

УДК 621.793:537.533.9

## ПРОГНОЗИРОВАНИЕ ТОЛЩИНЫ БОРОАЛИТИРОВАННОГО СЛОЯ С ИСПОЛЬЗОВАНИЕМ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ

© 2024 г. У. Л. Мишигдоржийн<sup>а, \*</sup>, Б. А. Дышенов<sup>а, \*\*</sup>, А. П. Семенов<sup>а</sup>, Н. С. Улаханов<sup>а</sup>,  
Б. Е. Мархадаев<sup>а</sup>

<sup>а</sup>Институт физического материаловедения СО РАН, Улан-Удэ, 670047 Россия

\*e-mail: undrakh@ipms.bscnet.ru

\*\*e-mail: dyshenov@gmail.com

Поступила в редакцию 27.07.2023 г.

После доработки 27.09.2023 г.

Принята к публикации 27.09.2023 г.

Рассмотрено применение математических моделей искусственных нейронных сетей для прогнозирования свойств диффузионных покрытий, созданных методом химико-термической обработки на основе процесса бороалитирования. Проведены формализация и анализ прогнозирования результатов экспериментов. Установлено, что построение компьютерных моделей прогнозирования на основе экспериментальных данных бороалитирования с высокой точностью – это решаемая задача при использовании искусственных нейронных сетей типа многослойный персептрон. Так, тестирование количества скрытых слоев и количества нейронов в них выявили наибольший коэффициент корреляции  $R = 0.99993$  искусственной нейронной сети при использовании двух скрытых слоев с десятью и шестью нейронами соответственно. Наибольшей эффективности можно достичь с помощью функции активации “гиперболический тангенс”.

**Ключевые слова:** химико-термическая обработка, бороалитирование, микроструктура, углеродистая сталь, искусственные нейронные сети, толщина слоя.

DOI: 10.31857/S1028096024040128, EDN: GIJGSW

### ВВЕДЕНИЕ

Синтез покрытий, содержащих бор и алюминий, как метод инженерии поверхности позволяет в значительной мере повысить износо-, жаро- и коррозионную стойкость, снизить коэффициент трения поверхности изделий деталей машин [1, 2]. Представляет значительный научный и практический интерес разработка новых подходов формирования бороалитированных покрытий методами химико-термической и электронно-пучковой обработки и легирования поверхности. Однако не в полной мере ясны механизмы формирования различных структур, содержащих бор и алюминий, при воздействии интенсивного ускоренного пучка электронов и при диффузионных процессах. Сведения о связи параметров химико-термической и электронно-пучковой обработки (температуры, длительности обработки, параметров электронного пучка) со структурой и свойствами бор- и

алюминийсодержащих слоев и покрытий носят фрагментированный характер, не позволяющий провести систематизацию и прогнозирование [3–10].

Перечисленные проблемы определили направление исследований, заключающееся в разработке теоретических методик систематизации и прогнозирования эксплуатационных характеристик изделий из углеродистых и легированных сталей путем рационального выбора технологии воздействия, параметров и составов защитных, содержащих бор и алюминий покрытий. Для достижения поставленной цели рассмотрим комплекс исследований, базирующихся на массиве экспериментальных данных. Результаты исследований создадут предпосылки для разработки методов имитационного компьютерного моделирования, позволят заложить научные основы формирования и прогнозирования параметров

покрытий, в частности бороалитированных. Ранее авторами были проведены расчеты с помощью аппарата нейронных сетей и математического планирования эксперимента [11–13]. Настоящая работа предполагает дальнейшее развитие этих исследований.

Целью настоящей работы было построение прогностической модели зависимости толщины диффузионного слоя от исходных параметров бороалитирования с использованием искусственных нейронных сетей.

