

References

1. **Bogdanov V. V.** Project Management. Corporate system — step by step, Moscow, Mann, Ivanov and Ferber, 2012, 248 p. (in Russian).
2. **Berehovenko A.** Corporate project management system. A guide for setting up a successful business, real cases, Ridero, 2018, 100 p. (in Russian).
3. **Nugaybekov R. A., Maksin D. G., Lyashuk A. V.** Corporate project management system: from methodology to practice, Moscow, Alpina Publisher, 2015, 234 p. (in Russian).
4. **Illarionov A. V., Klimenko E. Yu.** Project portfolio: A tool for strategic enterprise management, Moscow, Alpina Publisher, 2013, 312 p. (in Russian).
5. **Lehmann O.** Project business and projects unpaid by the customer, *Project and Program Management*, 2018, no. 4, pp. 262–275 (in Russian).
6. **The site** of the Moscow branch of PMI, available at: <https://pmi.ru/infosystem/> (in Russian).
7. **Microsoft Project**, available at: <https://products.office.com/ru-ru/project/project-and-portfolio-management-software>
8. **Oracle Primavera**, available at: <https://www.oracle.com/industries/construction-engineering/index.html>
9. **TAdvise** portal data on project management systems, available at: http://www.tadviser.ru/index.php/Project_control_systems?Cache=no&ptype=system#ttop (in Russian).
10. **Partnership** with Microsoft, available at: <https://partner.microsoft.com/ru-ru/membership/project-portfolio-management-competency> (in Russian).
11. **Daniel B., Stang, Matt Light, Teresa Jones.** Magic Quadrant for Project Portfolio Management, Worldwide, available at: www.gartner.com
12. **Microsoft Project Server**, available at: <https://technet.microsoft.com/ru-ru/library/fp179724.aspx>
13. **vRiskGap**, available at: www.riskgap.ru
14. **AVAKOR**, available at: <https://digdes.ru/info/avtomatizatsiya-protsesov-upravleniya-riskami>
15. **Risk management in Project 2016**, available at: https://blogs.technet.microsoft.com/project_ru/2016/01/19/project-2016-1-10/ (in Russian).
16. **Microsoft Project Server**, available at: https://support.office.com/ru-ru/article/Adding_risk_to_the_project-7aalacc9-50cf-4f15-ac3b-fedf41b31c83
17. **Mantis Bug Tracker**, available at: <https://www.mantisbt.org/>
18. **Redmine**, available at: <https://www.redmine.org/>
19. **JIRA Software**, available at: <https://ru.atlassian.com/software/jira>
20. **Data** portal TAdviser on revenue from the introduction of ERP-systems, available at: <http://www.tadviser.ru/index.php/ERP/> (in Russian).
21. **SAP S / 4HANA 1809 — Feature Scope Description**, available at: https://help.sap.com/doc/e2048712f0ab45e791e6d-15ba5e20c68/1809.000/en-US/FSD_OP1809.pdf
22. **1C: ERP + PM Management** of the project organization 2, available at: <https://solutions.1c.ru/catalog/erp-pm/features>
23. **Microsoft Dynamics 365 for Finance and Operations**, available at: <https://docs.microsoft.com/ru-ru/dynamics365/unified-operations/financials/project-management/overview-project-management-accounting>
24. **Kryazhev S. A., Kuznetsova Ye. V., Makarov E. N.** Portfolio Management of IT Projects as a Tool for Implementing an IT Strategy, *Informacionnye texnologii*, 2017, vol. 23, no. 11, pp. 833–840 (in Russian).

УДК 004.032.26

DOI: 10.17587/it.25.572-576

С. Е. Левин, первый зам. гендиректора, **Я. Н. Окрент**, гл. науч. сотр. e-mail: info@pkcc-ps, ООО "Российская корпорация средств связи — Программные системы",
С. Я. Нагибин, д-р техн. наук, проф., зав. кафедрой, **Н. Е. Балакирев**, канд. техн. наук, доц., Московский авиационный институт (национальный исследовательский университет)

Математическая модель технологического процесса производства стирола

Приведена математическая модель технологического процесса производства стирола с использованием нейросетевых технологий. Рассмотрено применение искусственной нейронной сети прямого распространения с одним скрытым слоем, обученной на экспериментальной выборке. Приведен алгоритм формирования нейронной сети. Модель реализована в виде программного модуля. Приведены результаты прогнозирования процесса производства стирола на реальных данных и рекомендации по использованию разработанной модели в процессе оценки промышленной безопасности особо опасных производственных процессов.

