

2. Кукор Б.Л. Общие аспекты концепции системы стратегического управления регионом // Вестник Российской академии естественных наук. 2012. № 16(2). С. 104–106.

3. Кукор Б.Л., Клименков Г.В. Адаптивное управление промышленным комплексом региона: теория, методология, практика / Под общ. ред. Б.Л. Кукора. Екатеринбург – СПб.: Ин-т экономики УрО РАН, 2017. 305 с.

4. Яковлева Е.А., Платонов В.В., Карлик Е.М., Шарич Э.Э., Яковлева Д.Д. Эмпирическая модель систематизации финансовых показателей по функциям менеджмента как основа установления инновационного потенциала организации // Лидерство и менеджмент. 2019. Т. 6. № 2. С. 73–90.

5. Яковлева Е.А., Козловская Э.А., Бойко Ю.В. Оценка инновационного потенциала предприятия на основе стоимостного подхода // Вопросы инновационной экономики. 2018. Т. 8. № 2. С. 267–282.

6. Яковлева Е.А., Катермина Т.С., Шарич Э.Э., Яковлева Д.Д. Формирование потенциала финансовой системы для повышения инновационной активности // Вопросы инновационной экономики. 2019. Т. 9. № 2. С. 349–360.

УДК 004.8

doi:10.18720/SPBPU/2/id20-241

Богучаров Владислав Алексеевич,

магистрант высшей школы киберфизических систем и управления

РАЗРАБОТКА ИНТЕЛЛЕКТУАЛЬНОЙ СИСТЕМЫ ДЛЯ ПРОЦЕССОВ НЕПРЕРЫВНОГО ТИПА С ЦЕЛЬЮ МИНИМИЗАЦИИ ПОТЕРЬ ПРОИЗВОДСТВА

Санкт-Петербургский политехнический университет Петра Великого,
Санкт-Петербург, Россия,
vladconquist@gmail.com

Аннотация. Непрерывные производства выражают высокий интерес к решениям, способным минимизировать потери полезных веществ в ходе некоторых технологических процессов. В данной работе предлагается использование нейросетевого подхода с целью создания интеллектуальной системы, способной предлагать наиболее подходящие режимы функционирования технологических установок. Данный подход позволяет решать задачи оптимизации технологического производства с целью максимизации прибыли и минимизации потерь вырабатываемых полезных веществ.

Ключевые слова: нейросетевой подход, интеллектуальный помощник, производства непрерывного типа, оптимизация, глубокое обучение, градиентный метод, интеллектуальный анализ данных, принятие решений.

Vladislav Bogucharov,

Master student of Higher School of Cyber-Physical Systems and Control

INTELLECTUAL SYSTEM DEVELOPMENT FOR CONTINUOUS TYPE PROCESSES IN ORDER TO MINIMIZE LOSS OF PRODUCTION

Peter the Great St. Petersburg Polytechnic University, St. Petersburg, Russia,
vladconquist@gmail.com

Abstract. Continuous production expresses a high interest in solutions that can minimize the loss of nutrients during certain technological processes. In this paper, the use of a neural network approach is proposed with the aim of creating an intelligent assistant capable of offering the most suitable modes of operation of technological installations. This approach allows to solve the problems of optimizing technological production in order to maximize profits and minimize losses of produced useful substances.

Keywords: neural network approach, intelligent assistant, continuous-type production, optimization, deep learning, gradient method, data mining, decision making.

В настоящее время конкурентоспособность диктует производителям выдавать продукцию высокого качества при наименьших затратах [1, 3]. Требования к процессам непрерывного типа только увеличиваются, а причинно-следственная связь производственных цепочек усложняется, вследствие чего характер процессов становится все более случайным и неопределенным.

Ответственным по принятию решений относительно ведения технологического процесса в большинстве случаев является оператор, который руководствуется исключительно своими знаниями и опытом. Однако, стоит понимать, что привязка к опыту затрудняет замену высококвалифицированного специалиста, поскольку различия в квалификации могут влиять не только на производительность, но и на прибыль компании [6]. В связи с этим особую значимость приобретает способность искусственного интеллекта обобщать опыт исторических событий и в качестве интеллектуального помощника выдавать рекомендации по ведению технологического процесса на основе полученного опыта.

Данная задача может быть описана с помощью математического аппарата, где необходимо найти совокупность значений:

$$x = \{x_1, x_2, \dots, x_p\}, \quad (1)$$

при которых должен достигаться максимум функции $f(x): R^p \rightarrow R$, т. е. необходимо определить:

$$f(x) \rightarrow \max_{x \in R^p}, \quad (2)$$

где p – это количество оптимизируемых параметров;

$f(x)$ – это некоторая функция, способная прогнозировать отношение количества поступающего сырья к массе получившегося продукта.

