



УДК 004:62,408

**РЕАЛИЗАЦИЯ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ В УПРАВЛЕНИИ ПРОЦЕССОМ МИКРОДУГОВОГО ОКСИДИРОВАНИЯ НА БАЗЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ****IMPLEMENTATION OF THE DECISION MAKING SUPPORT IN THE MANAGEMENT OF MICROARC OXIDATION PROCESS ON THE BASIS OF ARTIFICIAL NEURAL NETWORKS****В.В. Ломакин, Т.В. Зайцева, Н.П. Путивцева, В.М. Яценко, О.П. Пусная  
V.V. Lomakin, T.V. Zaitseva, N.P. Putivzeva, V.M. Yatsenko, O.P. Pusnaya***Белгородский государственный национальный исследовательский университет,  
Россия, 308015, Белгород, ул. Победы, 85**Belgorod State National Research University, 85 Pobeda St, Belgorod, 308015, Russia**e-mail: lomakin@bsu.edu.ru, zaitseva@bsu.edu.ru, putivzeva@bsu.edu.ru, yatsenko\_v@bsu.edu.ru,  
pusnaya@bsu.edu.ru*

*Аннотация.* В рамках стратегий управления технологическими процессами на производстве в течение ряда лет все большим успехом пользуются искусственные нейронные сети. В данной статье представлен процесс организации нейронной сети для совершенствования технологии формирования МДО-покрытий за счет подбора оптимальных параметров процесса. Представлен обзор современного состояния данного процесса формирования покрытий, на его основе выделены основные факторы, влияющие на формирование покрытий с желательными свойствами. Для управления процессом микродугового оксидирования построена нейронная сеть, базовые положения которой описаны в работе.

*Resume.* Nowadays artificial neural networks are often used for management of technological processes in production. This article presents the process of organizing of neural network for improvement of the technology of formation of MAO-coatings by selecting of the optimum process parameters. A review of the current state of the coating formation process is presented. On the basis of the review the main factors influencing the formation of coatings with desirable properties were identified. To manage the process of microarc oxidation a neural network was built, the basic provisions of this network are described in the article.

*Ключевые слова:* микродуговое оксидирование, принятие решений, искусственные нейронные сети, оптимальные параметры процесса, свойства покрытий.

*Keywords:* microarc oxidation, decision making support, artificial neural networks, optimum process parameters, coatings properties.

Научные методы синтеза необходимых свойств поверхностей металлов для улучшения их свойств в настоящее время находят все большее применение в промышленном производстве. Одним из перспективных методов является процесс формирования покрытий с помощью микродугового оксидирования в растворах электролитов (МДО).

Основным отличием процесса МДО от традиционного анодирования является использование энергии электрических разрядов, мигрирующих по погруженной в электролит обрабатываемой поверхности, которые оказывают специфическое, плазмохимическое и гидродинамическое воздействия на металл основы, само покрытие и электролит, в результате чего формируются керамикоподобные покрытия с регулируемыми в широком диапазоне элементным и фазовым составом, структурой и свойствами [Суминов и др, 2001].

МДО широко применяется при замене тяжелых металлических сплавов или дорогостоящих композитных материалов на легкие металлы (Al, Ti, Mg и их сплавы и др.) с МДО-покрытиями. В машиностроении наиболее часто МДО-покрытия наносятся на пары трения, подшипники скольжения, зубчатые передачи, поршни, цилиндры, торцевые уплотнения для двигателей внутреннего сгорания, станков и машин различного назначения в судостроении, авиационной промышленности, детали для сельскохозяйственной техники. Применение метода МДО позволяет предприятиям выпускать продукцию нового качественного уровня, создавать высокотехнологичные материалы, удовлетворяющие растущим потребностям технического прогресса. Метод МДО

позволяет получать на группе металлов, относящихся к вентильным (Al, Ti, Mg, Zr и др.), и их сплавах многофункциональные керамикоподобные покрытия с уникальным комплексом свойств, в том числе износо-, коррозионно- и теплостойкие, электроизоляционные и декоративные, характеризующиеся высокими эксплуатационными показателями.

В результате анализа технологии получения МДО авторами [Тихоненко, Шкилько, 2010] были выделены преимущества данной технологии:

- малая концентрация, экологичность и неагрессивность электролитов и самого процесса,
- отсутствие необходимости тщательной предварительной подготовки поверхности детали,
- простое и легко управляемое оборудование,
- возможность автоматизации технологического процесса,
- возможность получения многофункциональных керамикоподобных покрытий, характеризующихся высокими эксплуатационными характеристиками и обладающих высокой адгезией,
- процесс обработки не изменяет начальных размеров детали, так как покрытие формируется за счет преобразования поверхностного слоя, стабильность характеристик покрытий.

Однако широкому применению технологии МДО в промышленности препятствуют следующие ее недостатки:

1. Повышение производительности МДО ограничено высокой энергоемкостью процесса, так как для увеличения толщины покрытий задают или большую плотность переменного тока, или увеличивают временную длительность проведения процесса МДО. Снизить энергозатраты при получении микродуговых покрытий возможно, к примеру, за счет использования новейших источников питания, технологических приемов, которые позволили бы минимизировать негативные последствия напряженных и супернапряженных режимов, или разработки энергосберегающих комбинированных режимов проведения МДО.

2. Сложность получения равномерных, с требуемыми толщиной и функциональными свойствами покрытий на всю или заданную поверхность изделий сложной геометрической формы, которую можно устранить путем применения дополнительных противоэлектродов и диэлектрических экранов или технологии нанесения покрытий в проточном электролите.