### МЕТОДИКА ЭКСПЕРИМЕНТА И ПРАКТИЧЕСКИЕ РЕЗУЛЬТАТЫ

Метод порошкового бороалитирования заключается в диффузионном насыщении металлов в порошковой среде при повышенной температуре [14]. Нагрев осуществляли в лабораторной печи ПМ-16П-ТД при температуре 900–1000°C в течение 2–8 ч. Бороалитирование стальных образцов проводили в насыщающей порошковой смеси  $69.5\% \text{Al}_2\text{O}_3 + 30(x\% \text{B}_2\text{O}_3 + y\% \text{Al}) + 0.5\% \text{NaF}$  (мас. %) в тиглях (цилиндрические контейнеры из нержавеющей стали) с плавким затвором (рис. 1) [15]. В качестве исследуемого материала использовали конструкционную сталь 20. Процесс порошкового бороалитирования осуществляется поэтапно. Сначала подготавливают насыщающую смесь и вырезают образцы. В качестве компонентов насыщающей смеси использовали порошки борного ангидрида  $\text{B}_2\text{O}_3$ , алюминия Al (ЧДА, ТУ 6-09-3742-87), оксида алюминия  $\text{Al}_2\text{O}_3$  (ЧДА, ТУ 6-09-426-75), фторида натрия NaF (ЧДА, ГОСТ 4463-66). Оксид алюминия предварительно прокаливали при 800°C в течение 2 ч. Затем навеску порошков смешивали в планетарной мельнице. Образцы размером  $10 \times 12 \times 20$  мм вырезали из сталь-

ных заготовок в отожженном состоянии, затем шлифовали и полировали. Далее осуществляли упаковку тигля. Подготовленную насыщающую смесь и стальные образцы загружали в тигель, так чтобы расстояние до стенок тигля и между образцами было не менее 15–20 мм. Последовательно укладывали лист асбеста, слой кварцевого песка толщиной 20–30 мм и слой плавкого затвора из борного ангидрида. Готовый тигель загружали в предварительно нагретую до заданной температуры печь. В процессе выдерживания при заданной температуре происходит инициация химических реакций в насыщающей смеси и образуются активные атомы бора и алюминия. В результате их дальнейшей адсорбции и диффузии на поверхности стали формируются бориды и алюминиды железа. По истечении времени выдерживания тигель охлаждали вне печи на спокойном воздухе при комнатной температуре. Далее тигли вскрывали, образцы зачищали от остатков насыщающей смеси и подвергали стандартной процедуре приготовления микрошлифов, заключающейся в последовательных операциях: очистке в ультразвуковой ванне, разрезании, шлифовании на абразивной бумаге различной зернистости и полировании на сукне при подаче суспензии. Для выявления микроструктуры полированные образцы подвергали химическому травлению четырехпроцентным раствором азотной кислоты в этиловом спирте.

В результате порошкового бороалитирования на поверхности стали 20 формируются слои толщиной от 30 до 260 мкм (рис. 2). В этом процессе выделим состав насыщающей смеси и условия насыщения, влияющие на получаемый результат. Состав насыщающей смеси зависит от требований, предъявляемых к свойствам упрочненного материала. Для достижения определенных свойств, например, повышенной износостойкости, содержание борного ангидрида в смеси должно быть не менее 50 мас. %. Выразим состав смеси через формулу:

$$x_1S + x_2S + x_3S + x_4S = S, \quad (1)$$

где  $S$  — масса итоговой шихты,  $x_1, x_2, x_3, x_4$  — массовые доли  $\text{Al}_2\text{O}_3$ ,  $\text{B}_2\text{O}_3$ , Al и NaF соответственно. Условия насыщения — температура  $t$ , °C, и время выдерживания  $T$ , ч.

### ПОСТАНОВКА МАТЕМАТИЧЕСКОЙ ЗАДАЧИ

Известно, что бороалитирование улучшает твердость, износостойкость, жаростойкость поверхностного слоя сплавов [1]. Одним из существенных факторов работоспособности





Рис. 1. Схема упаковки тигля со стальным образцом.



