



КОМПЬЮТЕРИЗАЦИЯ УЧЕБНЫХ И ТЕХНОЛОГИЧЕСКИХ ПРОЦЕССОВ

УДК 681.31

В.И. Малыгин, Л.В. Кремлева, К.Л. Шестаков

Малыгин Владимир Иванович родился в 1952 г., окончил в 1979 г. Университет Дружбы народов им. П. Лумумбы, доктор технических наук, профессор, действительный член АИН РФ, проректор по научной работе Севмашвуза – филиала СПбГМТУ. Имеет более 100 научных работ в области математического моделирования физических процессов при резании.



ПРОЕКТНЫЕ РЕШЕНИЯ В ТЕХНОЛОГИИ ДЕРЕВООБРАБОТКИ

Приведена методика оптимизации параметров технологического процесса деревообработки на стадии его проектирования с помощью использования искусственных нейронных сетей.

Ключевые слова: деревообработка, технологическое проектирование, математическая модель, нейронная сеть, оптимизация, анализ и синтез

В связи с возрастающим объемом использования при деревообработке, прежде всего в мебельном производстве, программно-управляемых станков, обладающих широким диапазоном выбора частоты вращения шпинделя (скорость резания) и скорости подачи, актуальным становится вопрос оптимизации параметров механической обработки древесины на стадии проектирования технологического процесса.

Цель статьи – разработать методику оптимизации параметров механической обработки древесины на стадии проектирования технологического процесса путем использования искусственных нейронных сетей.

Сущность проектирования заключается в принятии решений, обеспечивающих выполнение будущим объектом предъявляемых к нему требований. Синтез проектных решений, который строится обычно на анализе создаваемой системы, – основа проектирования. Анализ позволяет получить необходимую информацию для целенаправленного выполнения процедур синтеза в итерационном процессе проектирования. Поэтому синтез и анализ неразрывно связаны. Известно, что существует ряд подходов для обобщенного описания задач принятия решений (ЗПР). Задачу формулируют следующим образом [1]:

$$\text{ЗПР} = \langle A, K, \text{Мод}, P \rangle ,$$

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

Каждой альтернативе можно поставить в соответствие значения упорядоченного множества (набор) атрибутов: $X = \langle X_1, X_2, \dots X_n \rangle$. При этом X_i может иметь нечисловой характер. Присущие проектным задачам неопределенность и нечеткость исходных данных часто приводят к неопределенности математических моделей в силу недостаточной изученности процессов и их взаимосвязей в исследуемой среде. В наибольшей мере это относится к области технологического проектирования.

Обычно для получения параметрических моделей при проектировании операций технологических процессов используют методы идентификации и аппроксимации экспериментальных данных, т. е. феноменологические модели, сформированные методами планирования эксперимента. Для построения математических моделей применяют различные методы. На рис. 1 представлены области эффективного использования современных методов моделирования.

В настоящее время популярным становится подход, основанный на использовании искусственных нейронных сетей (ИНС), т. е. систем, которые способны сами анализировать имеющуюся и вновь поступающую информацию, находить в ней закономерности, производить прогнозирование и

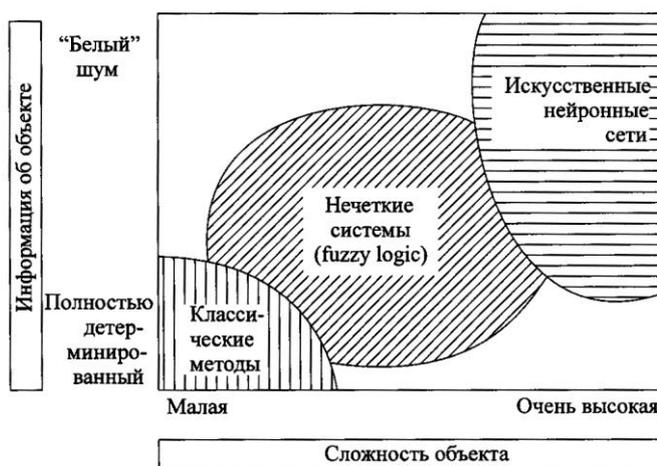
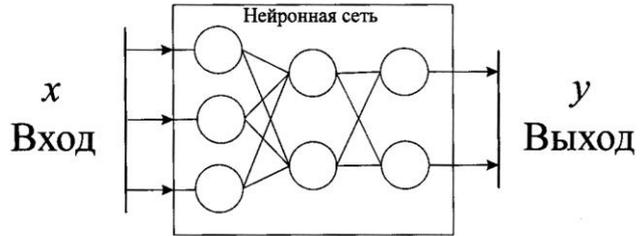


