

Г. Н. Пащенко, к.т.н.

Институт проблем информатики и управления

ПОДХОД К ПОСТРОЕНИЮ НЕЙРОСЕТЕВОЙ МОДЕЛИ ДЛЯ ТЕХНОЛОГИЧЕСКОГО ПРОЦЕССА ВАРКИ СТЕКЛА

С использованием многослойных нейронных сетей построена модель функциональных взаимосвязей между технологическими факторами и показателями качества продукции в технологическом процессе варки стекла. Приведенный алгоритм для построения математической модели технологического процесса варки стекла позволяет облегчить построение математических моделей различных технологических процессов. Применение полученных моделей в решении различных задач, способствует повышению качества продукции за счет соблюдения технологических процессов и увеличению коэффициента использования материала.

Ключевые слова: нейронная сеть, математическая модель, технологический процесс.



Көпқабатты нейрон желісін қолдану арқылы технологиялық факторлар мен шыны қайнату технологиялық үдерісіндегі өнімнің сапа көрсеткіші арасындағы функционалдық өзара байланыс моделі құрылды. Шыны қайнату технологиялық үдерісінің математикалық моделін құру үшін келтірілген алгоритм әр түрлі технологиялық үдерісте математикалық модель құруды жеңілдетеді. Әр түрлі есептерді шешуде алынған модельдерді қолдану технологиялық үдерістерді сақтау және материалды пайдалану коэффициентін арттыру есебінен өнім сапасын жақсартуға мүмкіндік береді.
Түйінді сөздер: нейрондық желі, математикалық модель, технологиялық үдеріс.



A model of functional interrelations between technology factors and parameters of quality of production in technological process of glass melting is constructed with the use of multilayered neural networks. The resulted algorithm for construction of mathematical model of technological process of glass melting allows to facilitate the construction of mathematical models of various technological processes. Application of the received models in the solution of various problems promotes improvement of quality of production due to observance of technological processes and increase of the operating ratio of material.

Key words: neural network, mathematical model, technological process.

Интеллектуальные системы на основе искусственных нейронных сетей позволяют решать задачи выполнения прогнозов, оптимизации, распознавания образов и управления [1]. Одной из областей применения инструментов теории искусственных нейронных сетей является моделирование сложных технологических процессов. К моделям предъявляются особые требования, так как они должны отражать информационные и функциональные зависимости между технологией производства и свойствами получаемой продукции, отвечающими за ее качество. Если известны системы уравнений, описывающие поведение объекта, то часто оказывается, что нет данных о величине отдельных параметров [2]. Принятая при проектировании модель может только приблизительно отражать объект, поэтому возникает ошибка при управлении с помощью такой модели. Модели в этом случае становятся очень громоздкими и их приходится упрощать, что, в свою очередь, тоже влияет на решение поставленной задачи, не всегда приводит к ее решению. Альтернативным методом моделирования являются искусственные нейронные сети, так как нейронная сеть обладает способностью к накоплению и последующему использованию знания [3].

В работах [4-8] рассматриваются случаи, когда нейронная сеть используется для построения модели технологического процесса и обучается на основе реальных данных. Проблемы разработки

и исследования нейросетевых инструментов моделирования и управления сложными технологическими процессами, математическое моделирование технологических процессов с использованием нейронных сетей представлены в работах российских ученых П.А. Домашнева и Е.В. Парфенова. В данных работах показано, что применение нейронных сетей для моделирования технологических процессов позволяет повысить эффективность систем управления качеством, поскольку предоставляет необходимый объем информации о процессе и дополнительные инструменты исследования, анализа и управления.

Совершенствование производства – это то, что необходимо для повышения экономической эффективности любого промышленного предприятия, в том числе стекольного [9, 10]. Определенные показатели стекловарения можно улучшить за счет модифицирующих оксидов, которые вводят в процессе варки стекол [11]. Построение адекватной модели технологического процесса варки стекла, на основе которой может быть эффективно осуществлен процесс управления, является актуальной задачей.

Технологический процесс варки стекла является одним из этапов технологического процесса стеклотарного предприятия. Управление варкой стекла – сложная задача. Как правило, эффективность производства стекла зависит от различных факторов, таких, как параметры варки, формования, отжига и резки стекла. Качество стекла при этом определяется точностью поддержания набора этих параметров на различных этапах технологического процесса его варки.

Варка технологического процесса значительно ускоряется при введении различных оксидов. Так, при введении небольших количеств оксида B_2O_3 ускоряется варка и улучшаются выработочные характеристики, что особенно заметно при механизированном формовании. Глинозем Al_2O_3 повышает

механическую прочность, а также термическую и химическую стойкость стекол.

