

Для индукторов простой формы применяются общепринятые методики расчета конструктивных параметров [15]. Исключения составляют индукторы специальной формы и назначения, для которых может варьироваться один или несколько параметров геометрии в сочетании с режимами работы генератора (мощность и частота) [16]. В этом случае поиск оптимального решения может быть также автоматизирован, по изложенной выше методике выбора охлаждающей среды. Как и в предыдущем случае возможно использование ряда расчетов электромагнитной задачи под управлением алгоритма оптимизации. Целевой функцией обычно служит термический КПД индуктора.

Одним из распространенных методов индукционного нагрева длинномерных заготовок является сканирующий метод. Искомыми параметрами в этом случае являются скорость движения индуктора, частота и мощность генератора. Наиболее распространенные направления оптимизации в этом случае: обеспечение равномерного нагрева при минимальном температурном градиенте во время проведения процесса и по всему сечению детали; обеспечение заданной глубины упроченного слоя (для случая, когда охлаждение происходит за счет теплопередачи вглубь от поверхности детали).

Заключение. Эффективным направлением ускорения технологической подготовки процессов индукционной закалки и сокращение сроков их внедрения в производстве является применение современных методов инженерного анализа и оптимизации. Существующие коммерческие программные средства на сегодняшний день не позволяют провести комплексный анализ и оптимизацию этого высокоэффективного энергосберегающего процесса. Разработанный авторами статьи программный комплекс KMTP Framework предоставляет широкие возможности решения прямых и обратных задач моделирования процессов термообработки. С помощью реализованных в разработке методов и моделей возможно обеспечение оптимизации формирования требуемой структуры и свойств материала детали, начиная с выбора химического состава стали, конструктивных параметров индуктора и заканчивая определением режимов термообработки.

СПИСОК ЦИТИРОВАННЫХ ИСТОЧНИКОВ

1. Кундас С.П., Лемзиков А.В., Коваленко В.И., Иванов Д.Г. Эффективность применения индукционного оборудования в процессах термообработки / *Материалы, технологии и оборудование в производстве, эксплуатации, ремонте и модернизации машин*. Том II. - Новополоцк: ПГУ, 2007. - С. 59-62
2. Интернет-ресурс <http://www.mssoftware.com>
3. Интернет-ресурс <http://www.deform.com>
4. Кундас С.П. Компьютерное моделирование процессов термической обработки сталей. - Мн.: Бестпринт, 2005. - 313 с.