При внедрении технологии МДО на предприятиях возникает потребность в объективной оценке качества покрытий и создании соответствующих нормативных документов. Отсутствие национальных стандартов для метода МДО и невозможность применения некоторых межгосударственных и национальных стандартов для оценивания качества покрытий, полученных микродуговым оксидированием, затрудняет разработку технологии их нанесения в условиях предприятия, диагностику, и, соответственно, получение достоверной оценки уровня их качества.

Таким образом, задачи совершенствования технологии формирования МДО-покрытий, подбора оптимальных параметров процесса, установление требуемых свойств покрытий, определение влияния на их формирование режимов протекания процесса, внешних факторов и т.д. являются актуальными.

В рамках данной статьи решается задача разработки энергосберегающих комбинированных режимов проведения МДО.

В настоящее время ведутся разрозненные исследования влияния электрических режимов и параметров обработки на формирование МДО-покрытий с желательными свойствами, но влияние выбора тех или иных параметров и режимов на формирование свойств покрытий исследовано недостаточно. Так, например, анализ литературных источников показал, что не был проведен экспериментальный анализ влияния анодных и АК+К режимов на такие характеристики, как сквозная пористость, адгезия, микротвердость, коррозионная стойкость, послойная (ступенчатая) износостойкость, но соответствии с имеющимися данными, эти или часть этих характеристик могут отличаться различаться в зависимости от выбранного режима. Также довольно мало изучено влияние на свойства формируемых МДО-покрытий технологических факторов, связанных с электролитами, таких как температура, срок хранения свежеприготовленного электролита до начала применения в технологическом процессе, срок межоперационного хранения между обработкой партий деталей, а также выработка в процессе эксплуатации.

Суммируя все вышесказанное, можно сделать вывод, что на свойства получаемых в процессе обработки покрытий, перечень возможных материалов и производительность оборудования оказывают влияние множество факторов: тип обрабатываемого материала, время обработки, состав и однородность электролита в объеме электролитической ванны, температура электролита и ее изменение в процессе обработки, уровни и формы напряжения и тока, проходящих через электролит и нагрузку.

На процесс формирования покрытий, характеризующийся рассмотренными показателями качества оказывает влияние вся совокупность внешних и внутренних факторов при проведении МДО-процесса. К внешним факторам относятся электрические параметры режима обработки и их временные характеристики, состав и температура электролита, наличие и тип системы перемешивания электролита и вращения обрабатываемой детали, размеры и расположение электрода (катода), воздействие на электролит ультразвуком и электромагнитным полем, наличие в электроли-



те определенных взвесей. Внутренними факторами являются: тип обрабатываемого материала, его предварительная термообработка, нанесение вспомогательных покрытий, степень шероховатости исходной поверхности и ее пористость. Когда совокупность внешних факторов определена возможностями технологической установки, а материалом детали и способом ее изготовления определены внутренние факторы – ключевую роль оказывают электрические режимы обработки и параметры электролита. Для получения определенных, заданных качественных свойств покрытий используются электролиты определенного (оптимального) состава, при обработке которыми формируются требуемые по химическому составу покрытия и обеспечивается проведение процесса МДО. С учетом более высокой степени начальной определенности прочих влияющих факторов основное влияние на качественные показатели готового покрытия будут оказывать электрические режимы обработки и время их воздействия. [Яценко и др, 2015]

МДО является сложным процессом, множество факторов влияет на выбор оптимального режима. при проведении обзора состояния вопроса было выявлено, что общепринятая модель формирования МДО-покрытий отсутствует. При проведении натурных экспериментов также не были выявлены аналитические зависимости между факторами за исключением частных случаев при малом количестве учитываемых факторов, например зависимость микротвердости и толщины МДО-слоя от концентрации электролита и электрических режимов процесса. [Дударева 2013]. Количество факторов, которые необходимо учитывать и варьировать значения которых при подбore оптимального режима МДО приводит к тому, что решение задачи достижения требуемых результатов за счет выбора оптимального режима при большом количестве входящих условно-зависимых параметров статистическими методами является сложным и трудоемким процессом.

Подобного рода задачи можно решить, используя искусственные нейронные сети (ИНС).

В ИНС отдельные нейроны соединяются между собой в сеть, которая посредством специального обучения определяет, как ей реагировать на те или иные раздражители. Процесс обучения интерактивен, так как необходимо представить определенные воздействия, сравнить реакцию на них и выполнить необходимую коррекцию для ответа.

Цели использования нейронных сетевых моделей вытекают из их возможностей:

- моделирование линейных и нелинейных, сложных для понимания процессов;
- имитация процессов, которые трудно смоделировать с помощью точных аналитических методов;
- моделирование процессов, основанных на не поддающихся измерению параметрах;
- сокращение времени разработки модели для сложных процессов.

Способность к обучению ИНС дает большую гибкость для получения ответа, лежащего в основе функционирования процесса, в том числе и с факторами, которые не являются очевидными, например, состав электролита, степень изношенности электрода, наличие предварительной обработки либо загрязненности материала основы или какой-либо иной не поддающийся численному измерению параметр. [Jimmy W, 2016]

Начиная с 80-х годов, были разработаны и проанализированы различные типы архитектуры обучающихся ИНС. Выбор конкретного типа архитектуры зависит от различных факторов. Применительно к приложениям промышленного управления можно сказать, что созданные модели должны имитировать функцию некоторого переменного процесса. Цель основана на базовых условиях технологического процесса и данных, поступающих от его окружения. Одной из самых простых архитектур для решения подобных задач — многослойный перцептрон прямого пространства (рис. 1). Число нейронов в скрытом слое зависит от сложности целевой функции, но в целом они варьируются от трех до девяти.

