



МЕТОДЫ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ЗАДАЧАХ ОПЕРАТИВНОГО УПРАВЛЕНИЯ И ОПТИМИЗАЦИИ СЛОЖНЫХ ТЕХНОЛОГИЧЕСКИХ КОМПЛЕКСОВ¹

Н.В. Крапухина, К.М. Пастухова, П.А. Свиридов

Московский государственный институт стали и сплавов, г. Москва

Рассмотрены особенности применения генетических алгоритмов для оптимизации сложных непрерывных статических систем. Предпринята попытка улучшения сходимости итерационных методов расчета таких систем.

В настоящее время все больше проявляется тенденция комплексного управления предприятием с помощью информационно-управляющих систем. Такие системы должны не только обладать функциями сбора, обработки, хранения, передачи и представления информации, но и выполнять многовариантные расчеты, необходимые для принятия обоснованных управленческих решений. Одним из методов оценки сценариев, анализируемых при принятии решений, является имитационное моделирование, поскольку постановка натурального эксперимента практически всегда неприемлема в силу ограниченности материальных или временных ресурсов. Немалую роль здесь играет моделирование технологического процесса производства. Принятие оптимального в каком-либо смысле решения непосредственно связано с оптимизацией технологического процесса.

Значительную часть промышленности составляют отрасли с непрерывным циклом производства — обогащение руд цветных и редких металлов, металлургия, нефтехимия, химическая промышленность, фармацевтика и др.

При моделировании и оптимизации технологических процессов в этих отраслях возникают следующие трудности:

- необходимость описания большого количества агрегатов и связей между ними;
- существенная нелинейность описания агрегатов;
- наличие рециркуляционных потоков;
- наличие агрегатов, для которых не известно аналитическое описание и которые описываются как «черный ящик»;
- сложность решения системы нелинейных уравнений большой размерности, определяемой числом агрегатов сложного комплекса и числом материальных потоков, связывающих эти агрегаты, а также размерностью векторов, характеризующих эти потоки;
- необходимость определения глобального экстремума выходов системы относительно входных воздействий;
- неизвестный вид и сложность вычисления целевой функции;
- плохая сходимость классических методов оптимизации.

Изучая проблему расчета технологических схем, авторы пришли к выводу, что одним из лучших путей ее решения, описанных в литературе [1], заключается в представлении технологической схемы в виде потокового ориентированного графа и применении методов структурного анализа. Модификация алгоритмов структурного анализа графа, выполненная авторами, позволила снизить вычислительную сложность расчета путём уменьшения числа итерируемых переменных. Данный подход позволяет производить расчет и оптимиза-

¹ Статья рекомендована к печати Программным комитетом Второй международной конференции по проблемам управления (Москва, 2003 г.).

цию сложной схемы, в которой часть моделей узлов не имеет аналитического описания. В последние годы в связи со значительным ростом вычислительных мощностей современных ЭВМ появилась возможность эффективного решения этой проблемы методами искусственного интеллекта, а именно, путем привлечения аппарата нейронных сетей. Перечисленные трудности оптимизации традиционно преодолеваются с помощью методов случайного поиска, однако сейчас появилась возможность применения генетических алгоритмов, которые часто оказываются более эффективными.

Рассмотрим более подробно применение методов искусственного интеллекта для моделирования и оптимизации сложных непрерывных статистических систем.

Для расчета технологической схемы производственного процесса, представленной в виде ориентированного графа, имеет значение лишь сам факт преобразования значений входных и управляющих переменных в значения переменных выходного потока, но не способ, которым это преобразование осуществляется. Часто исследователь не располагает моделью агрегата, заданной в аналитическом виде. В то же время, он может располагать достаточно большим множеством экспериментальных данных, полученных, например, в результате замеров значений соответствующих параметров и потоков на реальном физическом объекте. Сами по себе эти данные, при условии их правильного подбора, могут достаточно хорошо отображать поведение объекта в различных условиях. Однако в процессе моделирования требуется как можно более точное вычисление функции модели узла в тех точках, которые не входят во множество экспериментальных данных, т. е. аппроксимация функций многих переменных.

В разработанной авторами системе моделирования сложных технологических процессов предусматривается возможность расчета производственных схем, включающих в себя узлы с описанием типа «черного ящика». Для этого предлагается воспользоваться аппаратом нейронных сетей.

Традиционно для аппроксимации функций многих переменных применяют нейронные сети прямого распространения, что предполагает подбор структуры сети (количество скрытых слоев, число нейронов в каждом слое, функции активации отдельных нейронов) и обучение построенной сети путем подбора весов синапсов.

Учитывая, что конечный пользователь информационной системы, скорее всего, не является специалистом в области теории нейронных сетей, предлагается отдавать предпочтение тем нейросетевым алгоритмам, которые характеризуются максимальной степенью автоматизации процесса создания и обучения нейронной сети. Одним из

лучших среди них можно считать алгоритм Sibling/Descendant Cascade Correlation (SDCC) [2]. В его основе лежит алгоритм каскадной корреляции Фалмана [3]. Алгоритм предлагает конструктивный подход к созданию и обучению нейронной сети путем последовательного усложнения ее структуры. При этом могут применяться нейроны с различными начальными значениями весов синапсов и даже с различными функциями активации.