5. Кундас С.П., Лемзиков А.В., Гурченко П.С. Система компьютерного управления процессом закалки / *Технология, оборудование, автоматизация, неразрушающий контроль термических процессов на машиностроительных предприятиях*: Сб. научных трудов под ред. П.С. Гурченко. - Мн.: РДУП "Издательство ОСПИ", 2005. - С. 63-65.
6. Лемзиков А.В., Кундас С.П. Применение экспертных систем для автоматизированного управления процессом закалки / *Сборник материалов IV Международной научно-технической конференции «Проблемы проектирования и производства радиоэлектронных средств»*. В 2-х томах. Том 2. - Новополоцк: ПГУ, 2006. - С. 92-96.
7. Кундас С.П., Иванов Д.Г., Гишкелюк И.А. Совместное решение электромагнитной и тепловой задач при моделировании индукционного нагрева // *Известия Белорусской инженерной академии*, 2005. № 1(19)/2. - С. 51-53.
8. Кундас С.П., Тонконогов Б.А., Гишкелюк И.А., Лемзиков А.В., Иванов Д.Г., Коваленко В.И. Компьютерное моделирование и исследование теплофизических процессов в металлических деталях при закалке // *Известия Белорусской инженерной академии*, 2003. - № 1(15)/2. - С. 168-175.
9. Кундас С.П., Гишкелюк И.А., Тонконогов Б.А., Лемзиков А.В., Иванов Д.Г. Моделирование напряженно-деформированного состояния стальных деталей при закалке // *Деформация и разрушение материалов*, 2005. Т. 5. - С. 37-47.
10. Кундас С.П., Гишкелюк И.А., Иванов Д.Г. и др. Математическое моделирование индукционной закалки с применением метода конечных элементов // *Материалы Междунар. конф. «Актуальные проблемы теории и практики индукционного нагрева»*. - СПб.: ГЭТУ «ЛЭТИ» 2005. - С. 292-299.
11. Saunders N., Miodownik A. CALPHAD - Calculation of Phase Diagrams (Vol. 1). (R. Cahn, Ed.) Oxford: Elsevier Science, 1991. 128 p.
12. Лемзиков А.В., Иванов Д.Г., Кундас С.П., Куцыло В.В. Применение нейросетей для определения характерных точек фазовых превращений в сталях с различным химическим составом / *Информатика*. №1(13), 2007. - С.89-97.
13. Желудкевич М. С., Герман М. Л., Ознобишин А. Н. Управляемое водовоздушное охлаждение. - Мн: АНК ИТМО НАНБ, 2001. - 166 с.
14. Hui-pung, Li., Inverse heat conduction analysis of quenching process using finite-element and optimization method. Finite elements in analysis and design. 2006, №42, P. 1087-1096.
15. Semiatin S.L. and Stutz D.E. Induction Heat Treatment of Steel. Ohio : American Society for Metals, 1986. 308 P.
16. Design of complex induction hardening problems by the use of numerical simulation. Nacke, В. и E.Wrona. *Материалы Междунар. конф. «Актуальные проблемы теории и практики индукционного нагрева»*. - СПб.: СПбГЭТУ «ЛЭТИ», 2005. - С. 99-105.

Статья поступила в редакцию 29.10.2007

УДК 004.8.032.26; 691; 691:620.1

Лемзиков А.В., Кундас С.П., Куцыло В.В.

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ КОМПЬЮТЕРНОГО МОДЕЛИРОВАНИЯ ПРОЦЕССОВ ТЕРМООБРАБОТКИ

Введение. В настоящее время наметилась тенденция применения искусственных нейронных сетей (ИНС) при моделировании процессов термообработки в качестве элементов, производящих различного рода вычисления [1]. Наиболее востребованной областью, где использование ИНС позволяет

достичь существенного прогресса по сравнению с классическим подходом, является решение термодинамических задач, связанных с определением свойств сталей при различных условиях их обработки.

Куцыло Виталий Васильевич, инженер-программист, Центр 10.1, Белорусский государственный университет информатики и радиоэлектроники.

Машиностроение

Опыт исследований в рассматриваемой области показывает, что при моделировании такого процесса термообработки, как закалка, для уменьшения погрешности получаемых результатов необходимо учитывать эффект фазовых превращений в стали. В настоящее время для этой цели используются известные диаграммы фазовых переходов (термокинетические или изотермические) [2-4]. В то же время следует отметить, что не всегда можно найти диаграмму фазовых переходов для конкретной применяемой стали, заданной химическим составом легирующих элементов.

В связи с этим авторами были разработаны и обучены нейронные сети, позволяющие определять температуры, при которых происходит начало (Ac1) и конец (Ac3) образования аустенита в сталях различного химического состава в зависимости от скорости их нагрева, а также температуру начала образования мартенсита при охлаждении (Ms) [5].

В качестве одного из недостатков указанной разработки можно отметить необходимость формирования в диалоговом режиме структуры обучаемой нейросети (указать количество слоев и нейронов в них) до этапа обучения. Структура сети непосредственно влияет на способность ИНС обобщать обучающие данные и, следовательно, от выбора структуры зависит погрешность прогнозирования. В работе [5] проведена серия экспериментов по обучению сетей с различными структурами, и на основании анализа их погрешностей осуществлялся выбор оптимальной структуры. Такой подход отличается высокой трудоемкостью и требует определенных навыков от пользователя. Проблема состоит еще и в том, что универсального правила построения ИНС оптимальной архитектуры не существует – произвести точную оценку аппроксимирующих свойств сети выбранной архитектуры можно лишь после ее обучения.