**Рис. 2.** Микроструктуры бороалитированных слоев на стали 20 после термообработки при 900 (а, б) и 1000°C (в, г) в течение: а – 2 ч, средняя толщина слоя 110 мкм; б – 4 ч, средняя толщина 160 мкм; в – 2 ч, средняя толщина 180 мкм; г – 4 ч, средняя толщина 260 мкм.

защитного слоя является его толщина. Исходя из перечисленных факторов, формализуем процесс прогнозирования свойств изотермического бороалитирования. В математической модели процесса рассмотрим семь входных параметров:

$$x_1, x_2, x_3, x_4, x_5, x_6, x_7, \quad (2)$$

где  $x_1, x_2, x_3, x_4$  – массовые доли в составе смеси,  $x_5$  – марка стали,  $x_6$  – температура выдерживания,  $x_7$  – время выдерживания.

Параметры процесса бороалитирования, которые требуется найти (спрогнозировать):

$$y_1, y_2, y_3, y_4, \quad (3)$$

где  $y_1$  – толщина слоя,  $y_2$  – микротвердость,  $y_3$  – износостойкость,  $y_4$  – жаростойкость. Тогда задача нахождения этих параметров может быть описана в виде системы уравнений:

$$\begin{aligned} y_1 &= f_1(x_1, x_2, x_3, x_4, x_5, x_6, x_7) \\ y_2 &= f_2(x_1, x_2, x_3, x_4, x_5, x_6, x_7) \\ y_3 &= f_3(x_1, x_2, x_3, x_4, x_5, x_6, x_7) \\ y_4 &= f_4(x_1, x_2, x_3, x_4, x_5, x_6, x_7), \end{aligned} \quad (4)$$

где  $f_1, f_2, f_3, f_4$  – функции, которые описывают зависимость  $y_1, y_2, y_3, y_4$  от входных параметров  $x_1, x_2, x_3, x_4, x_5, x_6, x_7$ .

Таким образом, чтобы найти параметры процесса бороалитирования, необходимо решить систему уравнений (4), используя известные значения исходных параметров  $x_1, x_2, x_3, x_4, x_5, x_6, x_7$ . Для решения уравнений (4) предполагается решить задачу аппроксимации функции семи переменных, используя массив экспериментальных данных.

## АППРОКСИМАЦИЯ ФУНКЦИИ

Аппроксимация функции в семерном пространстве означает нахождение приближенной функции, которая описывает зависимость между семью входными переменными и выходным значением. Существуют несколько подходов к аппроксимации функций в многомерных пространствах, включая полиномиальную аппроксимацию.

Другим методом аппроксимации функций в многомерных пространствах является интерполяция. Она позволяет находить значения функции в любых точках всего диапазона изменения пере-

менных, используя ее известные из эксперимента значения в некоторых точках. Можно использовать многочлены Лагранжа или сплайны для интерполяции данных в семимерном пространстве. Многочлен Лагранжа в семимерном пространстве может быть записан в следующей форме [16]:

$$F(x_1, x_2, x_3, x_4, x_5, x_6, x_7) = \sum_{i=0}^n L_i(x_1, x_2, x_3, x_4, x_5, x_6, x_7) y_i, \quad (5)$$

где  $L_i(x_1, x_2, x_3, x_4, x_5, x_6, x_7)$  – многочлен Лагранжа, зависящий от переменных  $x_1, x_2, x_3, x_4, x_5, x_6, x_7$ ,  $y_i$  – значение функции в  $i$ -й точке данных. Многочлен Лагранжа может быть задан в виде:

$$L_i(x_1, x_2, x_3, x_4, x_5, x_6, x_7) = \prod_{j=0, j \neq i}^n \frac{x - x_j}{x_i - x_j}, \quad (6)$$

где  $n$  – количество точек.