Искомой совокупностью значений являются ключевые параметры некоторого технологического процесса. Например, в производстве сахара из свекловицы искомой совокупностью x могут являться значения температур в технологической установке, скорость поступающего сырья, рН подаваемых вод и многие другие ключевые параметры [4]. Нахождение идеальных значений для указанных параметров означало бы то, что $f(x)=1$, т. е. абсолютное исключение потерь в ходе технологического процесса.

Задача осложняется тем, что производители часто не обладают знаниями о том, что собой представляет функция $f(x)$, вследствие чего предлагается применение нейросетевого подхода для создания модели $\hat{f}(x)$ исходной функции $f(x)$, которая должна с высокой степенью точности вычислять целевое отношение по заданным входным параметрам.

Поскольку решается задача регрессии, степень точности модели $\hat{f}(x)$ может быть оценена в соответствии со среднеквадратичной ошибкой:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{f}(x_i) - f(x_i))^2. \quad (3)$$

Начальным этапом построения модели $\hat{f}(x)$ является интеллектуальный анализ имеющихся данных. Эта процедура является одной из важнейших, поскольку без нее имеется высокая вероятность того, что модель обучится по недостоверным данным.

Одним из способов уменьшения влияния недостоверных данных является анализ графиков изменения ключевых параметров во времени. Совместный выход нескольких параметров за пределы технологических режимов может означать, что производство было вынуждено остановиться в рассматриваемый момент времени, например, в связи с отключением электроэнергии или поломкой оборудования. Данные периоды подлежат исключению из анализа, поскольку они не являются наблюдениями, описывающими интересующий технологический процесс.

Помимо анализа графиков изменения во времени следует обратить внимание на гистограммы, отображающие наиболее характерные режимы работ исследуемых параметров. Такой анализ позволяет выявить параметры, которые были неисправны в ходе предоставленного периода времени. Сигналом неисправности может служить отсутствие распределения показаний параметра или факт того, что его среднее значение за историю наблюдений было меньше нуля. Если не исключить данные па-

параметры, то модель $\hat{f}(x)$ может выявить ложные зависимости между поступающим сырьем и получаемым продуктом.

Поскольку на технологических установках присутствует множество похожих по своим функциям сенсоров, то очевидно, что их показания также будут схожими. Для получения нейросетевой модели $\hat{f}(x)$ будет достаточно одного из них, поскольку другие объекты являются коллинеарными к выбранному при высоком абсолютном коэффициенте корреляции. Коллинеарные объекты не рекомендуется использовать для нейросетевых моделей, поскольку они могут внести избыточность в функцию путем добавления локальных минимумов или максимумов.

Для вычисления коэффициента корреляции между парой величин u и v используется формула Пирсона:

$$r_{uv} = \frac{\sum_{i=1}^n (u_i - \bar{u})(v_i - \bar{v})}{\sqrt{\sum_{i=1}^n (u_i - \bar{u})^2} \sqrt{\sum_{i=1}^n (v_i - \bar{v})^2}}, \quad (4)$$

где r_{uv} – вычисляемый коэффициент корреляции; n – размер выборки.

После того, как были исключены и аварийные периоды производства, и произведен отбор информативных параметров, следует выполнить фильтрацию аномальных показаний среди рассматриваемых объектов. Для данной процедуры может быть использовано правило интерквартильного размаха [5].

Квартили в данном случае – это процентиля, которые делят набор данных на четверти. Интерквартильный размах (IQR) – это число, которое показывается разброс средней половины набора данных, т. е. разница между третьим (Q_3) и первым (Q_1) квартилем.

Правило интерквартильного размаха предполагает, что показания по какому-либо объекту сгруппированы вокруг некоторого центрального значения. Тем самым IQR помогает определить, насколько велик данный разброс вокруг центрального значения объекта, а также то, как далеко разбросаны другие.

Если наблюдение меньше $Q_1 - 1.5 * IQR$ или больше $Q_3 + 1.5 * IQR$, оно считается далеким от центральных значений и классифицируется, как выброс. Графически применение метода представлено на рисунке 1.

После выполнения вышеуказанных шагов интеллектуального анализа гарантировано, что модель будет обучена на достоверных данных, и ее результаты не исказятся.