Особое внимание при выборе записей для обучения ИНС необходимо уделять обеспечению такого набора записей выходных параметров как функции от векторов входного слоя, который охватывает не только заданный диапазон, но и целевой отклик по всему диапазону входного сигнала.

Процесс формирования набора данных, подходящих для обучения ИНС, включает:

- выбор целевой переменной / переменных;
- выбор входного вектора элементов;
- обработку типов данных;
- интеллектуальный анализ экспериментальных данных.

Можно утверждать, что самой сложной задачей в моделировании ИНС является выбор технологических параметров, а именно, составляющих элементов вектора входных данных модели —  $p_1...p_k$ .

Исходные данные модели должны быть представлены достоверными, надежными, независимыми переменными, которые оказывают наибольшее влияние на конечную цель.

В тех случаях, когда технологический процесс имеет большое число переменных, и выбор оптимальных параметров процесса является достаточно сложной задачей.

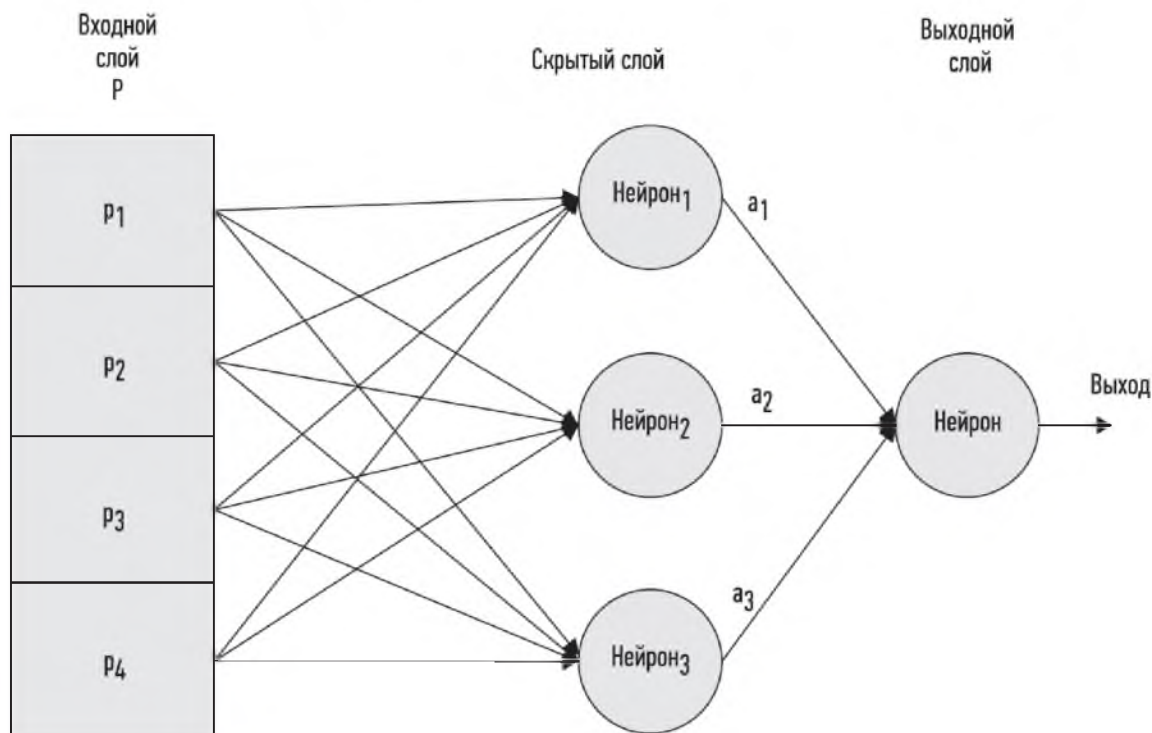


Рис. 1. Упрощенное представление многослойного персептрона прямого распространения для четырех входов с тремя нейронами в скрытом слое  
 Fig. 1. Simplified representation of the multi-layer perceptron direct distribution to the four inputs with three neurons in the hidden layer

На рис. 2 показана так называемая диаграмма типа «рыбьей кости» с описанием всех возможных воздействий, которые могли бы оказать влияние на целевое измерение.

Запись набора данных специальным образом подготавливается для обучения модели ИНС, для чего она случайным образом подразделяется на три отдельных подмножества (подкласса) записей: обучение, тестирование и валидацию (рис. 2).