Ключевые слова: промышленная безопасность, искусственные нейронные сети, математическая модель производства стирола, нормализация параметров, обучение нейронной сети, метод обратного распространения ошибки, алгоритм формирования нейронной сет, оценка результатов прогнозирования

Введение

При оценке рисков промышленной безопасности особо опасных производственных объектов определяющими факторами не всегда являются характеристики надежности обо-

удования. На промышленную безопасность сложного технологического процесса влияют множество факторов как внешнего, так и внутреннего характера.

Качество исходного сырья, погодные условия, влияние автоматизированных систем и

эксплуатирующего персонала на технологический процесс, профессиональная подготовка персонала и многие другие факторы могут внести решающий вклад в развитие негативных явлений, вплоть до потери контроля над технологическим процессом.

Раннее обнаружение этих факторов важно для своевременного принятия предупредительных мер, которые позволят предотвратить их негативное влияние [1].

Для изучения аномального поведения сложных технологических систем применяют, как правило, методы математического моделирования, которые позволяют свести задачу изучения различных процессов к задаче изучения свойств математической модели, представляющей собой систему уравнений, описывающих процессы.

Несколько более сложной задачей является оценка надежностных характеристик производства, в которых протекают химические процессы. Химия — наука экспериментальная. Все результаты исследований строения и реакций веществ проверяются на опыте с последующими рекомендациями к практическому использованию. Моделирование свойств и реакционной способности химических соединений является составной частью общей стратегии исследований. Математическая модель с помощью определенного алгоритма позволяет прогнозировать течение химических процессов. При этом в данном случае при моделировании необходимо, кроме теории надежности и математической статистики, использовать аппарат теории катастроф, теории хаоса и теории нелинейных динамических систем [2].

Стирол — один из важнейших продуктов нефтехимии, сырье для получения полимеров (полистирол, синтетический каучук) и сополимеров (ударопрочный полистирол на основе акрилонитрила и бутадиена), относится ко второму классу опасности. Производство стирола — крупнотоннажное, единичная мощность современных агрегатов составляет 150—300 тысяч тонн стирола в год. Основным промышленным способом производства стирола в настоящее время является дегидрирование этилбензола.

Постановка задачи

Необходимо построить математическую модель процесса производства стирола в целях прогнозирования его поведения при изменяющихся входных условиях.

Основные этапы моделирования

Для связи входных параметров и выходной характеристики предложено использовать сложную математическую модель искусственной нейронной сети (ИНС). Нейросети являются эффективным методом имитации процессов, который позволяет выявлять сложные зависимости между входными и выходными характеристиками [3, 4].

Процесс математического моделирования включает в себя следующие этапы:

- 1) подготовка данных;
- 2) формирование нейронной сети;
- 3) обучение нейронной сети;
- 4) тестирование нейронной сети.

Первый этап: подготовка данных

На первом этапе был проведен анализ данных, рассмотрены зависимости значений параметров установки производства стирола от времени, давления и температуры.

Для перехода к общим размерностям необходимо провести нормализацию данных:

$$\tilde{x} = \frac{2(x - x_{\min})}{x_{\max} - x_{\min}} - 1, x \in [-1; 1].$$

Нормализация выполняется, когда на различные входы нейронов подаются данные разной размерности. При отсутствии нормирования значения на втором входе будут всегда оказывать существенно большее влияние на выход сети, чем значения на первом входе. При нормировании размерности всех входных и выходных данных сводятся воедино.

