

УДК 681.5+622.3

О НЕЙРОСЕТЕВОМ МОДЕЛИРОВАНИИ ДИНАМИЧЕСКИХ СВОЙСТВ ТЕХНОЛОГИЧЕСКОГО ОБЪЕКТА

Ю.И. Еременко

Старооскольский технологический институт им. А.А. Угарова
Россия, 309516, Старый Оскол, микрорайон Макаренко, 42
E-mail: rem49@mail.ru

Д.А. Полещенко

Старооскольский технологический институт им. А.А. Угарова
Россия, 309516, Старый Оскол, микрорайон Макаренко, 42
E-mail: po-dima@yandex.ru

Ю.А. Цыганков

Старооскольский технологический институт им. А.А. Угарова
Россия, 309516, Старый Оскол, микрорайон Макаренко, 42
E-mail: Tsy-18@yandex.ru

Ключевые слова: горно-обогатительный комбинат, искусственная нейронная сеть, математическая модель, комплекс «мельница-классификатор», прогнозирующая система.

Аннотация: Актуальной проблемой производственных предприятий является необходимость повышения энергоэффективности производственных процессов, что напрямую влияет на стоимостные показатели продукции. Наиболее остро данная проблема наблюдается в тех отраслях, где осуществляется управление сложными многопараметрическими объектами. В данной работе выполняется идентификация комплекса «мельница-классификатор», функционирующего в технологическом процессе горно-обогатительного комбината. Построение модели осуществляется на основе аппарата искусственных нейронных сетей, с учетом динамических свойств объекта. Необходимость создания такой модели обусловлена дальнейшей разработкой прогнозирующей системы для помощи оператору.

1. Введение

На сегодняшний день технологический процесс большинства предприятий представляет собой значительную многошаговую последовательность операций, происходящих в объектах, характеризующихся большим числом технологических переменных и нелинейностью функциональных зависимостей, которыми описываются их изменения [1]. Управление объектами данного типа является достаточно сложной задачей. Тем более, когда в реальных условиях оператор управляет технологической цепочкой, состоящей из нескольких агрегатов, то вполне объяснима возможность совершения ошибок, приводящих к возникновению брака в продукции, необходимости аварийных остановов или же возникновению аварийных ситуаций [2, 3]. Для их предотвращения, оператор, как правило, осуществляет формирования «запаса сверху», ведя управление ниже зоны максимальной эффективности, но в рамках технологических регламентов.

Подобная стратегия позволяет получить годный продукт, но не обеспечивает максимальной эффективности процесса, приводя к удельному перерасходу энергоресурсов. Поэтому актуальным становится создание системы, способной оказывать помощь оператору при управлении технологической цепочкой в целом.

Из анализа технологии обогащения железорудного концентрата на горно-обогатительном комбинате [4, 5], можно сделать вывод, что данный процесс обладает перечисленными выше характеристиками, осложняющими задачу управления. Дополнительным фактором сложности является дискретный способ контроля качества продукта, осуществляемый лабораторией с периодом 1 раз в 2 часа, что не позволяет оператору иметь данные о качестве продукции на выходе в реальном времени. То есть отклик на изменение уставок будет виден только через значительное время, когда обработке будет подвергаться иной материальный поток сырья. Ситуации же смены уставок не являются редкостью, поскольку поступающий рудный материал различается по химическому составу, а соответственно и по физическим свойствам, что отражается на требуемом времени обработки для получения годного продукта.

Поэтому в данной работе предпринята попытка идентификации технологического объекта с достаточно высокими показателями точности при моделировании. Конечной целью является разработка системы, состоящей из набора моделей производственных агрегатов и способной на основе анализа текущих технологических показателей процесса выполнить прогнозирование, моделируя их будущее изменение. Обладая данной информацией, оператор сможет оценивать последствия изменения управляющих воздействий в реальном времени и корректировать их в более узких границах, что позволит вести процесс на более высоких показателях эффективности.

2. Теоретическая часть

Известными является множество способов идентификации технологических объектов на основе данных их промышленной эксплуатации. Наиболее распространены такие методы, как использование аналитических зависимостей, основывающихся на физических принципах функционирования объектов, применение аппарата передаточных звеньев, регрессионный анализ с использованием полиномов различного вида [6]. Существенным недостатком озвученных методов является невысокая точность при работе с нелинейными зависимостями. Еще одной проблемой является наличие строго определяемых коэффициентов, которые с течением времени могут изменять свое актуальное значение по причине изменения свойств сырья, параметров самого объекта. Это приводит к необходимости создания механизма адаптации или корректировки модели.

Поэтому в работе осуществляется разработка модели одного из главных объектов процесса обогащения – комплекса «мельница-классификатор» с использованием аппарата искусственных нейронных сетей (ИНС). Данный аппарат, за счет нелинейности, достигаемой использованием функций активации (ФА) различного вида, и способности обучения, должен обеспечить высокие показатели точности идентификации сложных технологических объектов и позволить адаптироваться к изменениям состояния как самих объектов, так и поступающего продукта [7].

