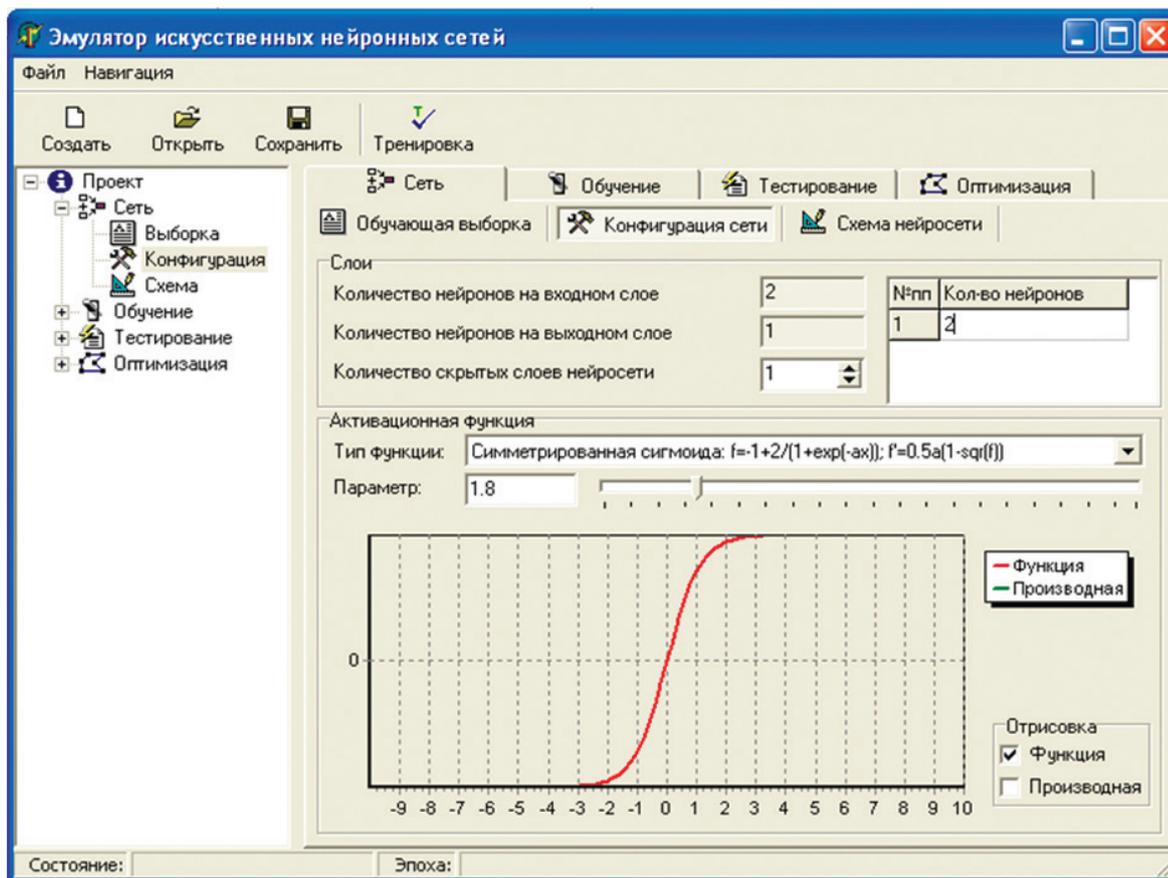


Рис. 2. Вид пользовательской формы «Конфигурация сети»

В качестве тестового примера проанализированы данные экспериментальных исследований влияния режимных параметров контурного фрезерования древесины на уровень

вибраций и достигаемую при этом шероховатость поверхности (табл. 1), которые взяты из [4]. Данные получены с использованием методов планирования факторного эксперимента

Таблица 1

РЕГРЕССИОННЫЕ ЗАВИСИМОСТИ, ПОЛУЧЕННЫЕ ПО ЭКСПЕРИМЕНТАЛЬНЫМ ДАННЫМ [4]

Направление подачи фрезы	Показатели эффективности фрезерования	
	Уровень вибраций	Шероховатость
Древесина сосны		
Вдоль волокон	$D = 0,032 S_z^{0,27} t^{0,50}$	$Ra = 6,938 S_z^{0,59} t^{0,72}$
Поперек волокон	$D = 0,034 S_z^{0,23} t^{0,45}$	$Ra = 6,67 S_z^{0,303} t^{0,664}$
Древесина дуба		
Вдоль волокон	$D = 0,053 S_z^{0,132} t^{0,326}$	$Ra = 7,52 S_z^{0,41} t^{0,77}$
Поперек волокон	$D = 0,056 S_z^{0,0898} t^{0,293}$	$Ra = 7,14 S_z^{0,34} t^{0,74}$

и аппроксимации экспериментальных зависимостей регрессионными формулами. Здесь D – уровень вибраций, характеризуемый среднеквадратичным значением (СКЗ) отклонения центра заготовки при фрезеровании; Ra – шероховатость поверхности; S_z – подача на зуб фрезы; t – глубина резания.