Можно применить регрессионные модели, чтобы аппроксимировать функцию в семимерном пространстве на основе имеющихся данных. Также могут быть использованы нейронные сети для аппроксимации функций в многомерных пространствах. Например, многослойные персептроны или сверточные нейронные сети могут быть адаптированы для аппроксимации функций в семимерном пространстве на основе набора данных (рис. 3) [17].

Выбор подхода к аппроксимации функции в семимерном пространстве зависит от характера данных, доступных ресурсов и требований к точности и скорости аппроксимации. Каждый из описанных подходов имеет свои преимущества и ограничения, и выбор подхода будет зависеть от конкретной задачи и требований к результатам.

При аппроксимации функции в семимерном пространстве важно иметь достаточный объем данных для обучения модели. Чем больше данных, тем точнее может быть аппроксимация функции. Также важно следить за проблемами, такими как переобучение, особенно при использовании сложных моделей, таких как нейронные сети.

После выбора подхода к аппроксимации функции и обучения модели на доступных данных следует провести валидацию и тестирование аппроксимационной модели, чтобы оценить ее точность и адекватность. Если модель удовлетворяет требованиям к точности и скорости, то она может быть использована для аппроксимации функции в семимерном пространстве и для прогнозирования значений функции на новых данных.

Важно отметить, что аппроксимация функции в многомерных пространствах может быть достаточно сложной задачей. Прогнозы строят на основе экспериментально полученных данных. Это позволяет сделать предположение, что задачу можно эффективно решить одним из представленных методов.




Рис. 3. Модель многослойного персептрона.

Исходя из поставленной задачи прогнозирования свойств процесса изотермического бороалитирования, можно сделать декомпозицию под задачи прогнозирования толщины слоя, микротвердости, жаростойкости, износостойкости.

## ПРОГНОЗИРОВАНИЕ ТОЛЩИНЫ СЛОЯ

Имея ряд полученных экспериментальных данных, можно выделить порядок действий для анализа и прогноза толщины слоя при процессе изотермического бороалитирования. В целом прогностическая модель представляет собой итерационный цикл, состоящий из нескольких шагов (рис. 4). Первый шаг – подготовка данных о процессе бороалитирования, состоящих из семи входных и одной выходной переменных. Данные должны быть представлены в виде таблицы, где каждая строка соответствует одному наблюдению, каждый столбец – одной переменной. На следующем шаге нужно выбрать модель прогнозирования, которая лучше всего подходит для аппроксимации данных, например, нелинейная регрессия, интерполяция (многочлен Лагранжа) или искусственные нейронные сети [18, 19]. Далее следует определить параметры модели, которые максимально точно соответствуют экспериментальным данным, и выполнить итерацию с использованием методов наименьших квадратов, максимального правдоподобия или других методов оптимизации. Следующий шаг – нужно оценить точность модели, используя различные метрики, такие как коэффициент детерминации, корень из среднеквадратичной ошибки или средняя абсолютная ошибка. Затем необходимо использовать модель для прогнозирования выходного значения для новых наблюдений, которые не были использованы в обучающей выборке. Наконец, важно оценить результаты и улучшить модель при необходимости путем подбора других параметров или выбора другой модели.

## ПОДГОТОВКА ДАННЫХ

Особое внимание необходимо уделить процессу подготовки данных [20]. Можно выделить несколько основных шагов (рис. 5): выбор экспериментальных данных, которые будут использоваться для анализа и прогноза (табл. 1); очистка данных от ошибок, выбросов, пропущенных значений с помощью различных методов, фильтрации, обработки выбросов и заполнения пропущенных значений; преобразование данных в соответствующий формат (например, текстовые данные могут быть преобразованы в числовой



Рис. 4. Жизненный цикл прогностической модели.



Рис. 5. Подготовка данных.

формат, изображения – в массивы пикселей (табл. 2)); нормализация данных и установление одного масштаба для всех признаков (табл. 3); разбиение данных на обучающую, валидационную и тестовую выборки для обучения, настройки параметров и оценки производительности модели; предварительная обработка, аугментация данных для увеличения их разнообразия или уменьшения размерности для их упрощения.

