

# ГИБРИДНЫЕ НЕЙРОННЫЕ СЕТИ ПРИ УПРАВЛЕНИИ НЕПРЕРЫВНЫМ ПРОИЗВОДСТВОМ<sup>1</sup>

## HYBRID NEURAL NETWORKS IN CONTINUOUS PRODUCTION CONTROL

*E. Baryshnikova  
N. Krylosova*

*Summary.* The article considers the problem of continuous production control on the example of technological process of sheet glass production. The information about the object is presented in the form of expert evaluations in natural language. To maintain the stability of complex continuous technological processes, a model based on fuzzy neural network is proposed, combining the apparatus of artificial neural networks and fuzzy logic mechanisms. A hybrid algorithm is used to train the network. Since the network training is a continuous process, the proposed model will be adapted to the changing parameters of production, which will allow to use this network on other similar technological lines to maintain the stability of their work.

*Keywords:* fuzzy neural network, control system, continuous production.

**Барышникова Елена Сергеевна**

*ученый секретарь, старший научный сотрудник,  
Институт проблем точной механики и управления  
Российской академии наук  
baryshnikova@iptmuran.ru*

**Крылосова Наталия Юрьевна**

*инженер-исследователь, Институт проблем точной  
механики и управления Российской академии наук  
nataliya.krylosova@mail.ru*

*Аннотация.* В статье рассматривается проблема управления непрерывным производством на примере технологического процесса производства листового стекла. Информация об объекте управления представлена в виде экспертных оценок на естественном языке. Для поддержания стабильности сложных непрерывных технологических процессов предлагается модель на основе нечеткой нейронной сети, объединяющая аппарат искусственных нейронных сетей и механизмы нечеткой логики. Для обучения сети используется гибридный алгоритм. Так как обучение сети является непрерывным процессом, то предложенная модель будет адаптироваться под изменяющиеся параметры производства, что позволит использовать данную сеть и на других подобных технологических линиях для поддержания стабильности их работы.

*Ключевые слова:* нечеткая нейронная сеть, управляющая система, непрерывное производство.

## Введение

Непрерывные производства представляют из себя совокупность непрерывных технологических процессов, входящих в состав единого производственного комплекса или человеко-машинной системы. Такие производства характерны для отраслей промышленности, в которых при протекании физико-химических реакций, высокой температуре и/или давлении происходит преобразование исходного сырья в готовую продукцию. Как объект управления непрерывное производство листового стекла относится к классу обобщенных динамических систем, которые представляют совокупность взаимосвязанных объектов и процессов, изменяющихся во времени [1–4]. Для изучения подобного рода сложных объектов применяется системный анализ, основными этапами которого являются [5–7]:

1. Разработка постановки задачи управления для решения проблемы, в рамках которой определяются: объект исследования, цели и критерии для изучения объекта и управления им.

2. Определение структуры и границ изучаемой системы.
3. Разработка математической модели изучаемой системы, в рамках которой определяются элементы системы, элементарные воздействия на систему с помощью параметров и задание области определения каждого параметра.
4. Прогнозирование развития системы и исследование математических моделей.

На современных автоматизированных предприятиях с непрерывным производством одной из важнейших задач является принятие в режиме реального или близкого к реальному времени обоснованных решений по управлению функционированием производства для достижения поставленных целей [8].

В качестве примера непрерывного производства в данной работе выбрано автоматизированное производство высококачественного листового стекла. Технологический процесс производства листового

<sup>1</sup> Работа выполнена в рамках государственного задания Министерства науки и высшего образования Российской Федерации (тема № 122030400209-9 Разработка интеллектуальных моделей и методов управления сложными человеко-машинными системами в условиях критических ситуаций)

стекла — это энергоемкое сложное производство с запаздыванием по каналам управления и возмущающих воздействий, которое изменяется в широких пределах: от нескольких минут (для ванны расплава и печи отжига) до нескольких суток (по составу шихты). Поэтому эффективное управление процессом производства невозможно без прогнозирования развития технологических процессов и показателей качества стекла.

Сведения об объекте управления на момент создания системы управления, как правило, неполные, поэтому управляющая система должна обладать механизмом обучения. При этом имеющаяся информация об объекте управления представлена в виде экспертных данных на естественном языке. В связи с этим, возможным решением проблемы является комбинация системы нечеткого вывода с аппаратом искусственных сетей, сочетающая в себе как эффективный аппарат обучения, так и удобный механизм представления знаний и построения рассуждений.