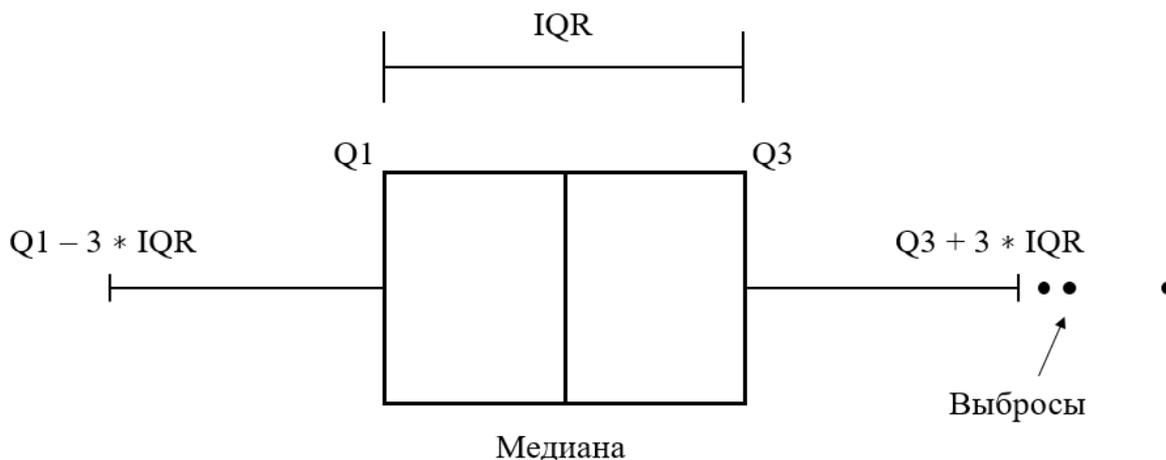


Рис. 1. Схематическое представление поиска выбросов с помощью интерквартильного размаха

В качестве инструментов разработки модели $\hat{f}(x)$ могут быть использованы язык программирования Python и нейросетевая библиотека Keras. Данный инструментарий позволяет создать нейросетевую модель с любой желаемой архитектурой. Однако, стоит помнить, что для нахождения комбинации оптимальных параметров, необходимо достигнуть глобального экстремума нейросетевой функции, и чем их будет меньше, тем легче и быстрее происходит поиск [2]. Тем самым для избегания избыточной сложности нейросетевой функции, а также исключения вероятности переобучения модели, не рекомендуется проектировать сложную архитектуру для искомой $\hat{f}(x)$.

Получив нейросетевую функцию $\hat{f}(x)$ можно приступить к поиску оптимальной комбинации параметров, которые максимизировали бы значение данной функции при некоторых входных параметрах.

Алгоритм поиска может быть описан следующими шагами:

1. Выбирается градиентный шаг a , а также критерий остановки поиска искомой комбинации, например, количество итераций поиска. При вычислении частных производных по исследуемым параметрам на компьютере бесконечно малое $h \rightarrow -\infty$ заменяется на малое, но конечное значение.

2. Вычисляется начальное значение нейросетевой функции $\hat{f}(x)$ относительно некоторого наблюдения.

3. К исследуемым параметрам добавляется малое h и вычисляется новое значение нейросетевой функции $\hat{f}(x+h)$. После чего получаем вектор частных производных:

$$\theta = \frac{\hat{f}(x+h) - \hat{f}(x)}{h} \quad (5)$$

4. Производится шаг в сторону градиента для получения обновленных показаний, приближенных к оптимальным:

$$x' = x + a\theta \quad (6)$$

5. Проверяется, не выходит ли какое-либо из значений исследуемых параметров за технологические режимы процесса. Если нет, продолжаем итерации до тех пор, пока не будет выполнен критерий остановки.

По итогу выполнения алгоритма получаем искомую комбинацию $x = \{x_1, x_2, \dots, x_p\}$, которую необходимо порекомендовать оператору технологического процесса.

Таким образом, в данной работе было развито применение нейросетевых методов на непрерывные производства. Очевидно, что накапливаемые данные некоторой технологической установки представляют ценность, и описанный подход дает возможность использовать имеющиеся показания с целью максимизации прибыли производства и минимизации потерь полезных веществ. Опираясь только на опыт прошлых событий и не имея субъективности принятия решений, разработанная модель может выступать в роли надежного интеллектуального помощника, который будет полезен как новым сотрудникам, так и для корректировки решений опытных работников.

Список литературы

1. Минько Э.В., Минько А.Э., Смирнов В.П. Качество и конкурентоспособность продукции и процессов: Учебное пособие. СПб.: СПбГУАП, 2005. 240 с.
2. Николенко С., Кадуринов А., Архангельская Е. Глубокое обучение. СПб.: Питер, 2020. 480 с.
3. Нуретдинова Ю.В., Степанова В.А., Бояркина А.А. Качество продукции как основа конкурентоспособности предприятия // Международный журнал гуманитарных и естественных наук. 2018. № 5–2. URL: <https://cyberleninka.ru/article/n/kachestvo-produktsii-kak-osnova-konkurentosposobnosti-predpriyatiya> (дата обращения: 25.05.2020).
4. Силин П.М. Технология сахара. 2-е изд., перераб. и доп. М.: Пищевая промышленность, 1967. 625 с.
5. Шмойлова Р.А., Минашкин В.Г., Садовникова Н.А. Практикум по теории статистики. 3-е изд. М: Финансы и статистика, 2011. 416 с.
6. Huang S.H., Zhang H.C. Artificial Neural Networks in Manufacturing: Concepts, Applications, and Perspectives // IEEE Transactions on Components, Packaging, and Manufacturing Technology. 1994. Part A, 17. P. 212-228. DOI: 10.1109/95.296402.