## ВЫБОР МОДЕЛИ ПРОГНОЗИРОВАНИЯ

Прогнозирование свойств процесса изотермического бороалитирования возможно по трем моделям: интерполяционного многочлена Лагранжа

**Таблица 1.** Пример предварительно собранных данных

| Состав порошковой смеси, мас. %                                                            |    |                               |     | Условия насыщения |      | Толщина бороалитированного слоя, мкм |          |          |          |           |
|--------------------------------------------------------------------------------------------|----|-------------------------------|-----|-------------------|------|--------------------------------------|----------|----------|----------|-----------|
| 69.5%Al <sub>2</sub> O <sub>3</sub> + 30(x%B <sub>2</sub> O <sub>3</sub> + y%Al) + 0.5%NaF |    |                               |     |                   |      | Материал                             |          |          |          |           |
| Al <sub>2</sub> O <sub>3</sub>                                                             | Al | B <sub>2</sub> O <sub>3</sub> | NaF | t, °C             | T, ч | Техническое железо                   | Сталь 20 | Сталь 45 | Сталь У8 | Сталь У10 |
| 70                                                                                         | 50 | 50                            | 0.5 | 900               | 2    | 65                                   | 55       | 40       | 35       | 30        |

**Таблица 2.** Пример преобразованных данных

| Образец | Al <sub>2</sub> O <sub>3</sub> , мас. % | Al, мас. % | B <sub>2</sub> O <sub>3</sub> , мас. % | NaF, мас. % | t, °C | T, ч | Марка стали | Толщина БА-слоя, мкм |
|---------|-----------------------------------------|------------|----------------------------------------|-------------|-------|------|-------------|----------------------|
| 1       | 69.5                                    | 50         | 50                                     | 0.5         | 900   | 2    | 1           | 65                   |
| 2       | 69.5                                    | 60         | 40                                     | 0.5         | 950   | 2    | 2           | 110                  |
| 3       | 69.5                                    | 60         | 40                                     | 0.5         | 950   | 2    | 3           | 240                  |

Примечание: 1 – техническое железо, 2 – сталь 20, 3 – сталь 45, БА-слой – бороалитированный слой.

**Таблица 3.** Пример нормализованных данных

| Образец | Al <sub>2</sub> O <sub>3</sub> | Al  | B <sub>2</sub> O <sub>3</sub> | NaF | t, °C | T, ч | Марка стали | Толщина БА-слоя |
|---------|--------------------------------|-----|-------------------------------|-----|-------|------|-------------|-----------------|
| 1       | 0.7                            | 0.5 | 0.5                           | 0.5 | 0.90  | 2    | 0.1         | 0.065           |
| 2       | 0.7                            | 0.6 | 0.4                           | 0.5 | 0.95  | 2    | 0.2         | 0.110           |
| 3       | 0.7                            | 0.6 | 0.4                           | 0.5 | 1.00  | 2    | 0.3         | 0.240           |

жа, метода нелинейной регрессии, искусственных нейронных сетей. Определенный практический интерес представляет математическая модель искусственной нейронной сети, обеспечивающая достаточно точные результаты прогностической модели по сравнению с методом интерполяции многочленом Лагранжа и методом нелинейной регрессии. Искусственные нейронные сети обладают следующими преимуществами: достаточной гибкостью и способностью к обучению для аппроксимации сложных нелинейных функций и нахождения сложных взаимосвязей между входными данными; способностью оперировать большими объемами вводных параметров в разнородной структуре данных; устойчивостью к разнородным и зашумленным данным.

При прогнозировании свойств процесса изотермического бороалитирования проявляется достаточно большое количество факторов, влияющих на результаты экспериментов, и зачастую появляются результаты, выбивающиеся из закономерностей [21].