Алгоритм понейронного наращивания. В качестве альтернативного подхода можно предложить использование алгоритма понейронного наращивания на этапе обучения ИНС. В настоящее время существуют деструктивные и конструктивные методы адаптации структуры. Деструктивные методы направлены на уменьшение архитектуры и подробно рассмотрены в работе [6]. Конструктивные методы представляют собой методы наращивания архитектуры ИНС на этапе обучения. К ним и относится предложенный метод понейронного наращивания. Его целью является уменьшение среднеквадратической ошибки аппроксимации ε , вычисляемой по формуле (1).

$$\varepsilon = \sqrt{\sum_k \frac{(y_k - t_k)^2}{N_k - 1}}, \quad (1)$$

где N_k – количество нейронов выходного слоя; y_k – значение k -го выходного нейрона; t_k – эталонное значение k -го выходного нейрона.

Рассмотрим предложенный алгоритм по шагам (рис. 1).

Шаг 1. Формируется нейронная сеть, состоящая из двух слоев: входного и выходного. Числа нейронов в слоях соответствуют количеству входных и выходных переменных соответственно.

Шаг 2. Задаются значения следующих величин: требуемой среднеквадратической ошибки аппроксимации ε обучения, количества добавляемых в слой нейронов за одну эпоху обучения N_A , максимального количества нейронов N_N в скрытом слое при наращивании, максимального количества скрытых слоев N_L , количества обучающих итераций в эпохе N_E , а также максимального количества итераций обучения N_T .

Шаг 3. Если обучающая эпоха, включающая N_E итераций, завершена, переход на шаг 4, иначе переход на шаг 8.

Шаг 4. Если при добавлении N_A нейронов в предпоследний слой их количество в нем не превысит максимальное N_N , переход на шаг 5, иначе переход на шаг 6.

Шаг 5. Добавление в последний скрытый слой N_A необученных нейронов. Переход на шаг 8.

Шаг 6. Если при добавлении скрытого слоя количество слоев не превысит максимальное N_L , переход на шаг 7, иначе переход на шаг 8.

Шаг 7. Добавление скрытого слоя с количеством нейронов N_A .

Шаг 8. Для всех обучающих пар осуществляется по одному шагу обучения.

Шаг 9. Определяется ошибка аппроксимации сети ε . Если она не меньше предыдущей, переход на шаг 11.

Шаг 10. Осуществляется сохранение состояния сети.

Шаг 11. Если достигнутая ошибка меньше требуемой, то переход на шаг 13.

Шаг 12. Если общее количество итераций не превышает N , возврат на шаг 3.

Шаг 13. Если сохраненная ошибка больше текущей, переход на шаг 15.

Шаг 14. Загрузка сохраненного состояния сети.

Шаг 15. Оптимальная структура сети найдена.

Результаты применения предложенного алгоритма.

Описанный алгоритм реализован в составе модуля нейронных сетей в программном комплексе КМТР Framework [7, 8]. Указанный модуль позволяет создавать, обучать, верифицировать и использовать нейронные сети для аппроксимации произвольных входных зависимостей. После добавления алгоритма понейронного наращивания было произведено переобучение нейронных сетей, прогнозирующих температуры Ac1, Ac3 и Ms.

Ранее, без применения указанного алгоритма, были получены структуры сетей, показанные в табл. 1.

Обучение нейронных сетей с применением алгоритма понейронного наращивания осуществлялось следующим образом. Создавалась сеть, содержащая один скрытый слой с единственным нейроном в нем. В качестве граничных условий алгоритма наращивания указывались параметры, показанные в табл. 2.

Максимальное число слоев нейросетей было ограничено значением 3, исходя из теоремы Колмогорова, согласно которой любую n -мерную задачу можно решить с помощью трехслойной нейронной сети, имеющей $2n+1$ нейронов в скрытом слое. Максимальное количество нейронов в слое взято равным 15, что примерно соответствует количеству входных параметров исследуемого процесса (12 входов для случая Ac1 и Ac3 и 15 для Ms).