Гибридные модели на основе нечеткого вывода описываются многими авторами. Искусственные нейронные сети применяются в основном для прогнозирования в экономике [9–11], моделирования процессов в промышленности и диагностике неисправностей [12], распознавании дефектов [13].

При этом почти не встречается работ по разработке систем управления непрерывным производством на основе искусственных нейронных сетей с нечетким выводом при возникновении аварийных ситуаций.

Под аварийной ситуацией будем понимать отклонение от нормального режима функционирования объектов управления вследствие неблагоприятных внешних условий, отказа оборудования и техники, ошибок эксплуатации, которое в случае непринятия своевременных управляющих решений может привести к аварии, катастрофе и (или) значительному материальному ущербу.

Знания могут быть представлены с высокой степенью детализации рассмотрения процесса управления, характеризующейся точностью описания конкретных аварийных ситуаций и принятия решения; для хранения подобных знаний создается база знаний прецедентов. Вывод, основанный на прецедентах, позволяет использовать специфические знания об аварийных ситуациях из предыдущего опыта. Решение в новой аварийной ситуации принимается путем нахождения подобного прецедента в прошлом, и это решение многократно используется в последующих аварийных ситуациях [14].

В [15] для прогнозирования и диагностики аварийных ситуаций предлагается использовать бинарные временные ряды. В [16] для идентификации возникшей

ситуации, выбора управления по ликвидации и предотвращения аварий используется метод имитационного моделирования.

Согласно [17] возникновение и развитие крупных аварий, как правило, характеризуется комбинацией случайных локальных событий, возникающих с различной частотой на разных стадиях аварии (отказы оборудования, человеческие ошибки, внешние воздействия, разрушение, выброс, пролив вещества, рассеяние веществ, воспламенение, взрыв, интоксикация и т.д.). Для выявления причинно-следственных связей между этими событиями используют логико-графические методы анализа «деревьев отказов и событий». При анализе деревьев отказов (АДО, Fault Tree Analysis — FTA) определяются комбинации отказов оборудования, ошибок персонала и внешних (техногенных, природных) воздействий, приводящих к основному событию (аварийной ситуации). Метод используется для анализа возможных причин возникновения аварийной ситуации.

Методы деревьев отказов и событий — трудоемки и применяются, как правило, для анализа проектов или модернизации сложных технических систем и производств. Последний метод — это метод количественного анализа. Он характеризуется расчетом показателей риска и может включать один или несколько вышеупомянутых методов (или использовать их результаты). Проведение количественного анализа требует большого объема информации по аварийности, надежности оборудования, учета особенностей окружающей местности, метеоусловий и других факторов. Недостатками количественного анализа риска являются невысокая точность результатов, вследствие чего использование количественных показателей (в частности, вероятности возникновения аварии) в качестве критериев безопасности для сложных производств, как правило, не оправдано.

## 1. Постановка и подход к решению задачи

Необходимо разработать систему управления непрерывным производством на основе комбинации системы нечеткого вывода и аппарата искусственных нейронных сетей.

*Решение задачи.* Рассмотрим решение поставленной задачи на примере технологического процесса производства листового стекла. Это сложный энергоемкий процесс с большим количеством нечетких качественных параметров.

Нами была собрана информация о ситуациях, которые могут привести к остановке производства. Данные представлены в нечетком виде на естественном языке.

Затем мы рассмотрели различные модели представления такой информации и соответствующие алгоритмы принятия решений.

Вся собранная информация была систематизирована с использованием аппарата таблиц решений. Но модель на основе таблиц принятия решений оказалась недостаточно адаптируемой. При возникновении новых ситуаций с кардинально иными признаками необходимо полностью пересматривать структуру таблицы. Модель на основе таблиц решений оказалась хорошим аппаратом для систематизации и формализации накопленного экспертного опыта.

Для решения задачи допустимо использование аппарата ситуационного управления. Однако процесс принятия решений при этом является долгой процедурой. Для непрерывного производства время принятия решения — очень важная характеристика.