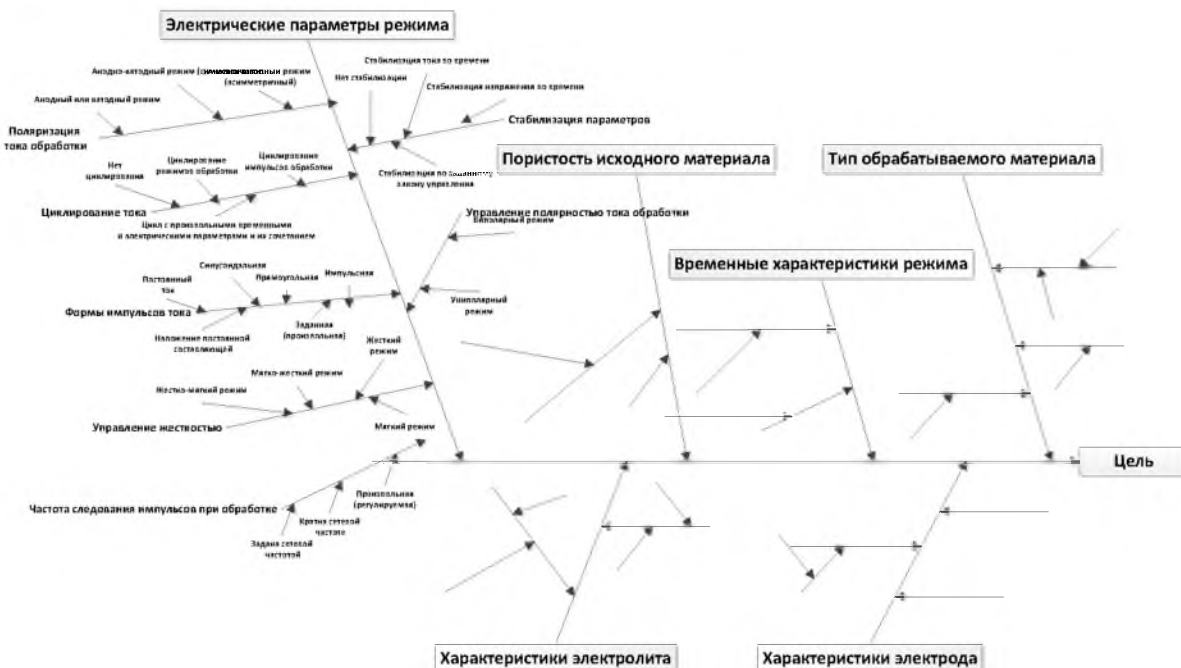


Рис. 2. Диаграмма воздействий на целевое измерение  
 Fig. 2. Diagram effects on the measurement target

Наборы данных для обучения и тестирования используются в процессе обучения модели. Для сходимости модели к целевой функции решения алгоритм обучения нейронной сети исполь-



зует подмножество данных обучения. Подмножество данных тестирования используется для предотвращения излишне длительного обучения, которое часто влияет на надежность модели. После того как модель ИНС обучена, она проходит валидацию, что обеспечивает качество полученной модели и надежность ее работы в условиях промышленной эксплуатации.

Подмножество, используемое для обучения, составляет от 60 до 80% объема всех имеющихся записей. Остальные записи, как правило, распределены между подмножествами данных тестирования и проверки равномерно. Каждая из записей должна быть выбрана случайным образом из набора данных и помещена в одно из трех подмножеств.

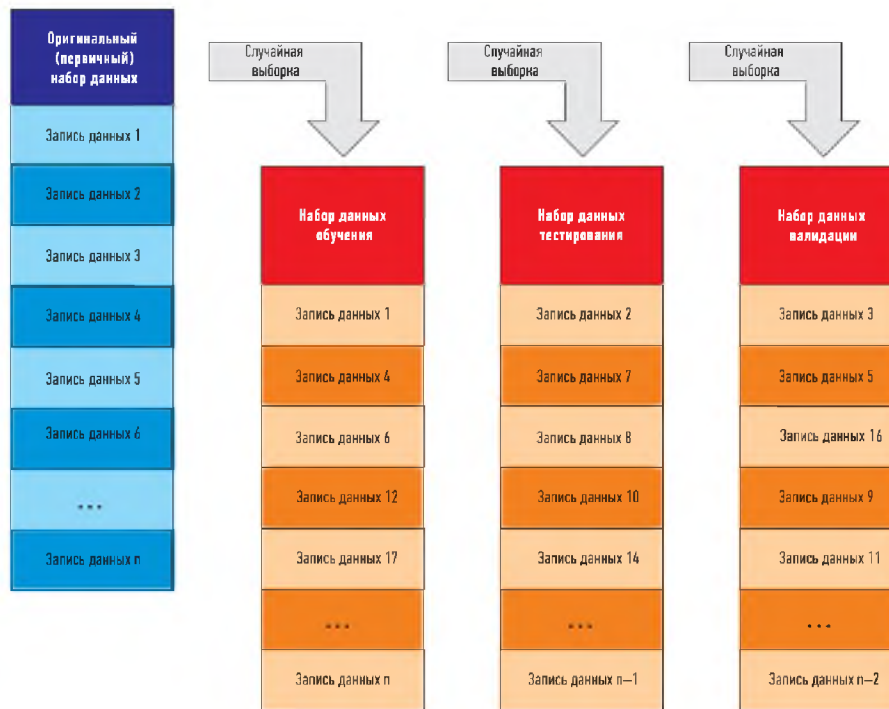


Рис. 3. Разбиение наборов данных на подмножества  
Fig. 3. Partitioning data sets into subsets

Обучение ИНС представляет собой итеративный процесс обратного распространения, который требует стратегии, делающей упор на надежность и подтверждение достоверности. Значения (веса) и их смещения для каждого нейрона предоставляются в процессе обучения. Алгоритм обратного распространения ошибки представлен на рисунке 4.

Согласно методу наименьших квадратов, минимизируемой целевой функцией ошибки НС является величина:

$$E(w) = \frac{1}{2} \sum_{j,p} (y_{j,p}^{(N)} - d_{j,p})^2 \quad (1)$$

где  $y_{j,p}^{(N)}$  – реальное выходное состояние нейрона  $j$  выходного слоя  $N$  нейронной сети при подаче на ее входы  $p$ -го образа;  $d_{j,p}$  – идеальное (желаемое) выходное состояние этого нейрона.

Суммирование ведется по всем нейронам выходного слоя и по всем обрабатываемым сетью образам. Минимизация ведется методом градиентного спуска, что означает подстройку весовых коэффициентов следующим образом [Корсунов и др, 2016]:

$$\Delta w_{ij}^{(n)} = -\eta \cdot \frac{\partial E}{\partial w_{ij}} \quad (2)$$

Здесь  $w_{ij}$  – весовой коэффициент синаптической связи, соединяющей  $i$ -ый нейрон слоя  $n-1$  с  $j$ -ым нейроном слоя  $n$ ,  $\eta$  – коэффициент скорости обучения,  $0 < \eta < 1$ .