Результаты обучения ИНС с применением алгоритма понейронного наращивания приведены в табл. 3.

Верификация результатов обучения производилась на четырех тестовых наборах данных, которые не участвовали в процессе обучения. Погрешность оценивалась путем вычисления среднеквадратического отклонения результатов прогнозирования нейросети от эталонных (экспериментальных) значений. В общем случае нейросети, обученные с применением нового алгоритма, показали результаты, сопоставимые с результатами сетей, созданных вручную. Однако анализ графических зависимостей результатов верификации показывает, что автоматически подобранная структура нейронной сети более близко аппроксимирует исходные данные, но имеют несколько всплесков, которые и обуславливают более высокую погрешность. Причиной всплесков может быть недостаточно проработанный критерий добавления нейронов, что приводит к чрезмерному разрастанию сети и ее «переобучению». Это можно отметить в качестве недостатка предложенного алгоритма, так как в результате его работы нейросеть имеет тенденцию к максимальному использованию всех

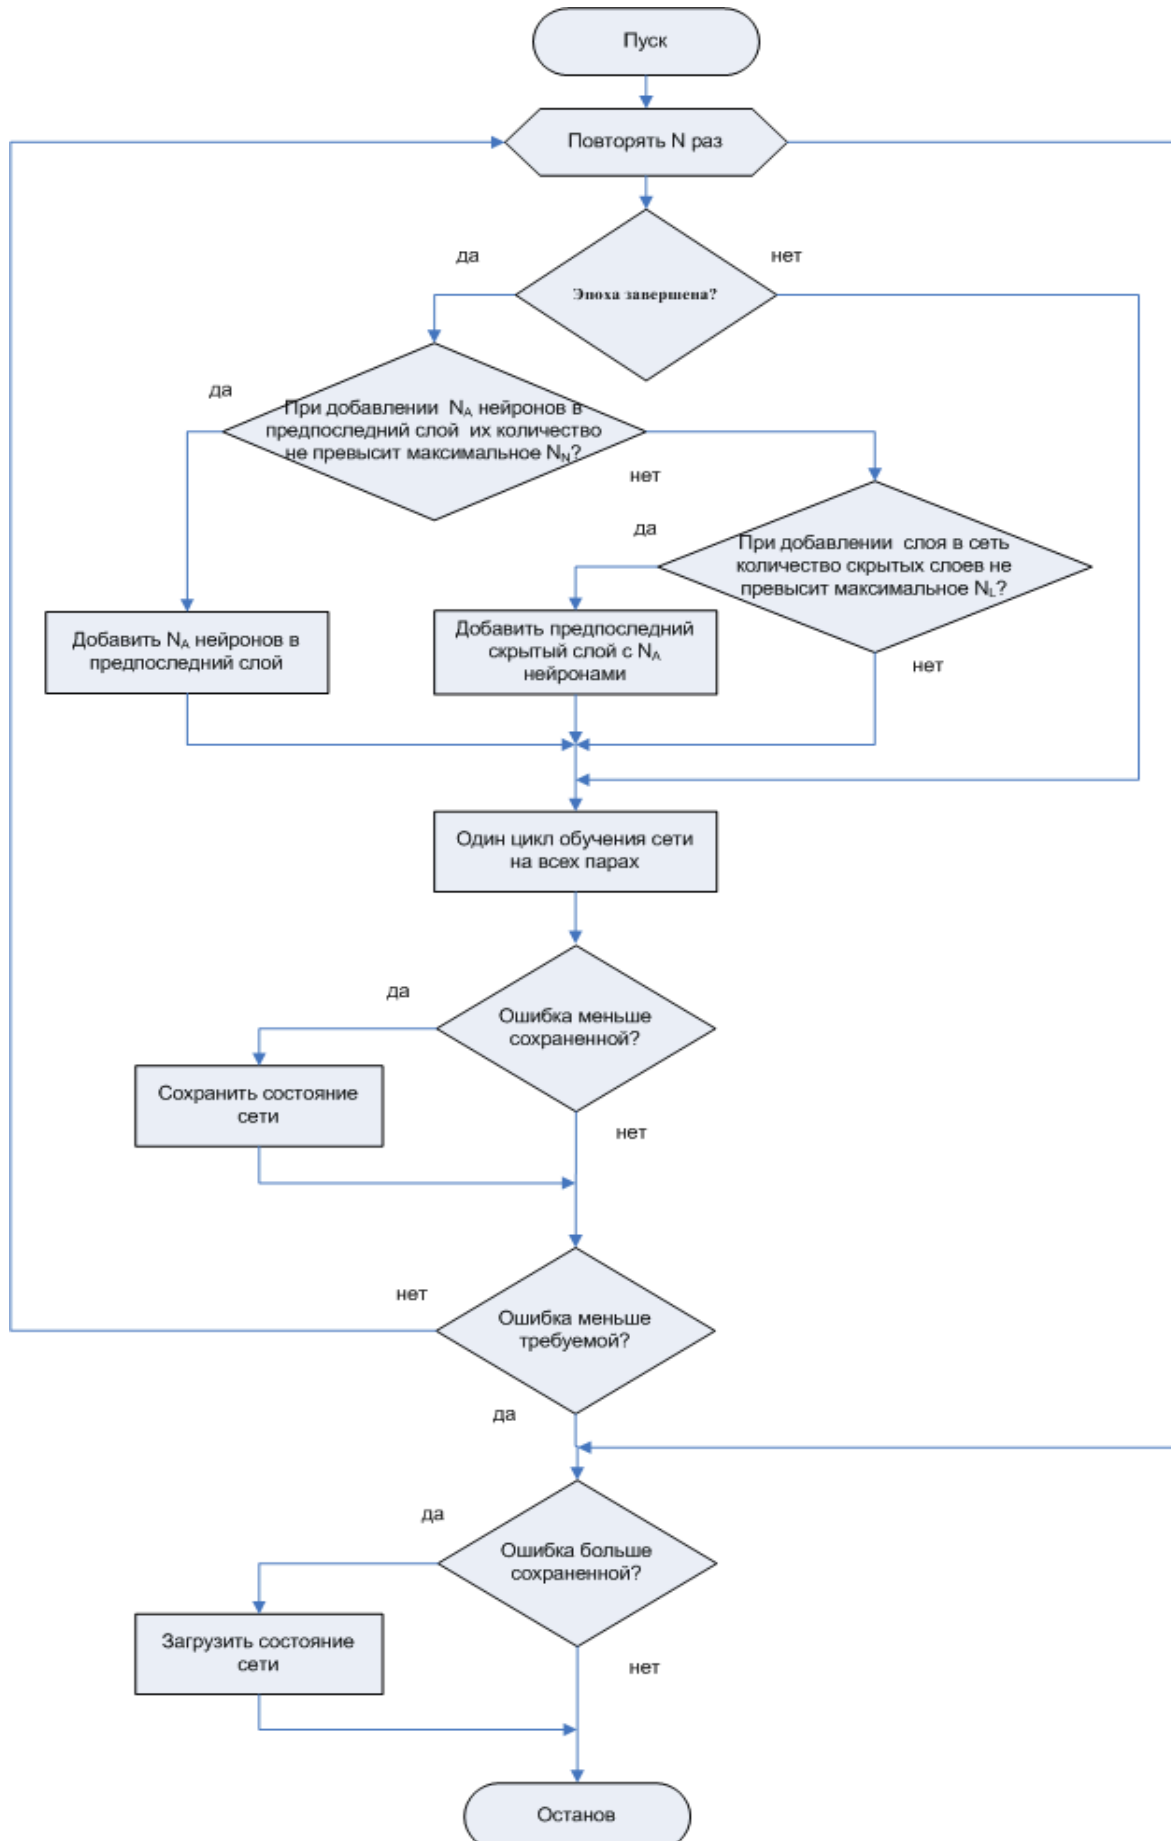


Рис. 1. Блок-схема алгоритма понейронного наращивания

Таблица 1. Параметры нейронных сетей, созданных ручным способом

Параметр	Ac1	Ac3	Ms
Структура сети (количество нейронов в слоях)	5-2	7	5-9
Погрешность 1	0,0346	0,0203	0,0644
Погрешность 2	0,0268	0,0194	0,0423
Погрешность 3	0,0336	0,0207	0,0612
Погрешность 4	0,0306	0,0239	0,0396