Первоначально был осуществлен анализ комплекса «мельница-классификатор». Данный агрегат представляет собой барабанную шаровую мельницу, производящую помол рудного материала, поступающего через загрузочную бутару. В барабан также загружаются мелющие тела – шары, и подается вода для обеспечения условий помола и выполнения транспортной функции. Через разгрузочную бутару осуществляется выход пульпы, поступающей на спиральный классификатор, разделяющий кондиционный

помол и пески – возврат, загружаемый обратно в мельницу [4, 5]. При функционировании комплекса измеряются следующие переменные: вес подаваемой руды $W(t)$, расход воды в загрузку мельницы $Q_1(t)$, расход воды в бутару мельницы $Q_2(t)$, мощность привода мельницы $P(t)$, токи спиралей классификатора $(I_1(t), I_2(t))$, которые были выбраны в качестве входных сигналов объединенной модели, и сигнал плотности слива классификатора $D(t)$, который был выбран в качестве выходного для нейросетевой модели комплекса, поскольку на рассматриваемом предприятии осуществляется режим стабилизации плотностного режима, что определяет данный сигнал в качестве значащего.

Для формирования репрезентативных обучающей и тестовой выборок были обработаны значения показателей за период около 4 месяцев. Общий объем информации составлял 71500 точка по каждому из сигналов с дискретностью 1 минута. Дальнейшая задача состояла в создании модели комплекса «мельница-классификатор» на основе аппарата ИНС с учетом динамических свойств. Для выполнения данного условия во входной слой нейросетевой модели были добавлены нейроны, обрабатывающие сигнал плотности слива классификатора, задержанный на 1 и более тактов [8]. В ходе работы изучался вопрос необходимого и достаточного числа задержек сигнала, при котором будут получены высокие значения показателей качества моделирования, но не будет создано ситуации избыточности.

3. Экспериментальная часть

Для проведения процедуры идентификации была реализована архитектура ИНС в соответствии с положениями работ [9-11]. Число нейронов во входном слое соответствовало количеству обрабатываемых сигналов, был использован 1 скрытый слой с 35 нейронами в нем и 1 нейрон в выходном слое. Структура модели комплекса «мельница-классификатор» на основе аппарата ИНС изображена на рис. 1.




Рис. 1. Схема модели комплекса «мельница-классификатор» на основе аппарата ИНС.

На рисунке представлены следующие условные обозначения: $[W(t); Q_1(t); Q_2(t); P(t); I_1(t); I_2(t)]$ – кортеж сигналов входных параметров, $[D(t)]$ – выходной моделируемый сигнал плотности слива классификатора, $x[1...j]$ – нейроны входного слоя, Y – нейрон выходного слоя, w – весовые коэффициенты, s – сумма весовых коэффициентов, b – смещение, $f(s)$ – функции активации нейронов, $z[2...30]$ – такт задержки сигнала.

В ходе проведения экспериментов последовательно увеличивалось количество обрабатываемых тактов задержки выходного сигнала. К тому же были опробованы 2 метода организации динамики – путем последовательного наращивания числа задержек (последовательный метод) и использование дискретного метода, заключающегося в подаче задержки только на 1 такт, только на 2 такта и так далее. При моделировании использовался одинаковый набор сигналов задержки – от 1 до 30 тактов. Для оценки качества работы моделей были использованы такие показатели, как коэффициент корреляции реального и моделируемого сигнала плотности слива классификатора ($corr_k$) и суммарное значение ошибки на основе функционала МНК ($F(LSM)$). На рис. 2 (а,б) представлен график изменения данного показателя, как наиболее наглядно демонстрирующего результаты экспериментов.