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial y_j} \cdot \frac{dy_j}{ds_j} \cdot \frac{\partial s_j}{\partial w_{ij}} \quad (3)$$

Здесь под  $y_j$ , как и раньше, подразумевается выход нейрона  $j$ , а под  $s_j$  – взвешенная сумма его входных сигналов, то есть аргумент активационной функции. Так как множитель  $dy_j/ds_j$  является



производной этой функции по ее аргументу, из этого следует, что производная активационной функция должна быть определена на всей оси абсцисс. В связи с этим функция единичного скачка и прочие активационные функции с неоднородностями не подходят для рассматриваемых НС. В них применяются такие гладкие функции, как классический сигмоид с экспонентой.

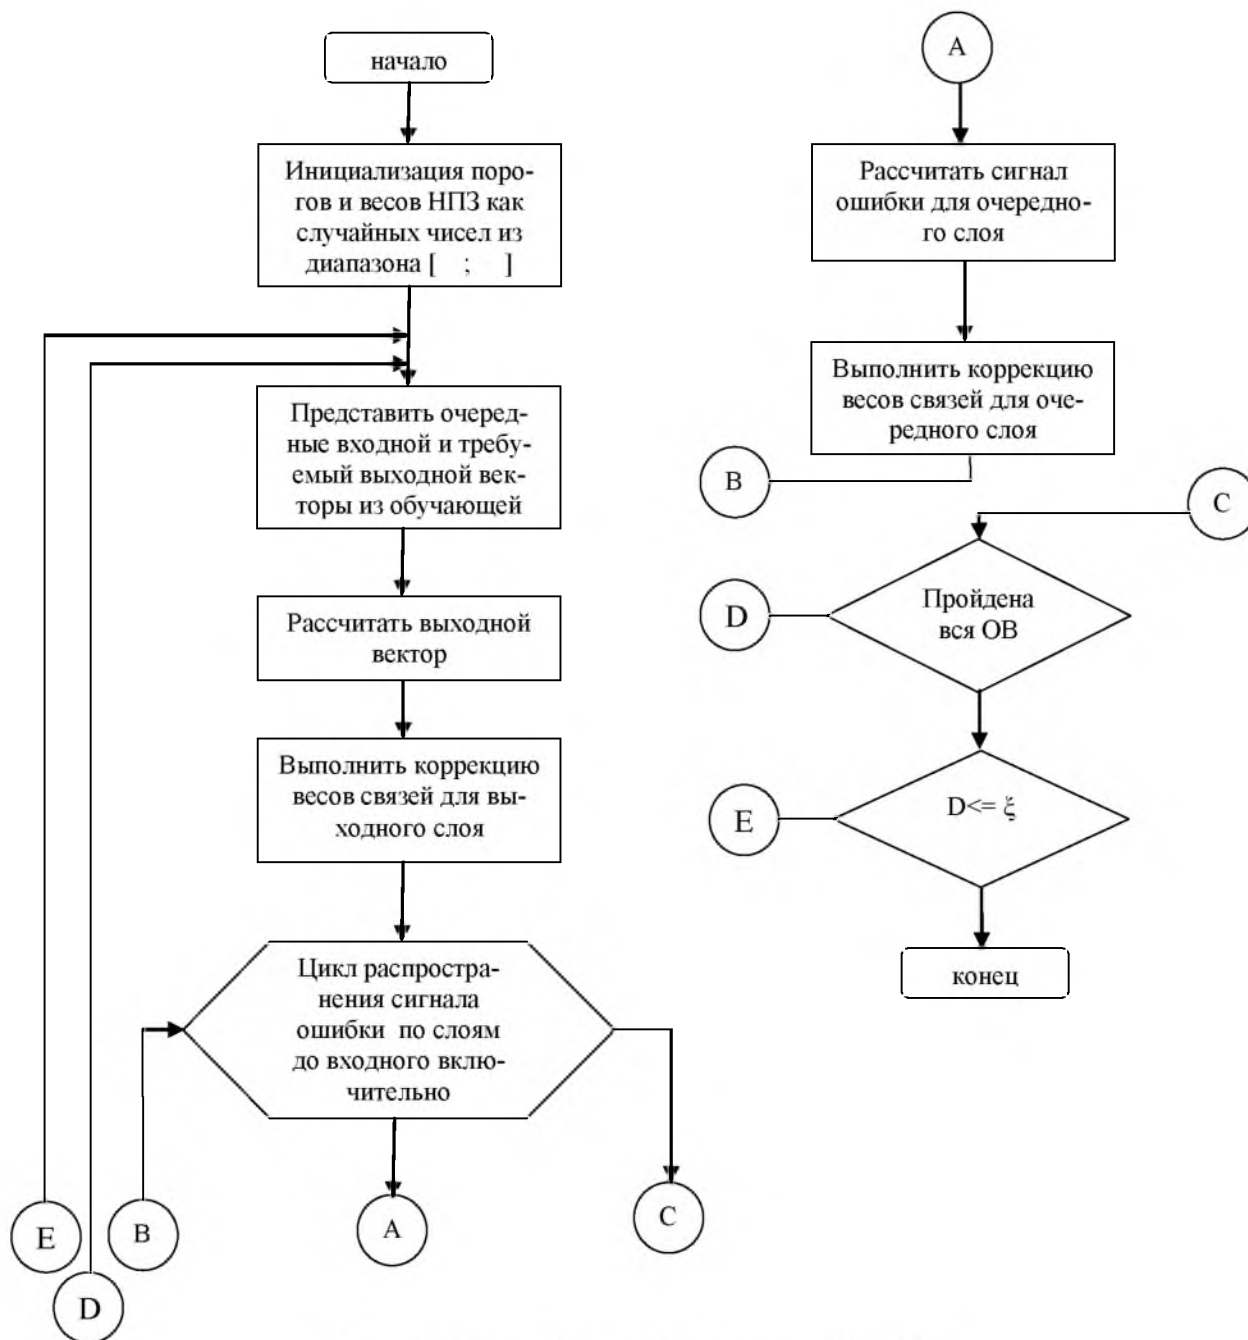


Рис. 4. Алгоритм обратного распространения ошибки  
 Fig. 4. Algorithm backpropagation