Таблица 2. Значения параметров алгоритма понейронного наращивания

Параметр	Значение
Максимальное число скрытых слоев	3
Максимальное число нейронов в слое	15
Количество добавляемых нейронов за шаг	1
Количество шагов между добавлением нейронов	1 000
Общее число шагов обучения	45 000

Таблица 3. Параметры ИНС, созданных с применением разработанного алгоритма

Параметр	Ac1	Ac3	Ms
Структура сети	15-15-10	15-15-5	15-15-7
Погрешность 1	0,0279	0,0285	0,0684
Погрешность 2	0,0378	0,0247	0,0505
Погрешность 3	0,0333	0,0236	0,0705
Погрешность 4	0,0376	0,0315	0,0515

доступных скрытых слоев. В этом случае только последний слой может содержать число нейронов, отличное от максимального, в то время как предыдущие слои заполнены нейронами до указанного предела. Определенная модификация алгоритма, возможно, позволит создавать сети, обладающие различным (и, возможно, более оптимальным) числом нейронов во всех скрытых слоях.

Можно предложить следующую модификацию алгоритма понейронного наращивания. В процессе обучения сети перед добавлением каждого нового слоя загружается та структура сети, которая на предыдущем этапе давала наименьшую погрешность. В результате этого количество нейронов в слоях в конце обучения не обязательно будет равно максимальному допустимому. Это позволит избежать эффекта переобучения сети, а также снизить вычислительную сложность последующего ее применения.

Кроме того, предложенный алгоритм подразумевает, что при добавлении нейрона в последний слой веса существующих нейронов остаются прежними и, следовательно, последующее обучение не обязательно влияет только на добавленный нейрон. Можно предложить сбрасывать все веса при добавлении нового нейрона. При этом обучение всей сети с новой структурой начнется заново, что, возможно, позволит ей выйти из устоявшегося режима и уменьшить результирующую погрешность. В этом случае необходимо увеличить количество шагов обучения между добавлениями новых нейронов для гарантированного обучения каждой отдельной структуры, что значительно увеличит время обучения сети в целом, однако такая модификация позволяет достичь меньшей погрешности каждого варианта структуры и, следовательно, более точно подобрать оптимальную структуру нейросети для решения поставленной задачи.

Еще одним вариантом применения автоматизации при разработке структуры нейронных сетей может быть алгоритм автоматического создания различных сетей с заданными входами и выходами. При использовании этого алгоритма пользователь задает количество входов и выходов нейронной сети, диапазоны их изменения и диапазоны изменения количества нейронов в слоях. Программа автоматически генерирует все возможные комбинации нейронных сетей с заданными количествами слоев и нейронов в них и поочередно обучает сети на указанной базе знаний. В этом методе отсутствует необхо-

димость в динамическом изменении структуры нейросетей, что положительно сказывается на достигаемой ими точности прогнозирования. В качестве недостатка предложенного метода можно отметить значительно возросшую вычислительную сложность обучения, а также необходимость вручную производить анализ результатов и выбор оптимальной структуры нейросети.

Заключение. Следует отметить, что применяя алгоритм понейронного наращивания, трудоемкость создания нейронной сети значительно меньше, чем в случае ручного подбора оптимальной структуры. Благодаря высокой автоматизации, задав несколько параметров перед началом обучения, пользователь получает нейронную сеть, аппроксимирующую исходные данные с точностью, достаточной для дальнейшего применения. В описанном случае погрешность прогнозирования температур Ac1, Ac3 и Ms не превышали 10% в обоих случаях.