В результате была выбрана модель нечеткой нейронной сети, которая объединяет методы нечеткой логики и аппарат искусственных нейронных сетей. В статье предложена структура и состав такой сети на основе модели нечеткой системы Такаги–Сугено–Канга.

Сеть состоит из входного, скрытого и выходного слоев. Входными переменными являются данные различных датчиков: температуры, давления защитной атмосферы, расположения лужи стекла, положения растягивающего устройства и пр. Во входном слое они нормализуются.

Скрытый слой представляет собой подсистему на основе нейронных сетей. На этом слое нормализованные данные с датчиков используются для вычисления функций принадлежности лингвистических переменных. Для простоты представления и вычисления, не в ущерб требуемой точности, мы выбрали трапециевидные функции принадлежности для всех лингвистических переменных (рис. 1).

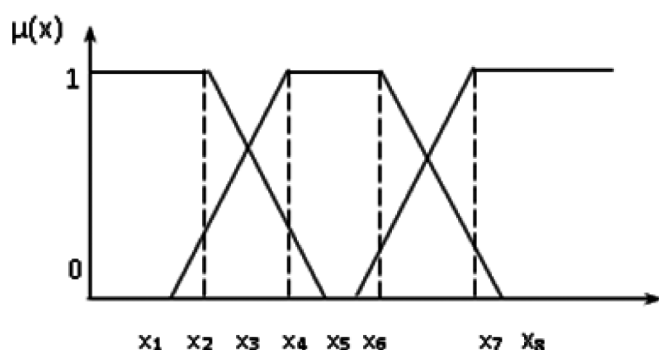


Рис. 1. Вид функций принадлежности входных лингвистических переменных

Полученные лингвистические переменные используются для определения класса возникшей ситуации и выработки необходимого управляющего воздействия.

## 2. Пример решения задачи

В первую группу лингвистических переменных мы отнесли данные о ленте стекла, которые раскрывают понятия управляемости, положения ленты стекла и др.

Вторая группа лингвистических переменных связана со свойствами выпускаемого стекла — толщина стекла, прозрачность и др., а также наличие дефектов, например, переменная «толщина» и ее возможные значения: «уменьшение», «увеличение» и «неравномерная».

В третью группу мы включили данные от исполнительных устройств — растягивающих устройств, шиберов, лера, холодильников и нагревателей.

К четвертой группе мы отнесли сведения от обеспечивающих служб — давление защитной атмосферы, расход воды и ее температура, расход электроэнергии и температура в ванне расплава.

На вход ИНС поступает цифровая информация от датчиков  $x_i$ , где  $i=1, \dots, n$ ,  $n$  — количество входных сигналов. С помощью аппарата лингвистических переменных осуществляется переход к описанию текущей ситуации в виде значений функций принадлежности нечетких переменных. Функции принадлежности  $\mu_j(x_i)$ , где  $j=1, \dots, m$ , задаются экспертами на этапе разработки ИНС.

Полученные значения функций принадлежности поступают на следующий слой сети, где определяется наличие или отсутствие того или иного признака аварийной ситуации. Агрегирование лингвистических переменных проводится с использованием операций нечеткой логики (конъюнкции или дизъюнкции) и вычисляется как минимальное для конъюнкции и максимальное для дизъюнкции значения функций принадлежности

$$z_l = \{\mu_1(x_1) \wedge \mu_2(x_2)\} \vee \{\mu_3(x_3) \wedge \mu_4(x_4)\} \vee \dots \vee \{\mu_{n-1}(x_{n-1}) \wedge \mu_n(x_n)\}, \quad (1)$$

где  $l=1, \dots, k$ ,  $k$  — общее количество признаков аварийных ситуаций.

При этом количество участвующих в агрегировании переменных, как правило, различно. Например, признак «Болтание лужи» описывается группой переменных: «положение лужи в текущий момент», «положение лужи в момент времени  $t-1$ », «положение лужи в момент времени  $t-2$ ».

Полученные значения степени истинности признаков ситуаций агрегируются в третьем слое ИНС. При этом агрегирование реализуется с помощью формулы

$$y_i(x) = \frac{\sum_{j=1}^J w_j z_j}{\sum_{j=1}^J w_j} \quad (2)$$

где  $y_i$  — степень истинности  $i$ -й аварийной ситуации, а  $w_j$  — вес значимости  $j$ -го признака ситуации,  $i=1, \dots, I$ ,  $j=1, \dots, J$ .