Постановка задачи формулируется следующим образом: необходимо с помощью многослойных нейронных сетей построить модель функциональных взаимосвязей между технологическими факторами и показателями качества продукции, а также другими требуемыми показателями в сложном технологическом процессе варки стекла.

Модель строится на основе многослойного персептрона. Моделируемыми технологическими параметрами были выбраны следующие: концентрации содержания оксидов A_2O_3 и B_2O_3 , влияющие на скорость протекания технологического процесса. В качестве моделируемых показателей качества технологического процесса выбраны основные характеристики свойств полученной продукции: твердость стекла H и его толщина h . При построении данной модели первоначально выбиралось небольшое количество моделируемых параметров для того, чтобы проверить корректность функционирования данной модели. В дальнейшем количество моделируемых параметров планируется увеличить.

Нейронная сеть состоит из нескольких слоев нейронов (общее число слоев – K , при этом входной слой считается нулевым), которые получают, обрабатывают и передают информацию относительно связей входных параметров и соответствующих откликов. Нейронная сеть имеет один входной слой, один выходной слой и как минимум один скрытый слой. Количество входов и выходов сети определяем по количеству входных и выходных параметров исследуемого технологического процесса. Число нейронов скрытого слоя выбирается чисто эмпирическим путем. Как правило, данное количество определяется следующим образом: $n_{\alpha} + n_{\text{вых}}$, где n_{α} , $n_{\text{вых}}$ – количество нейронов во входном и в выходном слое.

Во входном слое имеем N образов x , в выходном слое – Q образов y . В сеть входит промежуточный слой нейронов. Эти нейроны выполняют классификацию и выделение признаков по информации, обеспечиваемой входными и выходными слоями:

$W_{i,j}^{(k)}$ – весовой коэффициент синаптической связи, соединяющий j -ый нейрон слоя $(k-1)$ с i -ым нейроном слоя k ;

$S_i^{(k)}$ – вход i -го нейрона в k -ом слое;

$f_i^{(k)}$ – вычисленный выход i -го нейрона в k -ом слое;

d_i – требуемый выход i -го нейрона.

Величина $S_i^{(k)}$ является взвешенной суммой входных сигналов нейрона и представлена формулой (1):

$$S_i^{(k)} = \sum_{j=0}^L f_j^{(k-1)} \cdot W_{i,j}^{(k)}, \quad (1)$$

где L – число нейронов в слое $(k-1)$ с учетом нейрона с постоянным выходным состоянием $+1$, задающим смещение.

Для обучения нейронной сети использовался алгоритм обратного распространения ошибки [12-14], в котором при правильном функционировании сети ошибка распространяется от выходного слоя к входному в направлении, противоположном направлению распространения сигнала. Нейронная сеть обратного распространения состоит из нескольких слоев нейронов, где каждый нейрон слоя i связан с каждым нейроном слоя $i+1$, т.е. в данном случае речь идет о полносвязной нейронной сети. Выбранный алгоритм является эффективным алгоритмом для обучения многослойных нейронных сетей, с помощью которого успешно решаются многочисленные практические задачи. При формировании примеров учитываются входные параметры, которые влияют на выходной вектор.

На вход сети поочередно подаются все обучающие примеры, выходные значения сети при этом сравниваются с желаемыми значениями и вычисляется погрешность. Началу обучения предшествует процедура выбора функции активации нейронов. Функция активации является выходом нейрона. Выбрана сигмоидальная функция активации, которая наделяет нейронную сеть способностью создавать модели с дополнительной степенью свободы:

$$f_i^{(k)} = \frac{1}{1 + e^{-s_i^{(k)}}} \quad (2)$$

Основным достоинством данной функции является то, что она дифференцируема на всей оси абсцисс и имеет простую производную.

Для обучения нейронной сети весовые коэффициенты выбираются случайным образом. Следовательно, реальное выходное значение нейронной сети Y сначала также является случайной величиной. Обучающее множество $\{X, D\}$ состоит из следующих пар: вход сети и желаемый выход.

Обучение нейронной сети состоит в подборе весовых коэффициентов таким образом, чтобы минимизировать целевую функцию. В качестве целевой функции была выбрана сумма квадратов ошибок сети на примерах из обучающего множества:

$$E(w) = \sum_{j,p} (y_{j,p}^{(N)} - d_{j,p})^2, \quad (3)$$

где $y_{j,p}^{(N)}$ – реальный выход N -го выходного слоя сети для p -го нейрона на j -м обучающем примере;

$d_{j,p}$ – желаемый выход. Минимизировав данный функционал, получаем решение по методу наименьших квадратов.