Следовательно, использование предложенного алгоритма понейронного наращивания позволяет создавать и обучать нейронные сети, обладающие незначительной погрешностью, для последующего применения в задачах термообработки. В настоящее время нейронные сети, обученные с применением описанного алгоритма, применяются в составе программного комплекса ThermoSim 2 [9], моделирующего процесс закалки стальных изделий методом конечных элементов.

СПИСОК ЦИТИРОВАННЫХ ИСТОЧНИКОВ

1. Bhadeshia, H.K.D.H. Neural Networks in Materials Science / H.K.D.H. Bhadeshia // ISIJ International. – Vol. 39, 1999. – P. 966-979.
2. Кундас С. П., Тонконогов Б. А., Лемзиков А.В., Левашкевич Я. С., Юршевич Ю. Ф., Буйкевич Г. Л. Программный комплекс моделирования процессов термообработки / Проблемы проектирования и производства радиоэлектронных средств / Сборник материалов II Междунар. научн.-техн. конф. 15 - 17 мая 2002 г. Новополюк. Т. II. – С. 188-191.
3. Кундас С. П., Тонконогов Б. А., Лемзиков А.В., Левашкевич Я. С., Гишкелюк И. А., Гурченко П. С. Программный комплекс для моделирования процесса закалки стальных деталей / Технология, оборудование, автоматизация, неразрушающий контроль процессов нагрева и упрочнения

- деталей на машиностроительных предприятиях. – Мн.: УП "Технопринт", 2002. 163 с. Ил. – С. 109-112.
4. Кундас С. П., Тонконогов Б. А., Гишкелюк И. А., Лемзиков А.В., Левашкевич Я. С., Гурченко П. С. Компьютерное моделирование и исследование тепловых полей в металлических деталях в процессе закалки / Материалы, технологии и оборудование для упрочнения и восстановления деталей машин: Тематический сборник. – Мн.: УП "Технопринт"; Новополоцк: ПГУ, 2003. – С. 166-167.
 5. Лемзиков А.В., Кундас С.П., Куцыло В.В., Иванов Д.Г. Применение нейросетей для определения характерных точек фазовых превращений в сталях с различным химическим составом / Информатика. – Мн.: №1(13), 2007.
 6. Нейроинформатика / Горбань А.Н., Дунин-Барковский В.Л., Кирдин А.Н. и др. – Новосибирск: Наука. Сибирское предприятие РАН, 1998. – 296с.
 7. Кундас С.П., Лемзиков А.В., Иванов Д.Г., Коваленко В.И. Разработка структуры программного комплекса для моделирования технологических систем на основе динамически заменяемых модулей / Известия Белорусской инженерной академии, 2004 г., №1(17)/3 – С. 199-201.
 8. Кундас С.П., Лемзиков А.В., Коваленко В.И. Разработка гибридной экспертной системы для прогнозирования процесса закалки / Известия белорусской инженерной академии. Мн.: №1(19)/1, 2005. – С. 200-203.
 9. V. Demidovich, S. Kundas, D. Ivanov, A. Lemzikov, F. Tchmilenko Simulation of induction heat treatment as coupling of multiphysics phenomena / Heating by electromagnetic sources. Padua, University of Padua (Italy), 2007.

Статья поступила в редакцию 29.10.2007

УДК 621.762.001, 621.793.18

Шматов А.А., Побережный С.В.

СТРУКТУРА И ФАЗОВЫЙ СОСТАВ ДИФфуЗИОННЫХ Cr-Ti-Mo КАРБИДНЫХ СЛОЕВ НА ТВЕРДОМ СПЛАВЕ

Введение. Процессы нанесения многокомпонентных диффузионных карбидных покрытий на твердые сплавы пока недостаточно изучены. Причем наибольшее внимание уделяется двухкомпонентному диффузионному насыщению твердых сплавов карбидообразующими элементами, в то время как по трехкомпонентным диффузионным карбидным покрытиям практически не проведено никаких исследований [1-7].