Рис. 1. Области наиболее эффективного применения методов моделирования

Рис. 2. Принцип использования ИНС в качестве модели



выдавать неизвестные параметры, в том числе, и в условиях недостаточности или нечеткости исходных или выходных данных. Нейронные сети – обучаемые системы, имитирующие деятельность человеческого мозга. Фактически нейронная сеть представляет собой «черный ящик» с N входами и M выходами (рис. 2).

Несмотря на большое разнообразие, нейронные сети имеют общие черты. Так, все они состоят из большого числа однотипных элементов – нейронов. Каждый нейрон характеризуется своим 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 (возбуждение или торможение) поступает на синапсы следующих нейронов. На рис. 3 показана схема нейрона.

Каждый синапс характеризуется величиной синаптической связи, или ее весом W_i , который по физическому смыслу эквивалентен электрической проводимости. Текущее состояние нейрона определяют как взвешенную сумму его входов:

$$NET = \sum_{i=1}^n W_i \times X_i .$$

Выход нейрона есть функция его состояния:

$$OUT = F(NET) .$$

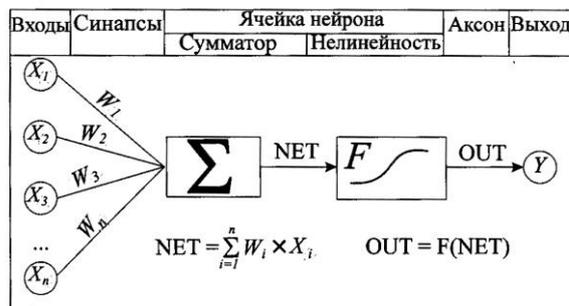


Рис. 3. Схема искусственного нейрона

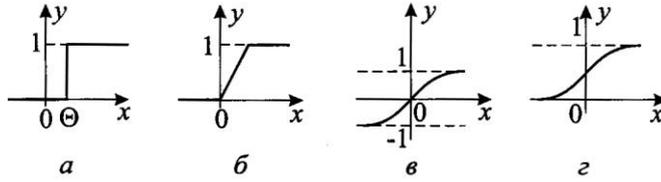


Рис. 4. Типы активационных функций: *a* – единичного скачка; *б* – линейный порог (гистерезис); *в* – гиперболический тангенс; *г* – сигмоид

Нелинейную функцию F называют активационной, и она может иметь различный вид (рис. 4):

а) единичного скачка
$$OUT = \begin{cases} 0, NET < \Theta \\ 1, NET \geq \Theta \end{cases};$$

б) линейный порог (гистерезис)

$$OUT = \begin{cases} 0, NET \leq \Theta \\ \frac{NET - \Theta}{\Delta}; & \Theta \leq NET \leq \Theta + \Delta \\ 1, NET \geq \Theta + \Delta \end{cases}$$

в) гиперболический тангенс
$$OUT = th(NET) = \frac{e^{NET} - e^{-NET}}{e^{NET} + e^{-NET}};$$

г) сигмоид
$$OUT = \frac{1}{1 + e^{-NET}}.$$

Нейроны в ИНС объединены в слои, которые связаны друг с другом посредством синаптических связей. Если каждый нейрон предыдущего слоя связан со всеми нейронами последующего слоя, то нейронную сеть называют полносвязной (рис. 5).