Третий множитель  $\partial s_j / \partial w_{ij}$ , очевидно, равен выходу нейрона предыдущего слоя  $y_i^{(n-1)}$ . Что касается первого множителя в (3), он легко раскладывается следующим образом:

$$\frac{\partial E}{\partial y_j} = \sum_k \frac{\partial E}{\partial y_k} \cdot \frac{dy_k}{ds_k} \cdot \frac{\partial s_k}{\partial y_j} = \sum_k \frac{\partial E}{\partial y_k} \cdot \frac{dy_k}{ds_k} \cdot w_{jk}^{(n+1)} \tag{5}$$

Здесь суммирование по k выполняется среди нейронов слоя n+1. Введя новую переменную

$$\delta_j^{(n)} = \frac{\partial E}{\partial y_j} \cdot \frac{dy_j}{ds_j} \tag{6}$$



получим рекурсивную формулу для расчетов величин  $\delta_j^{(n)}$  слоя  $n$  из величин  $\delta_k^{(n+1)}$  более старшего слоя  $n+1$ .

$$\delta_j^{(n)} = \left[ \sum_k \delta_k^{(n+1)} \cdot w_{jk}^{(n+1)} \right] \cdot \frac{dy_j}{ds_j} \quad (7)$$

Для выходного же слоя

$$\delta_i^{(N)} = (y_i^{(N)} - d_i) \cdot \frac{dy_i}{ds_i} \quad (8)$$

Теперь мы можем записать (2) в раскрытом виде:

$$\Delta w_{ij}^{(n)} = -\eta \cdot \delta_j^{(n)} \cdot y_i^{(n-1)} \quad (9)$$

Иногда для придания процессу коррекции весов некоторой инерционности, сглаживающей резкие скачки при перемещении по поверхности целевой функции, (9) дополняется значением изменения веса на предыдущей итерации

$$\Delta w_{ij}^{(n)}(t) = -\eta \cdot (\mu \cdot \Delta w_{ij}^{(n)}(t-1) + (1-\mu) \cdot \delta_j^{(n)} \cdot y_i^{(n-1)}) \quad (10)$$

где  $\mu$  – коэффициент инерционности,  $t$  – номер текущей итерации.

Таким образом, полный алгоритм обучения НС с помощью процедуры обратного распространения строится так:

1. Подать на входы сети один из возможных образов и в режиме обычного функционирования НС, когда сигналы распространяются от входов к выходам, рассчитать значения последних. Напомним, что

$$s_j^{(n)} = \sum_{i=0}^{M-1} y_i^{(n-1)} \cdot w_{ij}^{(n)} \quad (11)$$

где  $M$  – число нейронов в слое  $n-1$  с учетом нейрона с постоянным выходным состоянием  $+1$ , задающего смещение;  $y_i^{(n-1)} = x_{ij}^{(n)}$  –  $i$ -ый вход нейрона  $j$  слоя  $n$ .

$$y_j^{(n)} = f(s_j^{(n)}), \quad (12)$$

где  $f()$  – сигмоид

$$y_q^{(0)} = I_q, \quad (13)$$

где  $I_q$  –  $q$ -ая компонента вектора входного образа.

2. Рассчитать  $\delta^{(N)}$  для выходного слоя по формуле (8).

Рассчитать по формуле (9) или (10) изменения весов  $\Delta w^{(N)}$  слоя  $N$ .

3. Рассчитать по формулам (7) и (9) (или (7) и (10)) соответственно  $\delta^{(n)}$  и  $\Delta w^{(n)}$  для всех остальных слоев,  $n=N-1, \dots, 1$ .

4. Скорректировать все веса в НС

$$w_{ij}^{(n)}(t) = w_{ij}^{(n)}(t-1) + \Delta w_{ij}^{(n)}(t) \quad (14)$$

5. Если ошибка сети существенна, перейти на шаг 1. В противном случае – конец.

Сети на шаге 1 попеременно в случайном порядке предъявляются все тренировочные образы, чтобы сеть, образно говоря, не забывала одни по мере запоминания других.

Из выражения (9) следует, что когда выходное значение  $y_i^{(n-1)}$  стремится к нулю, эффективность обучения заметно снижается. При двоичных входных векторах в среднем половина весовых коэффициентов не будет корректироваться [3], поэтому область возможных значений выходов нейронов  $[0,1]$  желательно сдвинуть в пределы  $[-0.5, +0.5]$ , что достигается простыми модификациями логистических функций. Например, сигмоид с экспонентой преобразуется к виду

$$f(x) = -0.5 + \frac{1}{1 + e^{-ax}} \quad (15)$$



Соображения касательно внедрения нейронной сети в конкретном индустриальном применении включают в себя:

- конфигурацию нейронной сети (алгоритм);
- проверку качества входов;
- тестирование управления пространством;
- планирование альтернативной стратегии управления/измерения;
- соответствующий пользовательский интерфейс.

Учитывая все вышеизложенное можно сделать вывод о соответствии ИНС задачам подбора оптимальных режимов проведения МДО. Ниже разобрана упрощенная схема решения задачи подбора.

