ОБУЧЕНИЕ МАШИНЫ ОПТИМАЛЬНОМУ УПРАВЛЕНИЮ МНОГОФАКТОРНЫМ ОБЪЕКТОМ С ИСПОЛЬЗОВАНИЕМ АЛГОРИТМА РАСПОЗНАВАНИЯ МЕТОДОМ *R*-ФУНКЦИЙ

В. И. Салыга, И. Б. Сироджа

Харьков

В последнее время одной из наиболее актуальных задач является разработка принципиально новых методов построения систем автоматического управления сложными технологическими комплексами. Характерной чертой при развитии теории и практики автоматического управления является требование получения оптимального решения в любой производственной ситуации, возникающей в процессе функционирования системы. Основная проблема оптимального управления заключается в наиболее эффективном использовании имеющейся информации об объекте. Однако современные объекты управления характеризуются большим числом коррелированных внешних воздействий, объем информации о которых и скорость ее поступления зачастую превышают возможности человека выработать решение о действительном состоянии объекта. В частности, к сложным стохастическим объектам относятся и обогатительные процессы, которые характеризуются многофакторностью, наличием на входе и выходе неконтролируемых параметров, изменением характеристик основных воздействий в широких пределах, нелинейными зависимостями между параметрами, значительными запаздываниями по основным каналам управления, распределенностью параметров [1]. В этих условиях наиболее целесообразным является построение обучающихся систем управления, использующих методы теории автоматического распознавания образов.

Краткие сведения о состоянии автоматизации флотопроцесса

Промышленный флотопроцесс представляет собой сложную многомерную систему. В работах [1,6] приведена классификация переменных или обобщенных координат, определяющих эффективность ведения процесса флотации угля. Задачей управляющего устройства является выработка такого воздействия, при котором показатель качества достигает экстремального значения.

Автоматизация процессов обогащения имеет большое народнохозяйственное значение, определяя в значительной степени необходимые темпы роста коксохимической, металлургической, энергетической и других отраслей промышленности СССР. В области автоматизации флотоотделений сделаны уже первые шаги: созданы системы автоматического регулирования отдельными параметрами и системы автоматической стабилизации. В литературе описаны

системы автоматического регулирования плотности и расхода пульпы, расхода реагентов. Однако эти системы не могут обеспечить оптимального режима работы флотоотделений из-за сложности и стохастического характера физико-химических процессов, характеризующих флотацию.

До настоящего времени технологические режимы флотоотделений зачастую устанавливаются опытным путем, без достаточного обоснования основных закономерностей процесса. Поэтому многие фабрики ведут процесс флотации в далеко не оптимальных режимах; показатели процесса весьма неустойчивы. Оператор, руководствуясь часто интуитивными оценками, пытается управлять процессом, поддерживая показатели входных параметров в заданном диапазоне, несмотря на систематическое смещение внешних факторов. Этим в какой-то мере можно объяснить значительные дисперсии выходных показателей процесса.

При автоматизации флотационных отделений предлагается создание обучающихся автоматических систем.

Основное внимание следует уделить построению алгоритмов, удобных для использования на современных быстродействующих ЦВМ.

Описание алгоритма распознавания

Предлагаемый обучающийся алгоритм распознавания синтезирован на основе использования метода R-функций [2] и позволяет осуществить аналитическое описание сложных геометрических образов в многомерном пространстве, соответствующих исследуемым производственным ситуациям.

Входная информация об объекте распознавания (ситуации) представляет собой точку в n-мерном пространстве $\vec{X} = (x_1, \ldots, x_n)$, координаты которой являются численными значениями характерных признаков (параметров). Вектор $\vec{X} = (x_1, \ldots, x_n)$ будем называть реализацией определенной ситуации в пространстве признаков $\{x_1, x_2, \ldots, x_n\}$. Множество реализаций, объединенных какими-либо общими техническими или технологическими свойствами, назовем образом производственной ситуации, а конечную совокупность реализаций с заведомо известной информацией о принадлежности каждой реализации к определенному классу (образу) — учебной ситуационной выборкой.