Моделирование искусственной нейронной сети проводили с помощью двух инструментальных средств, на языке программирования python с помощью библиотеки Keras и Neural Network

Toolbox пакета Matlab. В обоих случаях можно выделить ряд основных этапов.

Начальный этап – выбор архитектуры нейронной сети, которая наилучшим образом подходит для решения данной задачи. Далее следует выбор количества слоев и нейронов, функций активации и методов обучения. Из полученных данных и опыта моделирования искусственной нейронной сети подобных задач можно предположить, что данная задача является классической для искусственной нейронной сети “Многослойные перцептроны” [22, 23]. В настоящей работе оптимальная функция активации была подобрана экспериментально. Количество скрытых слоев и количество нейронов в слоях проанализировано и представлено в табл. 4.

Следующий этап – обучение нейронной сети на подготовленных данных. Обучение может быть выполнено с использованием различных методов, таких как обратное распространение ошибки или метод градиентного спуска. В этой задаче обучение искусственной нейронной сети проводили с помощью метода обратного распространения ошибки с алгоритмом Левенберга–Марквардта.

Затем оценивают производительность нейронной сети по тестовым данным, которые не

**Таблица 4.** Анализ оптимальных параметров количества скрытых слоев и нейронов

| Функция активации       | Количество скрытых слоев | Количество нейронов в скрытых слоях | Коэффициент корреляции, $R$ |
|-------------------------|--------------------------|-------------------------------------|-----------------------------|
| Логистическая функция   | 1                        | 3                                   | 0.999850202419785           |
|                         |                          | 5                                   | 0.999883456311139           |
|                         |                          | 7                                   | 0.999904488927797           |
|                         | 2                        | 9–8                                 | 0.999919369923908           |
|                         |                          | 10–5                                | 0.999906610889563           |
|                         |                          | 2–9                                 | 0.999902950708139           |
| Гиперболический тангенс | 1                        | 7                                   | 0.999881083401258           |
|                         |                          | 8                                   | 0.999880403038413           |
|                         |                          | 9                                   | 0.999870837624614           |
|                         | 2                        | 10–6                                | 0.999930768410076           |
|                         |                          | 3–5                                 | 0.999918510660637           |
|                         |                          | 5–10                                | 0.999917738313901           |

использовались в процессе обучения, и определяют эффективность обучения нейронной сети для решения задачи прогнозирования.

Метод Левенберга–Марквардта считают самым быстрым и надежным алгоритмом обучения, он позволяет за меньшее количество итераций минимизировать целевую функцию по сравнению с другими методами [24]. Однако его применение связано с определенными ограничениями. Так, метод можно применять только для сетей с одним выходным элементом. Он также требует памяти, пропорциональной квадрату числа весов в сети. Фактически это ограничение не позволяет использовать метод для сетей большого размера (порядка тысячи и более весов). Таким образом, метод Левенберга–Марквардта применим для небольших сетей с одним выходом, а также для среднеквадратичной функции ошибок. Эти преимущества и ограничения делают оптимальным выбор обучения нейронной сети методом обратного распространения ошибки с алгоритмом Левенберга–Марквардта.

В ходе обучения нейронной сети достигают минимизации целевой функции ошибки нейронной сети, вычисляемой методом наименьших квадратов:

$$MSE(\{\omega_{i,j}\}) = 1/2 \sum_{k=1}^n (r_k - y_k)^2, \quad (7)$$

где  $r_k$  – значение  $k$  выхода искусственной нейронной сети,  $y_k$  – целевое значение  $k$  выхода искусственной нейронной сети,  $n$  – число нейронов в выходном слое,  $\omega_{ij}$  – вес связи, соединяющий нейрон  $i$  с нейроном  $j$ .

Результаты моделирования показали, что наиболее оптимальными параметрами искусственной нейронной сети прогнозирования свойств толщины процесса изотермического бороалитирования является функция активации “гиперболический тангенс” с двумя скрытыми слоями с десятью и шестью нейронами, при этом коэффициент корреляции наивысший и составляет 0.999930768410076 (табл. 4).