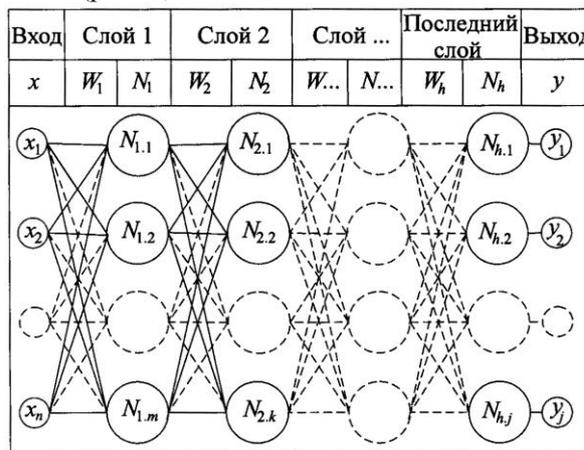


Рис. 5. Схема полносвязной многослойной искусственной нейронной сети (многослойный перцептрон)

В настоящее время существует множество алгоритмов обучения ИНС. В данной работе была реализована схема нейронной сети (НС) обратного распространения, алгоритм обучения которой 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 НС.

В общем случае задача обучения НС сводится к нахождению некой функциональной зависимости $Y = F(X)$ (фактически определению весов), где X – входной, а Y – выходной векторы на основе некоторых известных данных экспериментального, расчетного или иного характера. Таким образом в результате обучения система приобретает некоторый «опыт». В общем случае такая задача при ограниченном наборе входных данных имеет бесконечное множество решений. Для ограничения пространства при обучении ставят задачу минимизации целевой функции ошибки НС, которую находят по методу наименьших квадратов:

$$E(W) = \frac{1}{2} \sum_{jp} (OUT_{jp}^{(N)} - D_{jp})^2, \quad (1)$$

где $OUT_{jp}^{(N)}$ – реальное выходное состояние нейрона j выходного слоя N при подаче на входы НС p -го образа;

D_{jp} – идеальное (желаемое) состояние этого нейрона.

Рассмотрим полный алгоритм обучения нейросети, блок-схема которого представлена на рис. 6.

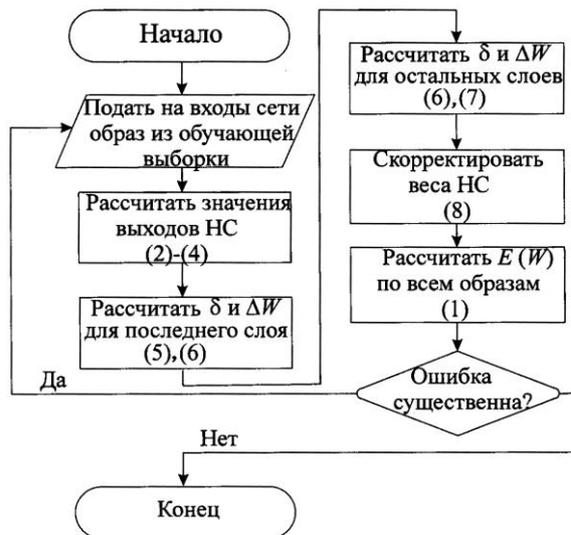


Рис. 6. Блок-схема алгоритма обратного распространения

1. Подать на входы сети один из возможных образов, рассчитать значения выходов согласно (2)–(4):

$$\text{NET}_j^{(n)} = \sum_{i=1}^M W_{ij}^{(n)} \times \text{OUT}_i^{(n-1)}, \quad (2)$$

где M – число нейронов в слое $n - 1$;

$\text{OUT}_i^{(n-1)} = X_{ij}^{(n)}$ – i -й вход нейрона j слоя n ;

$$\text{OUT}_j^{(n)} = F(\text{NET}_j^{(n)}), \quad (3)$$

где F – активационная функция;

$$\text{OUT}_q^{(0)} = X_q, \quad (4)$$

где X_q – q -ая компонента вектора входного образа.

2. Рассчитать $\delta^{(N)}$ и $\Delta W^{(N)}$ для выходного слоя по (5), (6):

$$\delta_l^{(N)} = (\text{OUT}_l^{(N)} - D_l) \frac{d\text{OUT}_l}{d\text{NET}_l}; \quad (5)$$

$$\Delta W_{i,j}^{(n)} = -\eta(\mu \Delta W_{i,j}^{(n)}(t-1) + (1-\mu)\delta_j^{(n)}\text{OUT}_i^{(n-1)}), \quad (6)$$

где η – коэффициент скорости обучения, $0 < \eta < 1$;

μ – коэффициент инерционности;

t – номер текущей операции.