До настоящего времени широкое промышленное применение получил порошковый способ химико-термической обработки (ХТО) с использованием герметичных контейнеров [8]. Этот наиболее простой и недорогой метод ХТО позволяет быстро разрабатывать двух- и трехкомпонентные диффузионные карбидные покрытия на твердых сплавах. Другие известные методы поверхностного упрочнения не всегда могут сформировать карбидные покрытия, одновременно легированные несколькими тугоплавкими металлами. К лучшим способам нанесения комплексных карбидов на поверхность твердосплавных изделий относятся PVD и CVD процессы, активируемые плазмой, магнетронный способ распыления. Данные процессы малопроизводительны, энергоемки, требуют применения дорогостоящего вакуумного оборудования и расхода дорогих компонентов [9,10].

Ранее авторы настоящей статьи в работе [11] провели сравнительный анализ свойств (твердости и износостойкости) одно-, двух- и трехкомпонентных карбидных слоев, полученных на твердых сплавах T15K6 и BK8 методом ХТО в 5-ти трехкомпонентных системах на основе: Cr-Ti-V, Cr-Ti-Mo, Cr-V-Mo, Cr-V-Nb и Ti-V-Mo. На основании полученных результатов были выбраны лучшие карбидные системы, в которых покрытия на твердых сплавах обладают максимальной износостойкостью. В частности, обработка в оптимальных составах порошковых сред на основе Cr-Ti-Mo, Cr-V-Mo и Ti-V-Mo, позволяет увеличить износостойкость твердого сплава T15K6 в 6,2 - 6,7 раза выше, по сравнению с необработанным. Однако исследования только свойств многокомпонентных карбидных слоев на твердом сплаве будут недостаточны без изучения их структуры, химического и фазового состава, кинетики их формирования, без выявления причин экстремального повышения износостой-

кости трехкомпонентных карбидных покрытий. Из-за большого объема поставленных задач в данной работе ограничились структурными исследованиями покрытий только в одной карбидной системе - на основе Cr-Ti-Mo, нанесенных на один тип твердого сплава - T15K6.

В связи с вышесказанным целью настоящей работы явилось проведение сравнительного анализа структуры, фазового состава и рабочих свойств диффузионных карбидных слоев, полученных на твердом сплаве путем их одно-, двух- и трехкомпонентного диффузионного насыщения хромом, титаном и молибденом.

Объекты и методика исследований. Одно-, двух- и трехкомпонентные карбидные покрытия в системе на основе карбидообразующих элементов Cr-Ti-Mo были получены на твердом сплаве T15K6 (79% WC, 15% TiC и 6% Co) высокотемпературным методом ХТО. Твердосплавные образцы помещали в контейнер из жаропрочной стали, заполненный специально приготовленной порошковой насыщающей смесью, которую герметично защищали плавким затвором. Затем контейнер с образцами был загружен в электрическую печь, разогретую до температуры 1100 °С, где выдерживали в течение 6 часов. Насыщающую смесь получали методом алюминотермии путем восстановлением оксидов металлов алюминием в порошковых смесях следующего состава, мас. %: 98% (50% Al₂O₃+35% Me_xO_y+15% Al)+1% NH₄Cl, где оксиды Me_xO_y = Cr₂O₃, TiO₂, MoO₃ являлись поставщиком карбидообразующих металлов. Предварительно восстановленную смесь размалывали и просеивали. Когда в нее дополнительно добавляли активатор (2% NH₄Cl), смесь для ХТО была готова к употреблению.

Структуру и фазовый состав карбидных покрытий изучали методами микроструктурного, дюротметрического, рентгеноструктурного и микрорентгеноспектрального анализов. Испытания на износостойкость твердосплавных режущих пластин T15K6 с карбидными покрытиями проводили путем токарного точения низколегированной конструкционной стали 40X (0.4% C, 1% Cr) при следующих условиях резания:

Шматов А.А., к.т.н., Белорусский национальный технический университет.

Беларусь, БНТУ, 220013, г. Минск, пр. Независимости, 65.

Побережный С.В., к.т.н., ГНУ «Институт порошковой металлургии».

Беларусь, 220000, г. Минск, ул. Платонова, 41.