Для сравнения было проведено два численных эксперимента с использованием ИНС. При первом эксперименте для каждой комбинации «обрабатываемый материал – направление подачи» была обучена полносвязная ИНС, состоящая из 3 нейронов (рис. 3а), при втором эксперименте – ИНС, состоящая из 6 нейронов (рис. 3б). Во втором случае на вход кроме численных данных (режимных параметров) подавалась нечисловая информация (обрабатываемый материал и направление по-

данных, остальные 25 % использовались в качестве тестовой выборки. В табл. 2 приведены экспериментальные данные (средние по уровням варьирования), аппроксимированные данные, рассчитанные по регрессионным зависимостям, и данные двух численных экспериментов с ИНС, состоящими из 3 (ИНС 1) и 6 (ИНС 2) нейронов.

При анализе полученных результатов установлено, что усредненная среднеквадратичная ошибка прогноза уровня вибраций для ИНС из 3 и 6 нейронов составила: при обработке древесины сосны – $8,25E-04$ и $2,51E-03$ м/с², древесины дуба – $9,63E-04$ и $2,01E-03$ м/с² соответственно. Ошибка прогноза достигаемой шероховатости поверхности составила: для древесины сосны – 0,09 и 0,11 мкм, дуба – 0,13 и 0,15 мкм соответственно. В то же время при

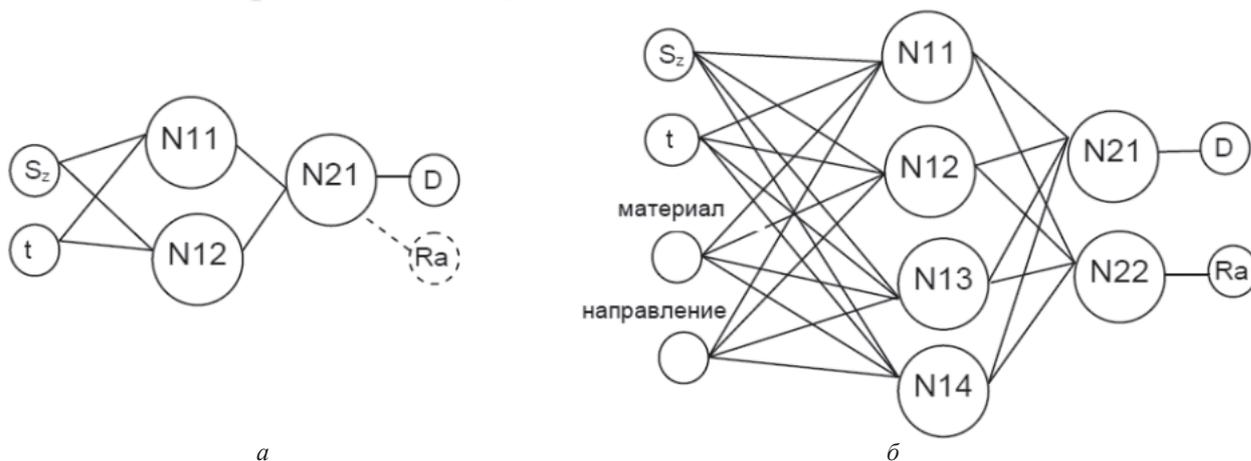


Рис. 3. Схемы ИНС, использованные при численном эксперименте

дачи). Таким образом, вместо 6 моделей была одна.

Обучение ИНС проводилось в пределах 10 000 итераций (шагов алгоритма). После обучения системы на вход подавались различные значения варьируемых параметров. Обучающая выборка при этом составляла 75 % от приведенных в работе [4] экспериментальных

использовании эмпирической формулы усредненная среднеквадратичная ошибка прогноза уровня вибраций составила для древесины сосны и дуба $3,00E-03$ и $3,94E-03$ м/с², по показателям шероховатости получаемой поверхности – 0,16 и 0,39 мкм соответственно.