Для успешного прогнозирования поведения системы необходимо оставить в обучающей выборке только те значения, которые характеризуют общую тенденцию развития системы, в противном случае многочисленные выбросы, которые могут быть ошибками снятия показаний, будут "отвлекать" модель от общего направления развития, увеличивая разброс выходных данных (рис. 1).

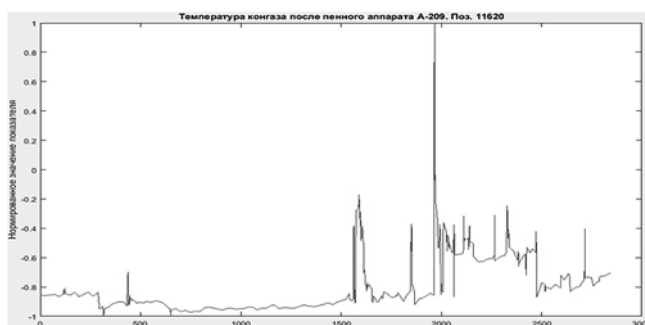


Рис. 1. Выброс на примере показателя температуры




Рис. 2. Выбросы на примере показателя содержания стирола




Рис. 3. Выбросы на примере показателя циркуляции

В то же время причиной некоторых выбросов или даже целых их серий могут быть определенные физические явления, которые система должна уметь выявлять и предсказывать (рис. 2, 3).

Для этого перед фильтрацией данных необходимо провести анализ по выявлению причин выбросов.

Конечным этапом подготовки выявления зависимостей между параметрами является сглаживание их значений. Для этого задается диапазон допустимых значений параметра, а для точек, которые не принадлежат данной области, ищется новое значение путем интерполяции. При вариации параметра разброса σ получаются разные модели кривых. Заметим, что чем больше σ , тем ближе построенная кривая к экспериментальной, но в то же время в модель включается большее число выбросов (рис. 4, см. четвертую сторону обложки).

Второй этап: формирование нейронной сети

Для решения поставленной задачи была выбрана модель нейронной сети прямого распространения (*feed-forward neural network*). В построенной модели используется трехслойная нейронная сеть прямого распространения с одним скрытым слоем. В ИНС выбранной структуры элементы (нейроны) между собой никак не связаны, но связаны с нейронами

предыдущего и следующего слоев (рис. 5, см. четвертую сторону обложки). Текущее состояние нейрона определяется как взвешенная сумма его входов. Выход нейрона — это функция его состояния (*функция активации*), вычисляющая его выходное значение.

Текущее состояние нейрона определяется как взвешенная сумма его входов. Выход нейрона — это функция его состояния (*функция активации*), вычисляющая его выходное значение. Методом подбора в качестве функции активации была выбрана сигмоидальная функция — гиперболический тангенс (*tansig*):

$$f_a(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}.$$

В результате должна минимизироваться сумма квадратов отклонений значений, полученных в результате работы нейросети, от экспериментальных данных. Таким образом, минимизируется следующий функционал:

$$F(\bar{u}, \bar{w}) = \sum_{l=1}^L \sum_{k=1}^M [Y - f(\bar{x}, \bar{a})]^2, \quad (1)$$

где $f(\bar{x}, \bar{a})$ — вычисляемая функция, которая получается в результате работы нейронов всех слоев; $\bar{a} \in R^{NN} = [v, w]$ — вектор оцениваемых параметров; M — число экспериментов.

Алгоритм формирования нейронной сети приведен ниже.

Шаг 1. На первом этапе осуществляется ввод входных данных.

Шаг 2. Инициализация:

$$v_{i,j} = w_j, l \in [-1, 1];$$

Шаг 3. Нормализация x, y :

$$\tilde{x}_{k,i} = \frac{2(x_{k,i} - x_{\min i})}{x_{\max i} - x_{\min i}} - 1; \quad \tilde{y}_{k,l} = \frac{2(y_{k,l} - y_{\min l})}{y_{\max l} - y_{\min l}} - 1.$$