Постановка задачи: Необходимо подобрать оптимальный режим проведения МДО по соотношению параметров и установлению их граничных значений до проведения технологического процесса (прямая задача). Для протекающего технологического процесса необходимо управлять настройкой значений параметров режима для подбора оптимальных характеристик, близких к требуемым (обратная задача).

Прямая задача формулируется в виде

$$\bar{Y} = F(\bar{X}) .$$

Где  $Y=Y(y_1, y_2, \dots, y_n)$  – n-мерный вектор, характеризующий оптимальные для конкретной задачи, получаемые в результате обработки свойства покрытий

$Y_1$  – толщина МДО-покрытия

$Y_2$  – износостойкость

$Y_3$  – пористость

И т.д.

$X=X[x_1, x_2, \dots, x_m]$  - n-мерный мультивектор входных параметров процесса (режим)

Например,  $x_1=(x_{11}, x_{12}, \dots, x_{1k})$  – вектор параметров электрического режима

$x_{11}$ - Возможности поляризации тока обработки (анодный режим, катодный режим, анодно-катодный симметричный режим, анодно-катодный асимметричный режим)

$x_{12}$  - Возможности циклирования (нет циклирования, возможность циклирования режимов обработки, возможность циклирования импульсов обработки, возможность построения цикла с произвольными временными и электрическими параметрами и их сочетанием)

$x_{13}$  - Форма импульса тока (постоянный ток, синусоидальная, прямоугольная, импульсная, наложение постоянной составляющей и заданная / произвольная)

и т.д.

$x_2=(x_{21}, x_{22}, \dots, x_{2s})$  – вектор, характеризующий особенности электролита и его использования

$x_{21}$ - Система перемешивания электролита (отсутствие системы, система перемешивания электролита 1-го типа, система перемешивания электролита 2-го типа и т.д.)

$x_{22}$ - Гомогенность электролита в объеме электролитической ванны (гомогенный, гетерогенный)

и т.д.

$x_3=(x_{31}, x_{32}, \dots, x_{3r})$  – вектор, характеризующий наличие предварительной обработки

$x_{31}$  – Термообработка

$x_{32}$  – Обезжиривание

$x_{33}$  – Нанесение вспомогательных покрытий

и т.д.

Обратная задача имеет вид

$$\bar{X} = F^{-1}(\bar{Y}) .$$

Так как процессы, связанные с подбором оптимальных режимов протекания МДО для достижения требуемых свойств получаемых покрытий, сложны и требуют знания эксперта, функции  $F$  и  $F^{-1}$  представлены в виде нейронных сетей.

Для этих целей использовались нейронные сети с алгоритмом обучения обратного распространения ошибки, каждый нейрон которой имеет вид:

$$\left\{ \begin{array}{l} S_{jk} = \sum_{i=1}^n x_i w_{ijk} \\ N_{jk} = f(S_{jk}) \end{array} \right. ,$$

где  $x_i$  - входы формального нейрона  $i=1, n$  ,





$w_{jk}$  - весовой коэффициент  $i$ -го входа  $k$ -го нейрона в слое  $k=1, \dots, n_i$ ,

где ( $n_i$  - количество слоев нейронной сети);

$f$  - функция активации нейрона;

$N_j$  - выход  $j$ -го нейрона,  $k$ -го слоя.

Для подтверждения работоспособности разработанной нейронной сети в качестве функции активации выберем наиболее часто применяемую функцию  $f(x) = 1/(1+e^{-ax})$ . Также для этой цели зафиксируем все компоненты вектора  $x$ , кроме одного (выбрать можно либо самый важный с точки зрения эксперта о достижимости требуемых результатов процесса, либо, если такие данные недоступны, то выбираем первую компоненту вектора), то есть остановимся на рассмотрении данного мультивектора со следующими ограничениями:

1. материал – алюминиевый сплав Д16Т
2. силикатный электролит на основе жидкого стекла  $\text{Na}_2\text{SiO}_3$
3. добавка в электролит - КОН
4. температура электролита не превышала  $45^\circ\text{C}$ ,
5. Длительность проведения процесса составляла 2 ч

Образцы изготавливались из прутка алюминиевого сплава Д16Т диаметром 32 мм и толщиной 3 мм, их поверхность была предварительно отшлифована. Площадь обработки образцов составляла  $\approx 1660$  мм<sup>2</sup>. Объем электролита составлял 50 литров дистиллированной воды, в который, исходя из плана эксперимента, добавлялось необходимое количество  $\text{Na}_2\text{SiO}_3$  и КОН.

Образец прикреплялся к алюминиевому проводу и погружался в электролит так, чтобы место токоподвода не соприкасалось с электролитом. Также в электролит погружался катод из нержавеющей стали 18ХН, при этом анодом являлся сам обрабатываемый образец.

Катод и анод размещали на расстоянии 15...20 см параллельно друг другу. Образец и электрод в течение всего процесса МДО находились в неподвижном состоянии. Электрический режим установки (емкость конденсаторной батареи источника питания установки) выбирался (и менялся) в соответствии с планом эксперимента. После окончания обработки образец отсоединяли от системы токоподвода и промывали водопроводной водой. [Дударева, 2013]

В качестве основных факторов, влияющих на качество МДО-слоя, были выбраны:

- концентрация в электролите щелочи КОН, дг/л;
- концентрация в электролите жидкого стекла  $\text{Na}_2\text{SiO}_3$ , дг/л;
- электрические режимы, которые определяются емкостью конденсаторной батареи установки.

Обучающее множество было построено на основе экспериментальных данных, полученных в процессе функционирования системы (табл).