Таким образом, каждому из выделенных классов производственных ситуаций в пространстве признаков соответствует некоторая область. Несмотря на то, что реальные производственные ситуации, принадлежащие разным классам, образуют непересекающиеся множества, для соответствующих им образов в пространстве выбираемых признаков условие непересекаемости

не выполняется в силу потери некоторой части полезной информации. В связи с этим создаются определенные трудности в построении алгоритмов разделения этих множеств в пространстве признаков.

Для преодоления этих трудностей используется рекуррентная процедура [3] предикатного описания произвольных геометрических форм с помощью R_2-функций, позволяющая эффективным образом осуществить идею аппроксимации заданными поверхностями границ областей, представляющих исследуемые образы в пространстве признаков. В качестве заданных поверхностей, в частности, используются гиперэллипсоид и гиперсфера.

R_2-функцией называется функция действительных переменных $y = f(x_1, \ldots, x_2, \ldots, x_n)$, определенная всюду в пространстве $\{x_1, x_2, \ldots, x_n\}$, если выполняется условие

$$S_2[f(x_1, \ldots, x_n)] = F[S(x_1), \ldots, S(x_n)],$$

где

$$S_2(x) = \begin{cases} 1, & \text{если } x \geqslant +0; \\ 0, & \text{если } x \leqslant -0, \end{cases}$$

а $F(x_1, x_2, \ldots, x_n)$ — булева функция.

Для более широкого ознакомления с теоретическими предпосылками читателю следует познакомиться с работами [2,3], а мы изложим основополагающие теоремы, используемые при синтезе алгоритма распознавания.

Теорема 1. Если некоторый геометрический образ (D) состоит из областей $(D_1), (D_2), \ldots, (D_m)$, заданных предикатами

$$\{f_1(x_1, \ldots, x_n) \geqslant 0\}, \quad \{f_2(x_1, \ldots, x_n) \geqslant 0\}, \ldots, \{f_m(x_1, \ldots, x_n) \geqslant 0,$$

а логика построения образа (D) определяется булевой функцией

$$D = F(D_1, D_2, \ldots, D_m),$$

то предикат

$$P(\vec{x}) \equiv \{\varphi[f_1(x_1, \ldots, x_n), f_2(x_1, \ldots, x_n), \ldots, f_m \times (x_1, \ldots, x_n)] \geqslant 0\}, \tag{1}$$

где $\varphi(u_1, u_2, \ldots, u_m)$ — R_2-функция, соответствующая булевой функции $F = F(D_1, D_2, \ldots, D_m)$, определяет геометрический образ (D).

Теорема 2. Если функции $f_i(x_1, \ldots, x_n)$; $(i = \overline{1, m})$ являются H-реализуемыми, то какова бы ни была логика построения образа (D) с помощью областей (D_i), $(i = \overline{1, m})$, определяемых предикатами $\{f_i(x_1, \ldots, x_n) \geqslant 0\}$, $(i = \overline{1, m})$, левая часть предиката (1) может быть построена с помощью следующей системы R_2-функций:
R_2-конъюнкция

$$z_1 \wedge_a z_2 = \frac{1}{2}\left(z_1 + z_2 - \sqrt{z_1^2 + z_2^2 - 2az_1z_2}\right);$$

R_2-дизъюнкция

$$z_1 \vee_\alpha z_2 = \frac{1}{2}\left(z_1 + z_2 + \sqrt{z_1^2 + z_2^2 - 2\alpha z_1 z_2}\right); \qquad (2)$$

R_2-отрицание

$$\bar{z} = -z,$$

где

$$-1 < [\alpha = \alpha(z_1, z_2)] \leqslant 1.$$

Для простоты аналитического описания образов использовались функции (2) при $\alpha = 1$

$$\begin{aligned} z_1 \wedge_1 z_2 &= \frac{1}{2}(z_1 + z_2 - |z_1 - z_2|) = \min(z_1, z_2); \\ z_1 \vee_1 z_2 &= \frac{1}{2}(z_1 + z_2 + |z_1 - z_2|) = \max(z_1, z_2); \\ \bar{z} &= -z. \end{aligned} \qquad (3)$$

Рассматриваемый алгоритм распознавания работает в двух режимах: обучения и распознавания.