Процесс обучения нейронной сети представляет собой уточнение и коррекцию значений весов коэффициентов для отдельных узлов с помощью постепенного увеличения объема входной и выходной информации. В процессе обучения веса настраиваются так, чтобы сеть давала ответы, которые наиболее близки к правильным. На вход нейронной сети подаются входные значения, а на выходе сравнивают значения сети с реальным результатом, и в зависимости от степени их разногласия корректируют внутренние веса нейронов.

В результате обучения при помощи алгоритма обратного распространения нейронная сеть самостоятельно подбирает необходимые значения весов и строит модель, которая наиболее точно описывает исследуемый процесс. Обучение нейронной сети прекращается, когда сеть работает удовлетворительно и ошибка достигла определенного уровня малости.

Построение модели функциональных взаимосвязей между технологическими факторами и показателями качества продукции в сложном технологическом процессе варки стекла с помощью нейросетевого аппарата осуществлялось по следующему алгоритму, состоящему из семи шагов.

Алгоритм:

Шаг 1. Выбор входных и выходных параметров модели.

Входной слой нейронов соответствует содержанию оксидов A_2O_3 и B_2O_3 , выходной слой – характеристикам результата технологического процесса твердости стекла H и его толщине h .

Шаг 2. Формирование примеров и содержимого входных и выходных векторов.

Числовые значения для входных параметров выбирались следующим образом: для оксида A_2O_3 в диапазоне 0,65-20,6%, для оксида B_2O_3 – в диапазоне 4-12%. Числовые значения для толщины стекла h выбирались в диапазоне 3-6,5 мм. Твердость стекла зависит от химического состава и снижается с увеличением содержания щелочных оксидов. Стекла имеют различную твер-

дость в пределах 4000-10000 МПа, или по шкале Мооса – 6-7. В данных пределах были представлены значения для твердости стекла *H*.

Шаг 3. Проектирование нейронной сети: выбор структуры, определение числа слоев и количества нейронов.

Построенная модель функциональных взаимосвязей между технологическими факторами и показателями качества продукции состоит из 3-х слоев: два скрытых слоя и один выходной слой. Входной слой называется нулевым слоем и не принимается во внимание при подсчете слоев. Первый скрытый слой состоит из 10 нейронов. Второй скрытый слой содержит 5 нейронов. Выходной слой имеет 2 выхода.

Шаг 4. Выбор алгоритма обучения нейронной сети.

Для обучения нейронной сети использовался алгоритм обратного распространения ошибки. Алгоритм обратного распространения ошибки является одним из методов обучения многослойных нейронных сетей прямого распространения, называемых также многослойными персептронами.

Выбирались различные методы обучения, такие, как метод градиентного спуска, метод градиентного спуска с адаптивным обучением, метод регуляризации Bayesian и метод случайных приращений. Сравнивались между собой сети, обученные различными методами, и выбирался метод, удовлетворяющий необходимым требованиям, а именно высокой скорости обучения.

Шаг 5. Обучение нейронной сети.

Обучение сети с помощью выбранного алгоритма предполагает 2 прохода по слоям сети: прямой и обратный. Во время прямого прохода входной вектор подается на входной слой нейронной сети и распространяется по сети от слоя к следующему. При этом генерируются выходные сигналы, которые являются реакцией сети на входной образ. Во время данного прохода все синаптические веса сети являются фиксированными. При обратном проходе все синаптические веса настраиваются в соответствии с правилом коррекции ошибок, т.е. находится разность между

желаемым и фактическим выходом сети. Результат формирует сигнал ошибки. Данный сигнал в дальнейшем распространяется по сети в направлении, обратном направлению синаптических связей. Синаптические веса настраиваются таким образом, чтобы максимально приблизить выходной сигнал сети к желаемому. Первоначальные числовые значения для весовых коэффициентов задавались в пределах от 0.1 до 1. В качестве функции активации была выбрана сигмоидная функция активации.

Шаг 6. Проверка и оптимизация нейронной сети.

На данном этапе возможны многократные обращения ко всем предыдущим шагам данного алгоритма. Производится расчет ошибки, осуществляется коррекция весов нейронной сети.

Шаг 7. С использованием многослойных нейронных сетей построена модель функциональных взаимосвязей между технологическими факторами и показателями качества продукции в технологическом процессе варки стекла.