3. Рассчитать $\delta^{(n)}$ и $\Delta W^{(n)}$ для всех остальных слоев:

$$\delta_j^{(n)} = \left[\sum_k \delta_k^{(n+1)} W_{jk}^{(n+1)} \right] \frac{d\text{OUT}_j}{d\text{NET}_j}. \quad (7)$$

4. Скорректировать веса ИНС:

$$W_{ij}^{(n)}(t) = \Delta W_{ij}^{(n)}(t) + W_{ij}^{(n)}(t-1). \quad (8)$$

5. Если ошибка существенна, то перейти на шаг 1. На этапе 1 сети поочередно, в случайном порядке, предъявляют вектора из обучающей последовательности.

В качестве тестового примера была построена и проанализирована модель износа ножа фрезы при обработке древесины различных пород. Использовались данные, приведенные в работе [3], где для прогнозирования стойкости инструмента применяли методы теории подобия. На основе опытных данных были выведены эмпирические зависимости интенсивности износа лезвия в зависимости от различных параметров обработки. Перечень и размерности параметров прогнозирующей системы, использованной в работе [2], приведены в табл. 1. В результате были получены следующие уравнения:

Таблица 1

Перечень и размерности параметров прогнозирующей системы

Параметр	Обозначение	Размерность в системе СИ
Прогнозируемые параметры		
Интенсивность изнашивания лезвия:		
по биссектрисе угла заострения	I_A	1
по передней поверхности	I_{II}	1
по задней поверхности	I_3	1
Прогнозирующие параметры, характеризующие лезвие		
Твердость	HV	$L^{-1}MT^{-2}$
Теплопроводность	λ	$LMT^{-3}\theta^{-1}$
Объемная теплоемкость	$c\rho_1$	$L^{-1}MT^{-2}\theta^{-1}$
Прогнозирующие параметры, характеризующие обрабатываемый материал		
Плотность	ρ_2	ML^{-3}
Кислотное число	pH	1
Прогнозирующие параметры, характеризующие износ лезвия		
Средняя толщина срезаемого слоя	a_{cp}	L
Длина срезаемого слоя	l	L
Скорость резания	v_r	LT^{-1}

$$I_A = 5,52 \cdot 10^{-6} \left(\frac{\lambda}{c\rho_1 a_{cp}} \sqrt{\frac{\rho_2}{HV}} \right)^{0,527} \left(\frac{\lambda}{c\rho_1 v_r l pH} \right)^{0,238};$$

$$I_{II} = 5,66 \cdot 10^{-10} \left(\frac{\lambda}{c\rho_1 a_{cp}} \sqrt{\frac{\rho_2}{HV}} \right)^{0,1} \left(\frac{\lambda}{c\rho_1 v_r l pH} \right)^{-0,21};$$

$$I_3 = 8,15 \cdot 10^{-9} \left(\frac{\lambda}{c\rho_1 a_{cp}} \sqrt{\frac{\rho_2}{HV}} \right)^{0,151} \left(\frac{\lambda}{c\rho_1 v_r l pH} \right)^{-0,0072}.$$

На основе опытных данных была построена обучающая выборка и обучена ИНС, топология которой представлена на рис. 7. Обучение проводили в пределах 10 тыс. итераций (шагов алгоритма). После обучения системы на вход подавали различные значения прогнозирующих параметров, а на выходе определяли прогнозируемые.

Экспериментальные данные сопоставляли с рассчитанными по эмпирическим зависимостям и с полученными в результате моделирования при помощи аппарата ИНС. Результаты сопоставления представлены в табл. 2. На основании сравнения результатов можно сделать вывод о достаточной точности прогноза ИНС.