В режиме обучения на вход алгоритма поступает информация учебной ситуационной выборки по каждому образу. Далее осуществляется построение гиперэллипсоидов, описывающих каждую из N учебных выборок в пространстве признаков (N — количество образов). Это построение состоит из трех последовательных операций:

1) линейного преобразования (сжатия) пространства признаков с учетом дисперсии реализаций образа по координатам;

2) построения гиперсфер в преобразованном пространстве, охватывающих учебную выборку каждого образа с центром в точке МОЖ (математического ожидания) элементов учебной выборки;

3) превращения гиперсферы в гиперэллипсоид путем обратного преобразования пространства признаков.

Построенный таким образом гиперэллипсоид определяется предикатом

$$B_j = P_j^{+}(\vec{x}) \equiv \left\{\left[r_j^2 - \left(\sum_{q=1}^{n} k_q (x_{cq} - x_{sq})^2\right)\right] \geqslant 0\right\}, \qquad (4)$$

$$(j = \overline{1, N})$$

где r_j — радиус описанной гиперсферы в преобразованном пространстве с центром в точке

$$\vec{x}_{cq} = (x_{c1}, \ldots, x_{cn}) = \frac{\sum_{q=1}^{n} x_q}{m}; \quad (q = \overline{1, n});$$

m — количество точек учебной выборки;
x_s — координата текущей точки;

$k_q = \frac{\alpha_q}{\alpha_{\max}}$ — коэффициент сжатия по осям координат,

где

$$\alpha_q = \frac{1}{\sigma_q};\ \sigma_q = \sqrt{\frac{1}{m}\sum_{q=1}^{n}(x_{cq} - x_q)^2}.$$

Радиус описанной гиперсферы равен максимальному расстоянию от центра тяжести выборки до всех точек, входящих в нее, и определяется по формуле

$$r_{cs} = \sqrt{\sum_{q=1}^{n} k_q\,(x_{cq} - x_{sq})^2}.$$

Построение гиперэллипсоидов завершается формированием так называемого начального предикатного описания всех образов, которому соответствует логика:

$$A_j = \begin{cases} \underline{B_1 \wedge \bar{B}_2 \wedge \ldots \wedge \bar{B}_N}; \\ \underline{B_j \wedge \bar{B}_{j+1} \wedge \ldots \wedge \bar{B}_N};\ (j = \overline{1,\ N}). \\ B_N \end{cases} \qquad (5)$$

В результате начального предикатного описания каждый из предикатов (4) описывает не всю область, занимаемую учебной выборкой. В эту область могут не входить все точки учебной выборки данного образа и, наоборот, она может включать точки «чужих» образов. В связи с этим производится этап «доучивания» алгоритма, который состоит в следующем. В каждой точке учебной выборки проверяется истинность каждого из предикатов (4) в соответствии с логикой (5) и априорной классификацией «учителя». Если предикат $P_j^+(\vec{x})$ в точке j-го образа истинен, то логика (5) остается без изменения. В противном случае производится построение гиперсферы с центром в исследуемой точке и радиусом, равным половине расстояния от данной точки до ближайшей «чужой». При этом гиперсфера определяется предикатом

$$C_j = P_j^+(\vec{x}) = \left\{\left[\frac{r_j^2}{4} - \left(\sum_{q=1}^{n}(x_{pq} - x_{sq})^2\right)\right] \geqslant 0\right\}, \qquad (6)$$

где p и s — p-я и s-я координаты соответствующих точек.

Таким образом производится доопределение начального предикатного описания в соответствии со следующей рекуррентной логической процедурой. Если после r-го такта обучения распознаванию N образов построены логические предикаты $A_{j(r)}$, а очередная исследуемая точка принадлежит j-му образу, то после

$(r+1)$-го такта обучения доопределенные предикаты будут отвечать логике

$$A_{j(r+1)} = \begin{cases} A_{1(r)} \wedge \bar{C}_{j(r+1)} \\ A_{2(r)} \wedge \bar{C}_{j(r+1)} \\ \dots\dots\dots\dots \\ A_{j(r)} \vee C_{j(r+1)} \\ \dots\dots\dots\dots \\ A_{N(r)} \wedge \bar{C}_{j(r+1)} \end{cases} \qquad (7)$$

После перебора всех точек учебных выборок обучение прекращается.

Режим распознавания состоит в определении значения истинности всех построенных в период обучения предикатов в предъявляемой новой точке. Результат распознавания определяется номером j предиката $P_j^+(\vec{x})$, истинного в испытуемой точке $\vec{x}$.