После работы нейронной сети параметры элементов матриц X, Y восстанавливаются:

$$y_{k,i} = y_{\min i} + \frac{(\tilde{y}_{k,i} + 1)(y_{\max i} - y_{\min i})}{2};$$

$$x_{k,i} = x_{\min i} + \frac{(\tilde{x}_{k,i} + 1)(x_{\max i} - x_{\min i})}{2}.$$

Шаг 4. Вычисление функции $f(\bar{x}, \bar{a})$:

независимые входные переменные $\tilde{x}_{k,i}$ суммируются с весами и передаются вышестоя-

шему слою (скрытый слой). Каждая единица скрытого слоя принимает эту сумму, обрабатывает ее функцией активации и передает всем единицам в слой выше:

$$z_i = u_{0,i} + \sum_{j=1}^N \tilde{x}_j u_{ij};$$

$$z_j = f(z_j, a).$$

Каждая выходная единица суммирует эти взвешенные входные сигналы и обрабатывает их функцией активации:

$$y_l = w_{0,l} + \sum_{j=1}^P z_j w_{j,l};$$

$$y_l = f(y_l, a).$$

Третий этап: обучение нейронной сети

Главное свойство нейросетей — способность к обучению. В процессе обучения нейронная сеть способна выявлять сложные зависимости между входными и выходными данными, а также выполнять обобщение. Это значит, что в случае успешного обучения сеть вернет верный результат на основании данных, которые отсутствовали в обучающей выборке, а также на основании неполных и/или "зашумленных", частично искаженных данных. Из способности к обобщению и выделению скрытых зависимостей между входными и выходными данными следует способность ИНС к прогнозированию. После обучения сеть способна предсказать будущее значение некоторой последовательности на основе нескольких предыдущих значений.

Обучение сети прямого распространения проводится методом обратного распространения ошибки таким образом, чтобы минимизировать среднеквадратическую ошибку отклика сети на обучающей выборке. В данном алгоритме выходные значения сравниваются с точными результатами для вычисления значения предопределенной функции ошибки. Используя эту информацию, алгоритм корректирует вес каждого соединения, чтобы уменьшить значение функции ошибки на некоторую величину.

При обучении набор исходных данных делят на две части — обучающую выборку и тестовые данные. Обучающие данные подаются сети для обучения, а проверочные используются для расчета ошибки сети. Для данной модели на вход подавались исходные значения по 43 параметрам. При этом все данные делятся в соотношении 4:1, где 4 части (80 %) отходят на обучение и 1 часть (20 %) отводится на те-

стирование. Цель обучения состоит в том, чтобы при уменьшении ошибки на проверочных данных сетью выполнялось обобщение.

Четвертый этап: апробация нейронной сети

Тестирование качества обучения ИНС проводилось на 20 % реальных исходных данных, которые не участвовали в ее обучении. Результаты моделирования представлены (рис. 6, см. четвертую сторону обложки).

График демонстрирует результаты прогнозирования нейронной сети (красные) в сравнении с экспериментальными данными (синие). Для оценки эффективности прогнозирования анализировались значения следующих параметров:

- Mean Relative Error (MRE) — относительная ошибка, которая показывает, насколько велика абсолютная ошибка по сравнению с общим размером тестируемых данных. Полученный результат $MRE = 2,7931 \%$;
- KL — расстояние Кульбака — Лейблера, которое показывает потерю информации при замене истинного распределения на расчетное. Чем меньше значение KL, тем лучше совпадение распределений исходного и расчетного векторов. Полученный результат $KL = 0,16758$;
- R^2 — коэффициент детерминации для модели принимает значения от 0 до 1. Чем ближе значение коэффициента к 1, тем сильнее зависимость. Для приемлемых моделей предполагается, что коэффициент детерминации должен быть не меньше 0,5. Полученный результат $R^2 = 0,64174$.

Выводы

Проверка технологического процесса производства стирала с использованием нейросетевых технологий осуществлялась на примере известных входных и выходных данных и показала, что нейронная сеть дает аналогичные имеющиеся результаты с наперед заданной точностью. Для более точного прогнозирования вышеописанные этапы построения математической модели могут потребовать корректировки и экспериментального подбора характеристик сети (число скрытых слоев и нейронов, выбора функции активации). В связи с этим полученные на данной стадии результаты моделирования процесса производства стирала при известных входных параметрах, несмотря на вполне удовлетворительные результаты, необходимо рассматривать как предварительные.