Рис. 7. Топология искусственной нейронной сети, использованной для численного эксперимента ($a_{kv} = \lambda/c\rho_1$, остальные обозначения см. в табл. 1)

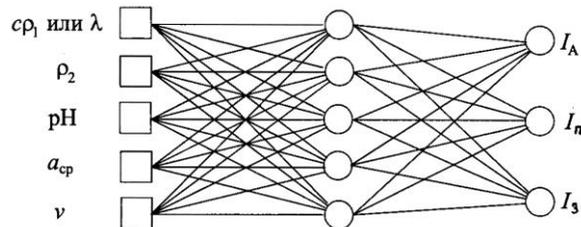


Таблица 2

Сопоставление экспериментальных данных с данными, полученными по эмпирическим зависимостям (ЭЗ) и рассчитанными с применением ИНС

Отношение теплопроводности лезвия к его объемной теплоемкости, м ² /с	Плотность обрабатываемого материала, кг/м ³	Кислое число	Средняя толщина срезаемого слоя, м	Скорость резания, м/с	Выходные данные (эксперимент, расчет по ЭЗ, расчет по ИНС)		
					I_A	$I_{П}$	I_3
5,40E-06	400	5,5	8,00E-05	46	6,240E-10	2,98E-09	1,57E-09
					6,50E-10	2,90E-09	3,40E-09
					6,98E-10	2,84E-09	1,70E-09
5,40E-06	400	5,5	1,60E-04	46	4,92E-10	2,58E-09	1,74E-09
					4,50E-10	3,20E-09	3,50E-09
					4,80E-10	2,55E-09	1,66E-09
5,40E-06	400	5,5	8,00E-05	23	8,28E-10	2,71E-09	2,04E-09
					7,60E-10	2,70E-09	3,80E-09
					7,77E-10	2,89E-09	1,79E-09
5,40E-06	400	5,5	1,60E-04	23	5,32E-10	2,62E-09	1,59E-09
					5,30E-10	2,80E-09	3,90E-09
					5,49E-10	2,58E-09	1,73E-09
5,40E-06	700	4	8,00E-05	46	8,40E-10	3,22E-09	1,60E-09
					8,10E-10	2,90E-09	3,80E-09
					8,61E-10	3,06E-09	1,72E-09
5,40E-06	500	7,5	8,00E-05	46	5,08E-10	5,08E-10	5,08E-10
					6,40E-10	2,80E-09	3,40E-09
					4,60E-10	6,28E-10	4,46E-10
7,30E-06	400	5,5	8,00E-05	46	7,44E-10	5,69E-09	2,74E-09
					8,10E-10	3,00E-09	3,40E-09
					1,63E-09	6,70E-09	4,40E-09
7,30E-06	400	5,5	8,00E-05	46	2,53E-09	7,54E-09	6,10E-09
					9,10E-10	3,90E-09	3,40E-09
					1,63E-09	6,70E-09	4,41E-09

В заключении следует отметить, что подход, основанный на использовании нейронных сетей, дает возможность в качестве целевых полей (выходов) определять и входы системы или несколько входов и (или) выходов, что в случае недостаточности информации о входных или выходных данных позволяет количественно прогнозировать неизвестные параметры, поскольку обученная сеть содержит сведения о взаимном влиянии всех входов на все выходы. Немаловажным аспектом также является тот факт, что векторы входных и выходных сигналов могут содержать компоненты, выраженные в виде логических функций или текстовой информации, отражающие, в том числе, и некоторые субъективные оценки объекта исследования проектировщиком.

СПИСОК ЛИТЕРАТУРЫ

1. Горбань, А.Н. Нейроинформатика [Электронный ресурс] / А.Н. Горбань. – Загл. с экрана.
2. Заенцев, И.В. Нейронные сети: основные модели [Электронный ресурс] / И.В. Заенцев. – Загл. с экрана.
3. Зотов, Г.А. Повышение стойкости дереворежущего инструмента [Текст] / Г.А. Зотов, Е.А.Памфилов. – М.: Экология, 1991. – 304 с.

Севмашвutz

Поступила 15.12.04

V.I. Malygin, L.V. Kremleva, K.L. Shestakov

Project Solutions of Woodworking Technology

Technique for woodworking process optimization at its projecting phase by using artificial neural networks is given.