Выход ИНС образует вектор истинности аварийных ситуаций, по которому определяется наличие или отсутствие конкретной аварии на объекте.

Таким образом, нами получена модель, на вход которой подаются данные с датчиков, а на выходе получаем решение о необходимости реализации того или иного управляющего воздействия и информацию о том, может ли текущая ситуация привести к остановке производства.

Обучение гибридной сети проводится одновременно с ее созданием.

*Этап 1.* Выбираем первую ситуацию. Для этой ситуации формируем набор входных переменных и создаем первый слой сети.

Формируем функции принадлежности для лингвистических переменных, описывающих данную ситуацию. В вычислении функции принадлежности могут участвовать данные с нескольких датчиков.

Создаем нейроны, определяющие наличие признаков выбранной ситуации.

Устанавливаем веса значимости для полученных признаков равными 1.

*Этап 2.* Выбираем следующую ситуацию и формируем набор входных переменных для нее. Добавляем необходимые входные данные в первый слой сети.

Формируем функции принадлежности для лингвистических переменных, описывающих эту ситуацию с учетом уже имеющихся в сети.

Создаем нейроны, определяющие наличие признаков выбранной ситуации.

Корректируем веса значимости для признаков ситуации.

*Этап 3.* Подаем в вход нейронной сети информацию о предыдущей ситуации и обратным проходом корректируем веса и коэффициенты функций принадлежности с помощью метода градиентного спуска.

В данном методе минимизируется среднеквадратичная ошибка по формуле

$$E_p = 0,5 \sum_{k=1}^{NK} (y_k - d_k)^2$$

для каждой выборки ( $d_k$  и  $y_k$  — соответственно желаемое и расчетное значения на выходе сети).

*Этап 4.* Возвращаемся к этапу 2.

*Этап 5.* Повторяем этап 3 для всех уже имеющихся ситуаций.

Алгоритм обучения представлен на рис. 2.

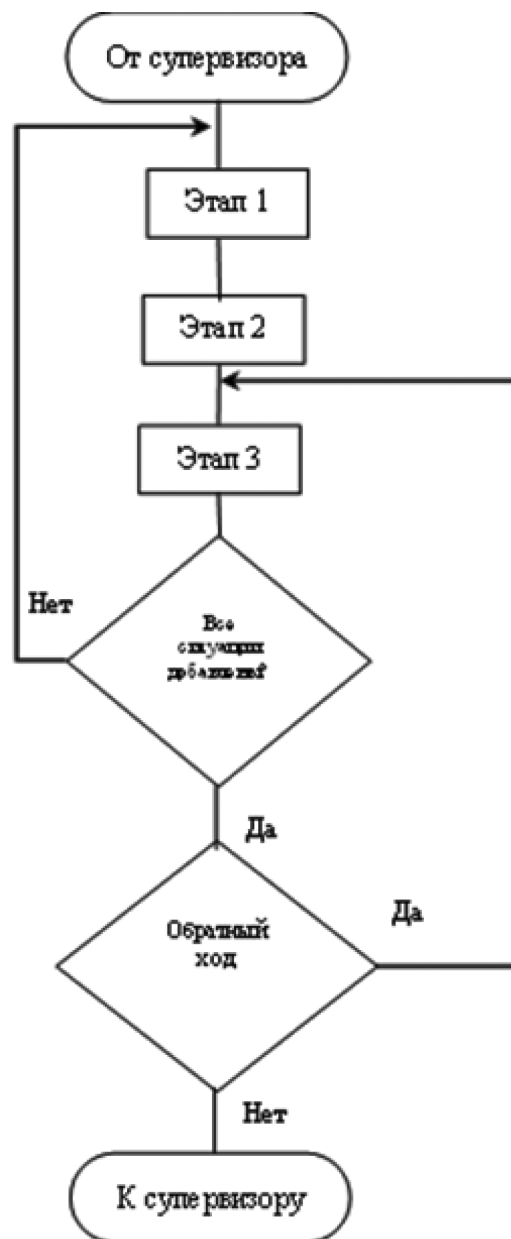


Рис. 2. Алгоритм обучения ИНС

### Заключение

В статье предлагается алгоритм создания и обучения искусственной нейронной сети на основе системы нечеткого вывода для управления непрерывным производством.