Отметим, что хотя алгоритм SDCC в значительной степени автоматизирует процесс обучения, в его исходной версии используется параметр λ , влияющий на интенсивность роста числа слоев нейросети. Авторами разработано эмпирическое правило автоматического подбора этого параметра, в основе которого лежит отслеживание изменения ошибки обучения при добавлении в сеть нейронов-близнецов. Коэффициент изменяется таким образом, чтобы добавление в сеть нейронов-близнецов было более вероятно до тех пор, пока расширение существующего скрытого слоя приводит к уменьшению ошибки обучения. Если введение нового нейрона в существующий скрытый слой дает меньший эффект (в смысле уменьшения ошибки) по сравнению с предыдущим шагом, то считается, что существующий слой начал исчерпывать свой «потенциал», и вероятность добавления нового слоя увеличивается.

Если текущий шаг обучения является самым первым или на очередном шаге обучения был выбран для добавления в сеть один из нейронов-потомков, то значение λ для следующего шага становится равным нулю, т.е. сразу после углубления сети всегда предпринимается попытка обучения за счет расширения уже существующего скрытого слоя.

Если же на текущем шаге был выбран один из нейронов-близнецов, то после соединения выбранного нейрона с выходным слоем синапсами и обучением этих синапсов возможны следующие варианты.

- Значение функции ошибки увеличилось. В этом случае выбранный нейрон удаляется из сети, а на следующем шаге выбор осуществляется только из нейронов-потомков. Это значит, что через один шаг значение λ станет равным нулю и процесс повторяется.
- Значение функции ошибки уменьшилось. В этом случае значение λ для следующего шага обучения вычисляется по формуле:

$$\lambda(t+1) = \max\left\{0, \min\left\{1, \lambda(t) + \left(1 - \frac{\varepsilon(t)}{\varepsilon(t-1)}\right)\right\}\right\},$$

где $\lambda(t)$ — значение λ на текущем шаге обучения; $\varepsilon(t)$ — значение относительного изменения ошибки на текущем шаге обучения; $\varepsilon(t-1)$ — значение относительного изменения ошибки на предыдущем шаге обучения.



Относительное изменение ошибки на очередном шаге вычисляется по формуле:

$$\varepsilon(t) = \frac{E(t) - E(t-1)}{E(t) + E(t-1)},$$

где $E(t)$ – значение функции ошибки на том же шаге обучения, для которого вычисляется значение относительного изменения ошибки; $E(t-1)$ – значение функции ошибки на предыдущем шаге обучения.

Для эффективного управления производством необходимо определение оптимального режима функционирования системы. При оптимизации технологической схемы производственного процесса возникает необходимость нахождения глобального оптимума многомодальной функции неизвестного вида. Это налагает определенные ограничения на метод оптимизации, делая возможным только применение методов прямого поиска.

На данный момент для решения этой задачи большой популярностью пользуются методы оптимизации, основанные на генетических алгоритмах. Эти алгоритмы находят глобальный оптимум с большей вероятностью, чем алгоритмы случайного поиска, предназначенные для этой же цели.

В качестве хромосомы рассматривается точка пространства поиска. Генам хромосомы соответствуют значения оптимизируемых параметров. В качестве функции приспособленности рассматривается функция вида $\mu(F(x))$, где $F(x)$ – целевая функция.

К преимуществам генетических алгоритмов можно отнести то, что они не требуют задания начальной точки. Начальная популяция обычно генерируется случайным образом. Однако существуют и другие методы. Один из них описан в работе [4] и подразумевает генерацию начальной популяции по принципу побитового разнообразия, которое вычисляется по формуле

$$D_{bit} = \frac{1}{l} \sum_{i=1}^l \left(1 - 4 \left(0,5 - \frac{c_i}{v} \right) \right),$$

где c_i – число нулей в i -ой позиции, суммированное по всем особям популяции; l – длина хромосомы; v – численность популяции. Популяция генерируется таким образом, чтобы значение D_{bit} было максимальным.

Такой способ генерации решает и еще одну проблему, возникающую при поиске глобального оптимума – попадание в точки локальных экстремумов. Благодаря такой генерации начальной популяции происходит максимальный охват области поиска. Применение специальных методов выбора «родителей» в сочетании с некоторыми эвристиче-

скими предположениями позволяет не сужать эту область поиска в начале работы алгоритма и обеспечить его сходимость в конце работы. Это достигается двумя схемами выбора «родителей»: схема «аутбридинга» и схема «инбридинга». «Аутбридинг» – скрещивание родителей с дальним родством для поддержания разнообразия популяции. «Инбридинг» – скрещивание близкородственных особей. Его применение может приводить к преждевременной сходимости к локальному оптимуму. Особи являются «близкими родственниками», если хэммингово расстояние между их генотипами не превышает заданного положительного числа d .