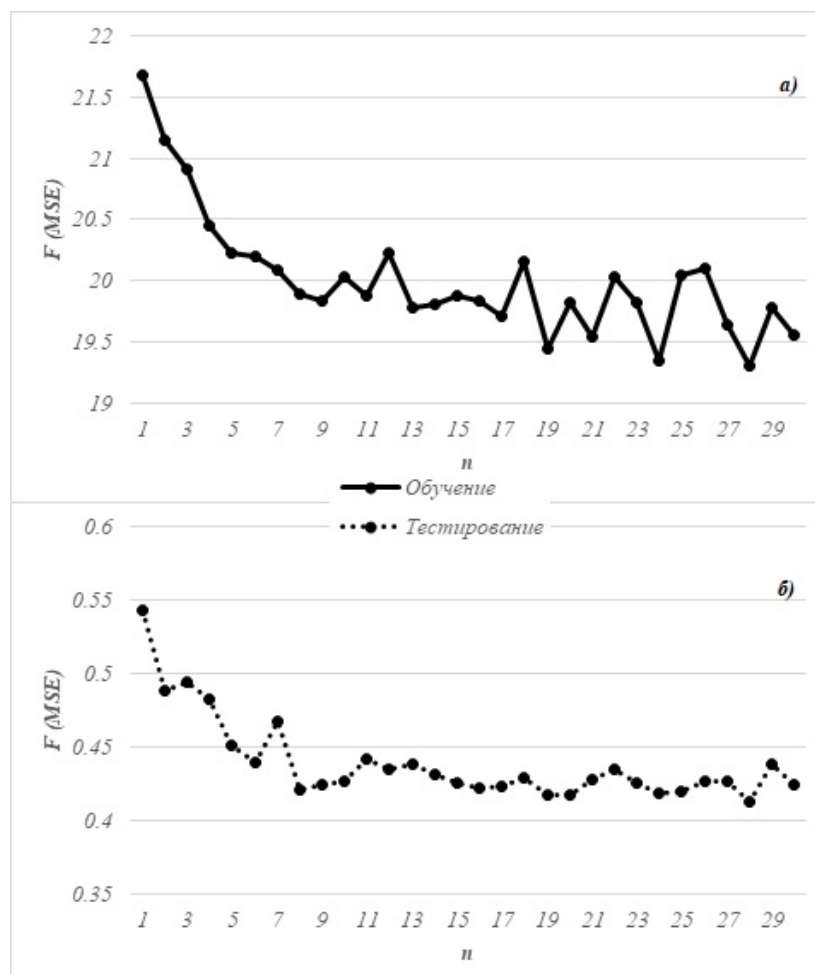


Рис. 2. Схема модели комплекса «мельница-классификатор» на основе аппарата ИНС.

Из рисунка видно, что достаточным числом задержек является 9 тактов. Численные значения показателей качества моделирования для опыта с 9 тактами задержки представлены в таблице 1.

Таблица 1. Численные значения показателей качества моделирования при использовании различных моделей.

	Подача на вход ИНС задержек сигнала плотности последовательным методом	Подача на вход ИНС задержек сигнала плотности дискретным методом
Обучение		
corr k	0.9955	0.9533
F (LSM)	19.8323	200.636
Тест		
corr k	0.9644	0.7217
F (LSM)	0.4241	5.0444

Данные результаты приведены для последовательного метода организации динамики модели. При подаче же задержек дискретным методом был получен аналогичный результат, но в целом данный метод, согласно значений показателей качества, показывает значительно худший результат. Поэтому в качестве приоритетного был выбран последовательный метод подачи задержек выходного сигнала.

4. Заключение

В ходе работы были осуществлены эксперименты по реализации динамики при моделировании сложного многопараметрического технологического объекта на основе аппарата ИНС. При проведении экспериментов были апробированы 2 различных способа организации динамики. На основании анализа численных значений показателей качества был выбран последовательный метод как основной. К тому же было определено число тактов задержки выходного сигнала, необходимое для достижения требуемого качества работы модели.

Разработка нейросетевой модели комплекса «мельница-классификатор» показывает возможность идентификации прочих агрегатов с использованием данного аппарата. Это необходимо для реализации прогнозирующей системы, способной на основе анализа текущих показателей технологического процесса обогащения моделировать будущий его ход и тем самым предоставлять оператору актуальные данные для повышения энергоэффективности процесса.

Список литературы

1. Дядик В.Ф., Байдали С.А., Криницын Н.С. Теория автоматического управления: учебное пособие / Томск: Изд-во Томского политехнического университета, 2011. 196 с.
2. Еременко Ю.И., Полещенко Д.А., Цыганков Ю.А. О построении нейросетевой модели технологического объекта на основе его информационно-аналитического представления // Вести высших учебных заведений Черноземья. 2018. № 1. С. 45-57.

3. Филимонов А.Б., Филимонов Н.Б. Ситуационный подход в задачах автоматизации управления техническими объектами // Мехатроника, автоматизация, управление. 2018. Т. 19, № 9. С. 563-578.
4. Марюта А.Н. Автоматическая оптимизация процесса обогащения руд на магнитно-обогатительных фабриках. М.: Недра, 1975. 328 с.
5. Олейников В.А., Тихонов О.Н. Автоматическое управление технологическими процессами в обогатительной промышленности. М.: Недра, 1966. 245 с.
6. Полещенко Д.А., Цыганков Ю.А. Идентификация многопараметрического технологического объекта управления // Материалы XIII Всероссийской научно-практической конференции с международным участием «Современные проблемы горно-металлургического комплекса. Наука и производство. Старый Оскол: СТИНИТУ «МИСиС», 2016. С. 88-90.
7. Eremenko Y., Poleshchenko D., Glushchenko A. About Heating Plants Control System Developing on Basis of Neural Network Usage for PID-Regulator Parameters Optimization // Applied Mechanics and Materials. 2014. Vol. 682. P. 80-86.
8. Лубенцов В.Ф. Исследование САУ процессом ферментации с применением технологии нейронных сетей // Приборы и системы. Управление, контроль, диагностика. 2005. № 9. С. 1-4.
9. Cybenko G. Approximation by superposition of a sigmoidal function//Mathematics of Control, Signals, and Systems. 1989. Vol. 2.P. 303-314.
10. Gorban A.N., Wunsch D. The general approximations theorem // Proc. IEEE IJCNN. IEEE, 1998. P. 1271-1274.
11. Hecht-Nielsen Rt. Theory of the backpropagation neural network // Proc. of the Int. Joint Conf. on Neural Networks, P. 593-611. IEEE Press, New York, June 1989.