Для обучения нечеткой сети используется гибридный алгоритм. При этом уточнение параметров осуществляется в два этапа. На первом этапе фиксируются параметры первого слоя и рассчитываются линейные параметры полиномов третьего слоя TSK. На втором этапе фиксируются линейные параметры полиномов третьего слоя и уточняются нелинейные параметры первого слоя.

В настоящее время осуществляется тестирование предложенной сети на данных с ОАО «Саратовстрой-

стекло». Результаты тестирования показывают целесообразность использования полученных результатов в системе управления производством.

Так как обучение искусственной нейронной сети с нечетким выводом — непрерывный процесс, то предложенная модель будет адаптироваться под изменяющиеся параметры производства. Это позволит использовать данную сеть не только на рассмотренной технологической линии, но и на других, подобных ей.

Внедрение данной системы позволит уменьшить количество аварий, улучшить стабильность производственного процесса, а также осуществлять сбор информации о текущем состоянии объекта управления и обучение системы. Предлагаемая система существенно расширяет функциональные возможности действующих систем управления.

### ЛИТЕРАТУРА

1. Meshalkin V.P. et al. State of the art and research development prospects of energy and resource-efficient environmentally safe chemical process systems engineering // *Mendelev communications*. — 2021. — V. 31. — №5. — pp. 593–604.
2. Makarov R.I. et al. Information Analysis of the Sheet-Glass Utilization Factor in Production // *Glass Ceram.* — 2020. — V. 77. — pp. 295–297.
3. Makarov, R.I. et al. Salient Aspects of the Implementation of Digital Economics in Glass Plants in Russia // *Glass Ceram.* — 2019. — V.75. — pp. 438–440.
4. Петров Д.Ю. Архитектура информационной системы управления жизненным циклом цифрового двойника для непрерывного производства // *Известия Санкт-Петербургского государственного технологического института (технического университета)*. — 2021. — № 57. — С. 98–104.
5. Глушков В.М. Введение в АСУ. Изд. 2-е. К.:Техника. — 1974. — 320 с.
6. Вешнева И.В. и др. Проектирование интеллектуальной информационной системы для анализа и прогнозирования динамики рисков конкурентоспособности регионов РФ // *Известия Санкт-Петербургского государственного технологического института (технического университета)*. — 2021. — № 56. — С. 81–88.
7. Polyakova M. et al. Application of system analysis for technological processes investigation // *Key Engineering Materials*. — 2020. — V.834. — pp. 24–31.
8. Lim, K.Y.H. et al. A state-of-the-art survey of Digital Twin: Techniques, engineering product lifecycle management and business innovation perspectives. // *J. Intell. Manuf.* — 2020. — V.31. — pp.1313–1337.
9. Vince Vella, Wing Lon Ng (2016) Improving risk-adjusted performance in high frequency trading using interval type-2 fuzzy logic. *Expert Systems with Applications*, volume 55, pages 70–86.
10. Youngmin Kim, Wonbin Ahn, Kyong Joo Oh, David Enke (2017) An intelligent hybrid trading system for discovering trading rules for the futures market using rough sets and genetic algorithms. *Applied Soft Computing*. Volume 55, Pages 127–140.
11. Dehghani, M.; Riahi-Madvar, H.; Hooshyaripor, F.; Mosavi, A.; Shamshirband, S.; Zavadskas, E.K.; Chau, K.-w. (2019) Prediction of Hydropower Generation Using Grey Wolf Optimization Adaptive Neuro-Fuzzy Inference System. *Energies*. 12, 289.
12. Efimov I.V., Petrov D.Yu., Ivashchenko V.A., Meshalkin V.P. (2014) Avtomatizirovannaya nejronno-evristicheskaya procedura raspoznavaniya tochechnyh defektov v listovom stekle [Automated neuron-heuristic procedure for recognizing point defects in float glass] *Himicheskaya tekhnologiya* volume 8, pages 500–504.

© Барышниковна Елена Сергеевна (baryshnikova@iptmuran.ru); Крылосова Наталия Юрьевна (nataliya.krylosova@mail.ru)  
Журнал «Современная наука: актуальные проблемы теории и практики»