Сравнение результатов позволяет сделать вывод о более высокой точности прогноза вы-

Таблица 2

РЕЗУЛЬТАТЫ МАТЕМАТИЧЕСКОЙ ОБРАБОТКИ ДАННЫХ МНОГОФАКТОРНОГО ЭКСПЕРИМЕНТА

Режимы резания		Уровень вибраций D (СКЗ), m/s^2			Шероховатость поверхности Ra , μm				
S_z , мм/зуб	t , мм	Эксперимент	Эмпирическая формула	ИНС 1	ИНС 2	Эксперимент	Эмпирическая формула	ИНС 1	ИНС 2
Древесина сосны									
0,05	2	0,0148	0,0201	0,0144	0,0130	2,1	1,9	2,1	2,1
0,20	2	0,0329	0,0293	0,0333	0,0308	4,3	4,4	4,3	4,2
0,05	15	0,0567	0,0548	0,0571	0,0555	8,2	8,3	8,2	8,3
0,20	15	0,0784	0,0797	0,0761	0,0736	18,9	18,9	18,8	19,1
0,05	2	Поперек	0,0236	0,0184	0,0148	3,8	4,3	3,9	3,9
0,20	2	Поперек	0,0360	0,0325	0,0332	6,8	6,5	6,4	6,9
0,05	15	Поперек	0,0608	0,0589	0,0601	16,4	16,3	16,3	16,6
0,20	15	Поперек	0,0796	0,0810	0,0780	24,7	24,8	24,6	24,7
Среднеквадратичная ошибка		Средняя	3,00E-03	8,25E-04	2,51E-03	Средняя	0,16	0,09	0,11
		Максимальная	5,30E-03	1,6E-03	3,91E-03	Максимальная	0,47	0,26	0,20
Древесина дуба									
0,05	2	Вдоль	0,0391	0,0449	0,0392	0,0411	2,9	3,8	2,9
0,20	2	Вдоль	0,0588	0,0539	0,0586	0,0628	7,2	6,7	7,2
0,05	15	Вдоль	0,0898	0,0868	0,0903	0,0900	18,3	18,1	18,5
0,20	15	Вдоль	0,1017	0,1042	0,1010	0,1020	31,7	31,8	31,9
0,05	2	Поперек	0,0473	0,0525	0,0459	0,0445	3,6	4,3	3,8
0,20	2	Поперек	0,0641	0,0595	0,0624	0,0664	7,3	6,9	7,2
0,05	15	Поперек	0,0976	0,0947	0,0964	0,0930	19,1	18,9	19,3
0,20	15	Поперек	0,1047	0,1072	0,1067	0,1045	30,3	30,4	30,3
Среднеквадратичная ошибка		Средняя	3,94E-03	9,63E-03	9,63E-04	2,01E-03	Средняя	0,39	0,13
		Максимальная	4,85E-03	1,7E-03	4,31E-03	Максимальная	0,68	0,20	0,50

ходных параметров (в данном случае уровня вибрации и шероховатости поверхности) с применением полносвязной ИНС по сравнению с оценкой по феноменологическим моделям. При этом следует отметить, что максимальные среднеквадратичные ошибки прогноза технологических показателей с применением ИНС ниже, чем при прогнозе с помощью эмпирических моделей. На основании результатов математической обработки данных вычислительного эксперимента установлено, что ИНС с достаточной степенью точности позволяет подобрать режимы резания, которые обеспечивают требуемые шероховатость поверхности и уровень вибраций для заданной комбинации «обрабатываемый материал – направление резания».

Недостаточность или ограниченность информации о входных или выходных данных любого ТП связана с большим количеством участвующих в нем элементов и очень сложными взаимосвязями между ними. Количественный прогноз искомых параметров при экспериментальном или аналитическом подходе осуществляется, как правило, путем введения поправочных коэффициентов. Но неучтенными оказываются большое количество факторов (например, срок эксплуатации обо-

рудования, уровень квалификации рабочего, состояние поставки обрабатываемого материала, влажность, точность настройки станка и пр.). Нейронная сеть практически не имеет ограничений на количество анализируемых факторов, векторы которых могут содержать компоненты расчетного, экспериментально-лабораторного или производственного характера, иметь числовой, текстовый или логический тип, а также отражать субъективные оценки объекта исследования проектировщиком. Способность анализировать имеющуюся информацию, а также вновь получаемую в ходе операций обработки, выполняемых на конкретных рабочих местах, позволяет осуществлять прогноз количественных характеристик проектируемых ТП, руководствуясь при этом не только собственным опытом, но и знаниями, накопленными и проанализированными ИНС с учетом особенностей конкретного производства. Таким образом, использование ИНС для решения технологических задач является перспективным направлением развития методов математического моделирования технических систем, при этом актуальным остается вопрос об оптимизации топологии ИНС, используемых при технологическом моделировании.