Еще одной проблемой, которую решают генетические алгоритмы, является проблема нарушения простых ограничений в процессе поиска. Это важно, поскольку при их нарушении возможна неопределенность значения целевой функции из-за нарушения областей определения аргументов. Эти ограничения учитываются автоматически при генерации хромосомы. Остальные же ограничения учитываются при помощи введения «штрафных» функций.

Помимо применения методов искусственного интеллекта к моделированию и оптимизации сложных непрерывных статических систем авторами была предпринята попытка улучшения сходимости итерационных методов расчета таких систем.

Итерационные методы расчета схемы, в силу существенной нелинейности модели и большой размерности задачи, как правило, имеют плохую сходимость. Одним из распространенных способов улучшения их сходимости служит уменьшение числа итерируемых переменных. Представление схемы в виде графа позволяет снизить размерность путем разрыва обратных связей в системе и построения итерационных процедур в точках разрыва. Выбором оптимального множества точек разрыва можно существенно улучшить сходимость итерационной процедуры. Наиболее распространенным критерием оптимальности является число итерируемых переменных. Для разрыва графа с применением этого критерия в работе [1] предложены эффективные алгоритмы структурного анализа.

Однако данный критерий далеко не всегда наилучший, поскольку сходимость итерационного процесса сильно зависит также от начальных приближений. Эксперт-исследователь может располагать неформальной информацией о возможных значениях начальных приближений в определенных точках разрыва. Для учета таких знаний авторы предлагают некоторую модификацию упомянутого критерия, сводящуюся к вводу дополнительного коэффициента α , характеризующего степень желательности разрыва определенных дуг графа. При

этом формальная размерность дуг графа пересчитывается по формуле:

$$R_{\text{формальная}} = \frac{1-\alpha}{\alpha} R_{\text{реальная}}$$

Случай $\alpha = 0$ означает абсолютную недопустимость разрыва дуги, а $\alpha = 1$ – предпочтительность ее разрыва. Заметим, что данный критерий сохраняет свойство аддитивности, важное для применяемых алгоритмов структурного анализа.

Другая альтернатива определения вектора начальных условий, предложенная авторами, заключается в пересчете их значений, исходя из информации, известной эксперту для других потоков в системе. Исследователь отражает степень своих знаний с помощью специального коэффициента $\beta \in [0; 1]$. Значение $\beta = 0$ соответствует полному отсутствию информации о начальных приближениях для переменных потока; значение $\beta = 1$ означает абсолютную уверенность исследователя в начальных приближениях. Для учета этой информации авторы предлагают использовать алгоритм проектирования начальных приближений. Этот алгоритм осуществляет анализ графа схемы с целью определения множества дуг, оптимальных с точки зрения введенных исследователем коэффициентов β и обеспечивающих достаточно быструю сходимость в точках разрыва. Далее следует специальным образом организованный процесс расчета схемы, осуществляющий предварительную итера-

цию с целью расчета начальных приближений на разорванных потоках.

Методы оптимизации на основе генетических алгоритмов и аппроксимация функций были применены авторами для оптимизации схемы обогащения медно-никелевого файнштейна комбината «Североникель».

Работа выполнена на кафедре инженерной кибернетики Московского государственного института стали и сплавов.

ЛИТЕРАТУРА

1. *Островский Г.М., Волин Ю. М.* Моделирование сложных химико-технологических схем. – М.: Химия, 1975.
2. *Baluja S., Fahlman S. E.* Reducing Network Depth in the Cascade-Correlation Learning Architecture / School of Computer Science. Carnegie Mellon University. – Pittsburgh, 1991. – School of Computer Science. Carnegie Mellon University, October 17, 1994. – CMU-CS-94-209.
3. *Fahlman S.E., Lebiere C.* The Cascade-Correlation Learning Architecture / School of Computer Science. Carnegie Mellon University. – Pittsburgh, August 29, 1991. – CMU-CS-90-100.
4. *Исаев С. А.* Разработка и исследование генетических алгоритмов для принятия решений на основе многокритериальных нелинейных моделей: Дисс. канд. техн. наук. – Н. Новгород, 2000. – 198 с.

☎ (095) 236-25-35

E-mails: krapuhina@mis.ru, svirc@newmail.ru, kseniya_p@mail.ru □

Новая книга

Прангишвили И. В. Энтропийные и другие системные закономерности: вопросы управления сложными системами – М.: Наука, 2003. – 428 с.

Предназначена для специалистов по проблемам управления, системному анализу и информатике, аспирантов и студентов.

В монографии рассмотрены энтропийные модели сложных систем и энтропийные расчеты при управлении производственными и бизнес-процессами. Изложены основные объективные общесистемные закономерности функционирования технических и социальных систем, в том числе энтропийного равновесия, и определены методы управления энтропийными колебаниями, энтропийным равновесием и избыточной энтропией. Исследуются системные закономерности зависимости потенциала систем от их структуры, обсуждается резонансное управление. Анализируются сложные искусственные и природные системы и вопросы управления ими. В свете системного подхода представлены пути выхода России из структурного и системного кризисов, свойства современного общества и проблемы его развития.