## ЗАКЛЮЧЕНИЕ

С помощью математической модели на базе созданной нейронной сети получены достаточно точные прогностические результаты. Установлено, что прогнозирование свойств диффузионных покрытий по данным процесса бороалитирования является многокритериальной задачей, которую можно решать различными средствами математического аппарата. В частности, исследование показали высокую точность результатов при использовании искусственной нейронной сети типа многослойный персептрон. Тестирование количества скрытых слоев и количества нейронов в них выявили наибольший коэффициент корреляции  $R = 0.99993$  искусственной нейронной сети при использовании двух скрытых слоев с десятью и шестью нейронами соответственно. Наибольшей эффективности можно достичь с помощью функции активации “гиперболический тангенс”.

## ФИНАНСИРОВАНИЕ РАБОТЫ

Работа выполнена при финансовой поддержке Российского научного фонда (грант №19-79-10163-П).

**Конфликт интересов.** Авторы данной работы заявляют, что у них нет конфликта интересов.

## СПИСОК ЛИТЕРАТУРЫ

1. Земсков Г.В., Коган Р.Л. Многокомпонентное диффузионное насыщение металлов и сплавов. М.: Металлургия, 1981. С. 208.
2. Suwattananont N., Petrova R. // Solid State Sci. 2012. V. 14. P. 1669. <https://doi.org/10.1016/j.solidstatesciences.2012.06.008>
3. Cho J.H., Kim T.W., Son K.S., Yoon J.H., Kim H.S., Leisk G.G., Mitton D.B., Latanision R.M. // J. Metals Mater. Int. 2003. V. 9. № 3. С. 303. <https://doi.org/10.1007/BF03027051>
4. Tsipas S.A., Omar H., Perez F.H., Tsipas D.N. // Surf. Coat. Technol. 2008. V. 202. № 14. P. 3263. <https://doi.org/10.1016/j.surfcoat.2007.11.034>
5. Omar H., Tsipas S.A., Maragoudakis N., Michailidis N. // J. Corros. Eng. Sci. Technol. 2011. V. 46. № 6. P. 697. <https://doi.org/10.1179/147842209X12579401586564>
6. Maragoudakis N.E., Stergioudis G., Omar H., Paulidou H., Tsipas D.N. // Mater. Lett. 2002. V. 53. P. 406. [https://doi.org/10.1016/S0167-577X\(01\)00515-8](https://doi.org/10.1016/S0167-577X(01)00515-8)
7. Zakhariev Z., Marinov M., Penyashki T., Tsokov Pl. // J. Alloys Compd. 2008. 459. P. 501.
8. Ouladsaad S., Allaoui O., Daas A. // Indian J. Chem. Technol. 2019. V. 26. P. 239.
9. Mishigdorzhyn U.L., Ulakhanov N.S., Milonov A.S., Semenov A.P. // IOP Conf. Ser.: Mater. Sci. Eng. 2020. V. 759. P. 012017. <https://doi.org/10.1088/1757-899X/759/1/012017>
10. Mishigdorzhyn U., Chen Y., Ulakhanov N., Liang H. // Lubricants. 2020. V. 8. № 3. P. 26. <https://doi.org/10.3390/lubricants8030026>
11. Ulakhanov N., Mishigdorzhyn U. // IOP Conf. Ser.: Mater. Sci. Eng. 2019. V. 684. P. 012003. <https://doi.org/10.1088/1757-899X/684/1/012003>
12. Улаханов Н.С., Мишигдоржийн У.Л. Нейросетевая модель для расчета и прогнозирования толщины упроченного слоя на поверхности деталей машин // VII Междунар. конф. “Проблемы механики современных машин”, 25–30 июня 2018 г., г. Улан-Удэ, С. 322.
13. Mishigdorzhyn U.L., Ulakhanov N.S. // IOP Conf. Ser.: Mater. Sci. Eng. 2018. V. 411. P. 012049. <https://doi.org/10.1088/1757-899X/411/1/012049>
14. Sizov I.G., Mishigdorzhyn U.L., Maharov D.M. // Met. Sci. Heat Treat. 2012. V. 53. № 11–12. P. 592.
15. Патент 2401319 РФ, МПК C23C 8/72. Способ термомоциклического бороалитирования изделий из углеродистых сталей / Восточно-Сибирский гос. технолог. ун-т (№ 2009106319/02). Сизов И.Г., Мишигдоржийн У.Л., Махаров Д.М., Дашиев Ю.Б. // заявл. 24.02.2009; опубл. 10.10.2010. Бюл. № 28. 8 с.
16. Тараник В.А. // ScienceRise. 2015. Т. 2. № 8. С. 69. <https://doi.org/10.15587/23138416.2015.48349>
17. Иванов М.В. // Изв. Самарского науч. центра РАН. 2019. Т. 21. № 5. С. 11.
18. Интерполяция. Национальный исследовательский университет ИТМО. [http://aco.ifmo.ru/el\\_books/numerical\\_methods/lectures/glava3.html](http://aco.ifmo.ru/el_books/numerical_methods/lectures/glava3.html) (дата обращения: 30.06.2023).
19. Seber G.A.F., Wild C.J. // Nonlinear Regression. New York: John Wiley & Sons, 1989. P. 768.
20. Подготовка данных к прогнозированию и корректировка прогноза факторами. <https://4analytics.ru/planirovanie-i-prognozirovanie-praktika/video-podgotovka-dannix-k-prognozirovaniyu.html> (дата обращения: 08.06.2023)
21. Хайкин С. // Нейронные сети: полный курс. М.: ИД “Вильямс”, 2016. С. 1104.
22. Рутковская Д., Пилинский М., Рутковский Л. // Нейронные сети, генетические алгоритмы и нечеткие системы. М.: Горячая линия-Телеком, 2013. С. 384.
23. Bengio Y., Courville A., Vincent P. // IEEE Trans. Pattern Anal. Mach. Intell. 2013. V. 35. № 8. P. 1798.
24. Нгуен А.Т. Алгоритмическое обеспечение нейронной сети с полиномиальными кусочно-непрерывными функциями активации для обнаружения закономерностей в данных: дис. ... канд. тех. наук: 05.13.01. Томск: ТПУ–ТВСУР, 2019. С. 112.