Проведено обучение полученной модели в приложении Neural Network Toolbox системы MATLAB с использованием различных методов обучения нейронных сетей.

Проведен анализ полученных результатов. В процессе анализа для обучения нейронных сетей выбран один из алгоритмов обратного распространения ошибки – метод градиентного спуска в качестве самого эффективного при обучении нейронных сетей.

Разработанную и обученную нейронную сеть можно использовать для решения обратной задачи. Осуществляется это следующим путем: задавая желаемые значения N и h , можно рассчитать требуемые значения вводимых в технологическом процессе оксидов. Функционирование полученной модели технологического процесса варки стекла на реальных экспериментальных данных проводилось с использованием различных численных данных из указанных диапазонов.

Проведен анализ адекватности модели посредством экспериментов по проверке работоспособности и эффективности

полученной модели [15]. Лучшим методом обучения модели в результате экспериментов оказался метод градиентного спуска, так как для данного метода требуется меньшее количество итераций для обучения, т.е. преимущество в скорости обучения сети. Применение нейросетевого механизма позволило более полно отразить функциональные взаимосвязи между технологическими факторами и показателями качества продукции в сложном технологическом процессе варки стекла.

Таким образом, с использованием многослойных нейронных сетей построена модель функциональных взаимосвязей между технологическими факторами и показателями качества продукции в сложном технологическом процессе варки стекла. Полученная модель позволяет успешно применять ее в решении различных задач, способствуя повышению качества продукции за счет соблюдения технологических процессов и увеличения коэффициента использования материала.

Литература

1 *Омату С., Халид М., Юсоф Р.* Нейроуправление и его приложения. Кн.2 // Нейроконтроллеры и их применение / под ред. А.И.Галушкина, В.А.Птичкина. – М.: ИПРЖР, 2000. – 272 с.

2 *Бахметова Н. А., Токарев С. В.* Моделирование технологических процессов с помощью нейронных сетей // Современные наукоемкие технологии. – 2008. – №2. – С.139-140.

3 *Мухопад Ю. Ф., Пашков Н. Н., Сизых В. Н.* Адаптивный подход к нейронному управлению одним классом абсолютно устойчивых систем // Фундаментальные исследования. – 2011.– №8. (1). – С.139-147.

4 *Viharos Zs. J., Monostori L.* A general ANN-based cutting model and its application in different phases of manufacturing. MicroCAD '99. // Proceedings of International Conf. on Computer Research. – Hungary: University of Miskolc, 1999. – P.123-129.

5 *Viharos Zs. J., Monostori L.* Automatic input-output configuration of ANN-based process models and its application in machining

// Lecture Notes of Artificial Intelligence – Multiple Approaches to Intelligent Systems. – Cairo, 1999. – P.659-668.

6 *Ko J. K., Cho D. W.* Adaptive Modelling of the Milling Process and Application of a Neural Network for Tool Wear Monitoring // Proceedings of the International Journal of Advanced Manufacturing Technology. – 1996. – №12. – P.5-13.

7 *Viharos Zs. J.* Solutions of various assignments in different levels of machining using a general ANN-based process model // MOSYCUT – Model-based monitoring systems for cutting tools and processes. – Ljubljana, 1998. – P.65-72.

8 *Dini G.* A neural approach to the automated selection of tools in turning// Proceeding of 2-nd AITEM conference. – Padova, 1995. – P.1-10.

9 *Редько С. Г., Морозова Е. В.* Функционально-структурное моделирование технологических процессов стеклотарного производства // Современные проблемы науки и образования. – 2009. – №6. – С.116-121.

10 *Зубанов В. А., Чугунов Е. А., Юдин И. А.* Механическое оборудование стекольных и ситалловых заводов. – М.: Машиностроение, 1984. – 368с.

11 *Андреев Е. С.* Пути рационального использования материальных ресурсов в народном хозяйстве. – М.: Наука, 1975. – 96с.

12 *Иващук О. А.* Управление качеством и экологической безопасностью ремонтного производства на основе компьютерного моделирования // Современные наукоемкие технологии. – 2005. – №4. – С.23-25.

13 *Круглов В. В., Борисов В. В.* Искусственные нейронные сети. Теория и практика. – М.: Горячая линия – Телеком, 2001. – 382с.

14 *Стариков А. А.* Нейронные сети – математический аппарат. – <http://www.basegroup.ru>.

15 *Пащенко Г. Н.* О построении нейросетевой модели для технологического процесса варки стекла // Вестн. Нац. инж. акад. РК. – 2013. – №4. – С.40-44.