Экспериментальные результаты по обучению машины управлению процессом флотации

Необходимость внедрения быстродействующих вычислительных машин в сферу управления сложными технологическими процессами обусловлена «запаздываниями» в принятии решения человеком, что при современных скоростях приводит к перерасходу сырья до 25—30% по сравнению с оптимальным. При этом существенно ухудшается качество выходных продуктов.

Сложность объектов обогатительной технологии, неполнота априорной информации вызывает необходимость в применении обучающихся систем, способных после некоторого периода обучения выработать решающее правило и производить распознавание производственных ситуаций. При этом из всех возможных производственных ситуаций в пространстве параметров $\{x_1, x_2, \dots, x_n\}$ будем рассматривать лишь те, которые непосредственно связаны с конкретной задачей автоматического управления флотопроцессом. В частности, при построении оптимальных по быстродействию систем управляющий сигнал $u(t)$ принимает одно из двух значений ± 1 при отклонении режима от номинального. Таким образом, при решении задачи синтеза системы управления процессом флотации, оптимальной по быстродействию, можно выбрать три производственные ситуации (три образа), соответствующие следующим воздействиям на управляющие органы:

I. Регулировать путем увеличения управляющих воздействий — ситуация № 1, A_1.

II. Достаточно, так держать (номинальный режим) — ситуация № 2, A_2.

III. Регулировать путем уменьшения управляющих воздействий — ситуация № 3, A_3.

Задача обучения сводится к построению предикатов $P_j^+(\vec{x})$, $(j = \overline{1, 3})$, определяющих каждую из трех производственных ситуаций. При этом во всех $\vec{x} \in A_j$ предикат P_j истинен, а в $\vec{x} \bar{\in} A_j$ — ложен. В соответствии со значениями истинности предикатов P_j вырабатывается управляющий сигнал

$$u(t) = \begin{cases} +1, & \text{если } P_1 \geqslant 0; \\ -1, & \text{если } P_3 \geqslant 0. \end{cases} \qquad (8)$$

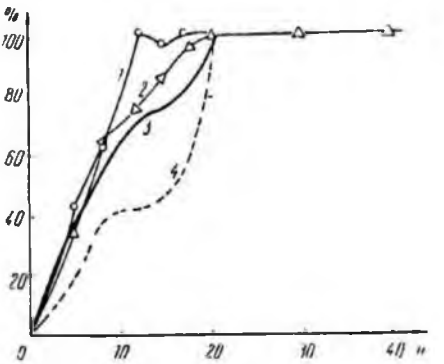

Установив соответствие между $x(t)$ и $u_{опт}(t)$, можно использовать алгоритмы обучения с поощрением для классификации. Полученные алгоритмы позволяют восстановить поверхность переключения в обучающейся системе управления.

При синтезе обучающейся системы управления был использован описанный выше алгоритм распознавания. В качестве входных параметров приняты плотность δ и расход $Q_п$ пульпы, зольность исходного шлама $A_и^c$, ситовые $C_{1,2}$ и фракционный Ф составы [7]. Управляющим воздействием является расход реагентов $Q_р$. В качестве выходных параметров принимались зольности концентрата $A_к^c$ и хвостов $A_{хв}^c$. Для обучения машины были использованы статистические данные по «оптимальному» ведению процесса флотации углей в условиях Суходольской ЦОФ.

Алгоритм реализован на ЦВМ «БЭСМ-4» в режиме обучения с поощрением. В таблице приведены результаты обучения. На рисунке показана зависимость процента правильных ответов от числа обучающих точек n. Показателем качества обучения служила дисперсия оценки оптимального вектора $U_{опт}$ в каждый момент времени

$$W^2[n] = M\{\|U[n] - U_{опт}\|^2\}. \qquad (9)$$

Описанная обучающая система является асимптотически оптимальной [5]. Формируемые в процессе обучения аналитические выражения в форме указанных выше предикатов определяют комбинированные гиперэллиптические и гиперсферические поверхности, которые достаточно аппроксимируют в пространстве изображений границы областей рассматриваемых образов. Достаточность аппроксимации обеспечивается сходимостью рекуррентной процедуры (7), хорошо согласующейся с гипотезой N-экстраполируемости образов В. М. Глушкова [4]. Кроме этого, предикаты весьма

просты и удобны в автоматической реализации на ЭЦВМ, ибо R-функции, представляющие их основу, сочетают в себе аналитические и логические свойства.