## Prediction of the Boroaluminized Layer Thickness Using an Artificial Neural Network

U. L. Mishigdorzhyn<sup>1, \*</sup>, B. A. Dyshenov<sup>1, \*\*</sup>, A. P. Semenov<sup>1</sup>, N. S. Ulakhanov<sup>1</sup>,  
B. E. Markhadayev<sup>1</sup>

<sup>1</sup>Institute of Physical Material Science SB RAS, Ulan-Ude, 670047 Russia

\*e-mail: undrakh@ipms.bsnet.ru

\*\*e-mail: dyshenov@gmail.com

The application of mathematical models of artificial neural networks for predicting the properties of diffusion layers created by thermal-chemical treatment based on the boroaluminizing process was considered. Formalization and analysis of prediction of experimental results were carried out. It was established that the construction of computer prediction models based on experimental data of boroaluminizing was a solvable problem with high precision when using artificial neural networks of the multilayer perceptron type. Thus, testing the number of hidden layers and the number of neurons in them revealed the highest correlation coefficient  $R = 0.99993$  of the artificial neural network using two hidden layers with ten and six neurons, respectively. The highest efficiency can be achieved using the “hyperbolic tangent” activation function.

**Keywords:** thermal-chemical treatment, boroaluminizing, microstructure, carbon steel, artificial neural networks, layer thickness.