Список литературы

1. *Норенков И.П.* Основы автоматизированного проектирования. М., 2009. 430 с.
2. *Короткий С.* Нейронные сети: основные положения. СПб., 2002. 10 с. URL: <http://www.rema44.ru/resurs/study/ai/materials/N1.DOC> (дата обращения: 25.02.2016).
3. *Короткий С.* Нейронные сети: алгоритм обратного распространения. СПб., 2000. 15 с. URL: <http://www.rema44.ru/resurs/study/ai/materials/N2.DOC> (дата обращения: 25.02.2016).
4. *Кремлева Л.В.* Повышение эффективности процесса механической обработки сложнопрофильных поверхностей литейных моделей из древесно-композитных материалов: дис. ... д-ра техн. наук. Архангельск, 2010. 306 с.

References

1. *Norenkov I.P.* *Osnovy avtomatizirovannogo proektirovaniya* [Fundamentals of Computer-Aided Design]. Moscow, 2009. 430 p.
2. *Korotkiy S.* *Neyronnye seti: osnovnye polozheniya* [Neural Networks: Conceptual Issues]. Saint Petersburg, 2002. 10 p. Available at: <http://www.rema44.ru/resurs/study/ai/materials/N1.DOC> (accessed 25.02.2016).

3. Korotkiy S. *Neyronnye seti: algoritm obratnogo rasprostraneniya* [Neural Networks: Back-Propagation Algorithm]. Saint Petersburg, 2000. 15 p. Available at: <http://www.rema44.ru/resurs/study/ai/materials/N2.DOC> (accessed 25.02.2016).

4. Kremleva L.V. *Povyshenie effektivnosti protsessa mekhanicheskoy obrabotki slozhnoprofil'nykh poverkhnostey liteynykh modeley iz drevesno-kompozitnykh materialov*: dis. ... d-ra tekhn. nauk [Improving the Efficiency of the Machining Process of Complex Surfaces of Wood-Composites Foundry Patterns: Dr. Eng. Sci. Diss.]. Arkhangelsk, 2010. 306 p.

doi: 10.17238/issn2227-6572.2016.3.97

*Lyudmila V. Kremleva**, *Oksana I. Bederdinova**, *Andrey N. Eliseev**

*Northern (Arctic) Federal University named after M.V. Lomonosov (Arkhangelsk, Russian Federation)

OPERATIONS SIMULATING OF PROCESS DESIGN WITH THE USE OF ARTIFICIAL NEURAL NETWORKS

The paper presents the approach description to the analysis of the design technology information with the use of an artificial neural network (ANN) and a classic back-propagation algorithm. On its basis the software for creating, training and functioning of a fully connected neural network of random topology is developed. We have analyzed the process data of tests of contour form milling tools obtained by the approximation method of experimental dependencies of the regression formulas. The results of numerical experiments using the ANN are described. During the first experiment we have used a fully connected ANN for the combination of “process material – feed direction”, including 3 neurons. In the second experiment the ANN training including 6 neurons has been provided. We have assessed the accuracy of the obtained data obtained by the ANN method in comparison with the classical approaches of processing and the use of experimental data. The forecast of the output parameters, such as the vibration level and the quality of the resulting surface using the ANN has a higher accuracy compared with the assessment of phenomenological models. The method based on the neural networks allows us to choose the cutting conditions for a given combination of “process material – feed direction” to provide the required parameters of the technological operations. The ANN has no restrictions on the number of the analyzed factors, can process the numeric, text or Boolean data types and reflects the subjective evaluations of the research object by the designer, which is impossible with the classical experimental approach using the regression models. Therefore, the ANN with the accumulated and analyzed knowledge can generate the values of the quantitative characteristics of the designed technological operations, taking into account the specific features of the production. This led us to the conclusion about the prospects of further research of the ANN use in the analysis and storage of production data and for the acquiring of new knowledge.

Keywords: *artificial neural network, learning algorithm for artificial neural network, design of process operations, regression model, neuron, synaptic connection, numerical experiment.*

Received on April 04, 2016

Поступила 04.04.2016

Corresponding author: Lyudmila Kremleva, *address:* Captain Voronin str., 6, Severodvinsk, Arkhangelsk region, 164520, Russian Federation; *e-mail:* L.Kremleva@narfu.ru

For citation: Kremleva L.V., Bederdinova O.I., Eliseev A.N. Operations Simulating of Process Design with the Use of Artificial Neural Networks. *Vestnik Severnogo (Arkticheskogo) federal'nogo universiteta. Ser.: Estestvennye nauki*, 2016, no. 3, pp. 97–105. doi: 10.17238/issn2227-6572.2016.3.97