№ опыта	№ образа	Количество обучающих точек	Количество экзаменуемых точек	Количество ошибочных ответов	Количество ответов «не знаю»	% правильных ответов	Общий % правильных ответов
1	I	5	300	240	0	20	33
	II	5	300	0	172	43	
	III	5	300	51	147	34	
2	I	8	300	181	0	40	56
	II	8	300	0	114	62	
	III	8	300	27	81	64	
3	I	12	300	179	0	41	72
	II	12	300	1	0	100	
	III	12	300	53	16	76	
4	I	15	300	165	0	45	75
	II	15	300	19	0	94	
	III	15	300	22	16	87	
5	I	18	300	120	0	60	85
	II	18	300	0	0	100	
	III	18	300	6	6	96	
6	I	21	297	0	0	100	100
	II	21	297	0	0	100	
	III	21	297	0	0	100	
7	I	30	288	0	0	100	100
	II	30	288	0	0	100	
	III	30	288	0	0	100	
8	I	40	278	0	0	100	100
	II	40	278	0	0	100	
	III	40	278	0	0	100	

ЛИТЕРАТУРА

1. V. I. Saliga, N. R. Hadžikov. Rješavanje zadataka identifikacije stacionarnih upravljivih objekata tehnologije obogaćivanja. Zbornik Radova Jurema, Svezak I, Zagreb, 1970.
2. В. Л. Рвачев. Геометрические приложения алгебры логики. Изд-во «Техніка», Киев, 1967.
3. И. Б. Сироджа. Алгоритм распознавания геометрических образов. «Изв. АН СССР, Техническая кибернетика», № 5, 1967.
4. В. М. Глушков. Введение в кибернетику. Изд. АН УССР, 1964.
5. Я. З. Цыпкин. Основы теории обучающихся систем. Изд-во «Наука», 1970.

6. В. И. Салыга. Постановка задачи оптимального управления процессом флотации. Сб. «Приборы и системы автоматики», вып. 15. Изд-во ХГУ, Харьков, 1970.
7. В. И. Салыга, А. К. Байдал, С. Г. Павлюченко. Применение множественной корреляции для анализа основных технологических зависимостей процесса флотации. Сб. «Обогащение и брикетирование угля», № 8. Изд-во «Недра», 1968.

СТАТИСТИЧЕСКОЕ ЭКВИВАЛЕНТИРОВАНИЕ ДИССИПАТИВНЫХ ДИНАМИЧЕСКИХ СИСТЕМ

Б. И. Мокин
Кривой Рог

Постановка задачи и исходные предпосылки

Все динамические системы в процессе эксплуатации изменяют свои параметры. Причины этого могут быть различными. Мы рассмотрим только те системы, изменения параметров которых обусловлены износом либо изменением рабочего режима по технологическим условиям, т. е. системы, которые в обычном смысле считаются стационарными.

Очевидно, что даже при очень медленных изменениях в процессе эксплуатации необходим анализ динамики систем с целью выявления новых границ областей устойчивости и изменений характера протекания переходных процессов. Чтобы произвести такой анализ, необходимо знать динамические характеристики исследуемой системы, точное значение которых определяется с помощью решения задачи идентификации.

Методы идентификации динамических систем с указанием преимуществ и недостатков наиболее полно представлены в работах [1, 2]. Определение точных значений характеристик динамических систем сопряжено с большими трудностями, поэтому иногда целесообразнее определять их более простые эквивалентные аналоги, позволяющие проводить исследования без существенных погрешностей.

Если исследуемая система относится к классу диссипативных, а ее входным воздействием является эргодический стационарный случайный процесс (очень часто встречающийся на практике случай), ее эквивалентные динамические характеристики целесообразно определять с помощью метода статистического эквивалентирования, алгоритм которого основан на следующих исходных предпосылках.

1. Передаточная функция системы аппроксимируется выражением

$$W(s) = \frac{K(cs+1)}{bs^2+as+1}, \qquad (1)$$