Таблица  
Table

Обучающее множество  
Training set

№	x1	x2	x3	y1	y2
1	0,1	0,2	0,1	0,0137	0,06718
2	0,1	0,2	0,2	0,0455	0,14187
3	0,1	0,6	0,1	0,0041	0,11968
4	0,1	0,6	0,2	0,049	0,07812
5	0,4	0,2	0,1	0,0036	0,11839
6	0,4	0,2	0,2	0,1237	0,09938
7	0,4	0,6	0,1	0,0449	0,11667
8	0,4	0,6	0,2	0,0638	0,08972

Таким образом, в качестве факторов процесса МДО использовались:

- $x_1$  – емкость  $C$  конденсаторов установки, мФ;
- $x_2$  – концентрация  $n_1$  жидкого стекла,  $\text{Na}_2\text{SiO}_3$ , дг/л;
- $x_3$  – концентрация  $n_2$  щелочи, КОН, дг/л.

В качестве параметров выхода были выбраны:

- $y_1$  – толщина упрочненного слоя без учета муллита  $h$ , мкм;
- $y_2$  – микротвердость слоя  $H_{\mu}$ , ТПа.

На рисунках 5а и 5б представлена близость полученных результатов обучающей и тестовой выборкам соответственно.




Рис. 5а. Результат обучающей выборки  
Fig. 5a. The result of the training sample




Рис. 5б. Результат тестовой выборки  
Fig. 5b. The result of the test sample

Таким образом, сеть была обучена, и ее можно использовать для дальнейших исследований.

Поставленная в статье цель достигнута: доказана эффективность применения ИНС для управления технологическим процессом МДО в условиях фиксации всех компонент вектора  $x$ , кроме отвечающего за особенности электролита и его использования. При этом были использованы следующие ограничения: алюминиевый сплав Д16Т, силикатный электролит на основе жидкого стекла  $Na_2SiO_3$ , добавка в электролит – КОН, температура электролита не превышала 45 °С, длительность проведения процесса составляла 2 ч.

В дальнейшем планируется разработка программного средства на основе ИНС, позволяющего управлять режимами процесса МДО при увеличении количества как входных, так и выходных параметров в зависимости от предъявляемых требований к получаемым покрытиям.

**Работа выполнена в рамках проекта по приоритетным направлениям социально-экономического развития Белгородской области «Разработка алгоритмов и программных средств поддержки принятия решений при определении технологических режимов и параметров процесса микродугового оксидирования», договор №37-гр от 19.10.2016 г.**

### Список литературы References

- Джимми У. Ки. 2016. Искусственные нейронные сети управления технологическими процессами. Часть 2 Control Engineering URL: [http://controleng.ru/perspektiva/neural\\_networks\\_/](http://controleng.ru/perspektiva/neural_networks_/)
- Dzhimmi U. Ki (Jimmy W. Key). 2016. Iskusstvennye nejronnye seti upravlenija tehnologicheskimi procesami [Artificial neural process control network] Chast' 2 Control Engineering URL: [http://controleng.ru/perspektiva/neural\\_networks\\_/](http://controleng.ru/perspektiva/neural_networks_/) (in Russian)
- Дударева Н.Ю. 2013. Влияние режимов микродугового оксидирования на свойства формируемой поверхности. Машиностроение. Уфа УГАТУ. Т. 17, № 3, (56): 217–222
- Dudareva N.Ju. 2013. Vlijanie rezhimov mikrodrugovogo oksidirovanija na svojstva formiruemoj poverhnosti.[ Influence of conditions on the properties of micro-arc oxidation formed surface] Mashinostroenie. Ufa UGATU. T. 17, № 3, (56):217–222 (in Russian)
- Корсунов Н.И., Лысьх К.В., Торопчин Д.А. 2015. Метод обучения перцептрона распознаванию текстовых символов при зашумлении. Научные ведомости БелГУ. Сер. Экономика Информатика 13(210): 99-103
- Korsunov N.I., Lysyh K.V., Toropchin D.A. 2015. Metod obucheniya perseptrona raspoznavaniju tekstovykh simvolov pri zashumlenijah. Nauchnye vedomosti BelGU. Jekonomika Informatika [Teaching Method perceptron recognition of text characters when pinching. Belgorod State University Scientific Bulletin. Economics Information technologies] 13(210): 99-103 (in Russian)
- Суминов И.В., Эпельфельд А.В., Людин В.Б. и др. 2001. Микродуговое оксидирование (обзор). Приборы № 9:13-23.
- Suminov I.V., Jepel'fel'd A.V., Ljudin V.B. i dr. 2001. Mikrodrugovoe oksidirovanie (obzor).[ Microarc oxidation (review)] Pribory № 9:13-23. (in Russian)
- Тихоненко В.В., Шкилько А.М. 2010. Влияние микродуговой обработки алюминия на эмиссионно-механические характеристики. Вестник ТГУ, т.15, вып.3
- Tihonenko V.V., Shkil'ko A.M. 2010. Vlijanie mikrodrugovoj obrabotki aljuminija na jemissionno-mehanicheskie harakteristiki.[ Influence microarc aluminum processing on emission-mechanical characteristics] Vestnik TGU, t.15, vyp.3 (in Russian)
- Яценко В.М., Ломакин В.В., Храмов Г.В. 2015. Функциональные возможности электротехнического оборудования для микродугового оксидирования. Научное обозрение: №22: 264-275
- Jacenko V.M., Lomakin V.V., Hramov G.V. 2015. Funkcional'nye vozmozhnosti jelektrotehnicheskogo oborudovanija dlja mikrodrugovogo oksidirovanija.[ The functionality of the electrical equipment for micro-arc oxidation] Nauchnoe obozrenie: №22: 264-275 (in Russian)