Список литературы

1. **Сенаторов М. Ю., Левин С. Е., Нагибин С. Я.** Дистанционный контроль производственной безопасности топливно-энергетического комплекса // XVI Междунар. науч.-практ. конф. "Технические науки — от теории к практике". Санкт-Петербург, 23 января 2017 г.

2. **Об Основах** государственной политики Российской Федерации в области промышленной безопасности на пери-

од до 2025 года и дальнейшую перспективу. Указ Президента Российской Федерации от 06.05.2018 № 198.

3. **Николенко С., Кадурин А., Архангельский Е.** Погружение в мир нейронных сетей. СПб.: Питер, 2018. 480 с.

4. **Anil K. Jain, Jianchang Mao, Mohiuddin K. M.** Artificial Neural Networks: A Tutorial, IEEE Computer, 1996, vol. 29, N. 3, pp. 31–44.

S. E. Levin, First Deputy General Director, e-mail: levin@pkcc-ps.ru,

Ya. N. Okrent, Chief Researcher, e-mail: namaste2003@gmail.com,

Russian Corporation of Means of Communication — Software Systems, Moscow, 105005, Russian Federation

S. Ya. Nagibin, Ph. D., Professor, e-mail: nsy7@rambler.ru,

N. E. Balakirev, Ph. D., Associate Professor, e-mail: balakirev1949@yandex.ru

Moscow Aviation Institute (National Research University), Moscow, 121552, Russian Federation

Mathematical Model of the Technological Process of Styrene Production

The article presents a mathematical model of the functioning of the technological process of styrene production using neural network technologies. The use of a direct propagation neural network with one hidden layer trained on an experimental sample is considered. The algorithm for the formation of a neural network is proposed. The model is implemented as a software module. The results of forecasting the process of styrene production on real data and recommendations on the use of the developed model in the process of assessing the industrial safety of highly hazardous production processes are presented.

Keywords: industrial safety, artificial neural networks, mathematical model of styrene production, normalization of parameters, neural network training, method of back propagation of error, neural network formation algorithm, evaluation of prediction results

DOI: 10.17587/it.25.572-576

References

1. **Senatorov M., Levin S., Nagibin S.** Distance control of process safety of fuel and energy complex, *XVI International research and practical conference on "Engineering sciences — from theory to practice"*, 2017, pp. 16–24 (in Russian).

2. **On fundamentals** of the Russian Federation state policy in the field of industrial safety for the period up to 2025 and further

prospects, Russian Federation Presidential Decree as of 06.05.2018 No. 198 (in Russian).

3. **Nikolenko S., Kadurin A., Arkhangelsky E.** Diving into the world of neural networks, St. Petersburg, Piter, 2018, 480 p. (in Russian).

4. **Anil K. Jain, Jianchang Mao, Mohiuddin K. M.** *Artificial Neural Networks: A Tutorial*, IEEE Computer, 1996, vol. 29, no. 3, pp. 31–44.

Адрес редакции:

107076, Москва, Стромьинский пер., 4

Телефон редакции журнала (499) 269-5510

E-mail: it@novtex.ru

Технический редактор *Е. В. Конова*.

Корректор *З. В. Наумова*.

Сдано в набор 09.07.2019. Подписано в печать 27.08.2019. Формат 60×88 1/8. Бумага офсетная.

Усл. печ. л. 8,86. Заказ ИТ919. Цена договорная.

Журнал зарегистрирован в Министерстве Российской Федерации по делам печати, телерадиовещания и средств массовых коммуникаций.

Свидетельство о регистрации ПИ № 77-15565 от 02 июня 2003 г.

Оригинал-макет ООО "Авансд солюшнз". Отпечатано в ООО "Авансд солюшнз".

119071, г. Москва, Ленинский пр-т, д. 19, стр. 1. Сайт: www.aov.ru