

В.Р. САБАНИН, Н.И. СМИРНОВ,
А.И. РЕПИН (МЭИ)

Параметрическая оптимизация и диагностика с использованием генетических алгоритмов

Рассматриваются пути решения многоэкстремальных задач параметрической оптимизации алгоритмов управления и диагностики, для решения которых предлагается модифицированный генетический алгоритм (МГА). В качестве примера, иллюстрирующего вычислительные возможности МГА, рассмотрен оптимальный синтез двухсвязной системы регулирования с двухканальным нейросетевым регулирующим устройством.

The paper discusses a way to solve multicriterion problems of parametric optimization of control and diagnostics algorithms and offers a modified genetic algorithm for their solution. Optimal synthesis of a two-variable regulatory control system with a two-channel neuron network-based controller is considered as an example illustrating the computational capability of the algorithm.

Получившие распространение при управлении и диагностике имитационные методы исследования предъявляют качественно новые требования к решению задач параметрической оптимизации [1]. На замену классическим косвенным приемам вычисления оптимальных состояний все активнее приходят численные алгоритмы оптимизации.

Опыт исследования алгоритмов управления и диагностики показал, что для простых одноконтурных систем регулирования задачи оптимизации, как правило, являются одноэкстремальными. Однако для сложных систем управления с нейроконтроллерами и многопараметрических диагностических нейросетей характерно наличие большого числа локальных экстремумов.

Для решения одноэкстремальных задач оптимизации существует достаточное число аналитических и численных алгоритмов. Одним из таких алгоритмов является симплекс-метод деформируемого многогранника Нелдера-Мида [2]. Универсальная программная реализация алгоритма представлена в работе [3]. Там же рассмотрены примеры ее использования для решения различных оптимизационных задач, включая задачу параметрической идентификации математических моделей объектов управления.

При оптимизации одноконтурной АСР с ПИ регулятором методом Нелдера-Мида было показано в работе [4], что из различных начальных координат алгоритм осуществлял устойчивый целенаправленный поиск вектора настроечных параметров K_p, K_u для целевой функции:

$$F(K_p, K_u, \psi, t) = I_{i,y} \cdot [1 + a \cdot |\psi_{30} - \psi|] \rightarrow \min, \quad (1)$$

где $I_{i,y} = \int_0^{t_p} |y(t)| dt$ – интеграл по модулю регулируемой величины $y(t)$ на интервале времени переходного процесса t_p ; ψ_{30}, ψ – соответственно, заданная и текущая

степень затухания переходного процесса регулирования; a – масштабный коэффициент, учитывающий вес штрафной функции.

Применение метода деформируемого многогранника для оптимизации одноконтурной системы регулирования с ПИД регулятором, двухконтурной АСР с дифференциатором и АСР с нейрорегуляторами различной структуры привело к неоднозначности решения, результаты которого зависели от выбранных начальных координат. Из этого следует вывод о многоэкстремальности подобных задач.

Методы одноэкстремальной оптимизации не гарантировали оптимальности решения, поэтому для решения поставленных задач возникает необходимость применения методов глобальной оптимизации. В настоящее время наиболее предпочтительными методами многопараметрической многоэкстремальной оптимизации являются генетические алгоритмы [5], реализующие постулаты теории эволюции и опыта селекции растений и животных. Стратегия поиска оптимального решения в генетических алгоритмах опирается на гипотезу селекции: чем выше приспособленность особи, тем выше вероятность того, что в потомстве, полученном с ее участием, признаки, определяющие приспособленность, будут выражены еще сильнее [6].

Генетические алгоритмы являются элементарной моделью процесса эволюции популяций особей в природе. Если принять, что каждая особь популяции является точкой в координатном пространстве оптимизационной задачи $X_i[x_{1i}, x_{2i}, \dots, x_{li}]$, а приспособленность особи – соответствующим значением функции цели $f(X_i)$, то популяцию особей можно рассматривать как множество координатных точек в пространстве, а процесс эволюции – как движение этих точек в сторону оптимальных значений целевой функции.

Подобно тому, как в природе информация о наследственных признаках организмов представлена в хромосомах в виде линейной последовательности различных комбинаций четырех нуклеотидов (А – аденин, Ц – цитозин, Т – тимин и Г – гуанин), в генетическом алгоритме векторы переменных также записываются в виде цепочек символов, используя двух-, трех- или четырехбуквенный алфавит [5]. Хромосомное представление информации позволяет применять генетические операторы: кроссовер, мутацию и инверсию. Генетические операторы являются упрощенной формой передачи наследственности. В природе они обеспечивают процесс эволюции, а в генетических алгоритмах оптимизации – движение координатных точек в направлении оптимальных значений функции цели.

Работа генетического алгоритма состоит из следующих этапов:

1. Создание в исследуемом пространстве поиска E^N начальной популяции особей размером μ ($\mu > N$), где N – размерность задачи. Исходная популяция обычно создается случайным образом сразу в символьном виде.

2. Перевод каждого вектора координат $X_i[x_{1i}, x_{2i}, \dots, x_{li}]; i \in \overline{0, \mu}$ из символьного вида в десятичный и расчет целевой функции для каждой координатной точки $f_i(X_i); i \in \overline{0, \mu}$.

3. Оценка популяции на вырожденность. Вырожденность популяции оценивается по разности максимального f^{\max} и минимального f^{\min} значений функции цели. При выполнении условия:

$$|f^{\max} - f^{\min}| \leq \varepsilon, \quad (2)$$

где ε – достаточно малое число, популяция вырождается в точку, соответствующую решению задачи. В противном случае выполняется следующий пункт.

4. Удаление из популяции $\rho \cdot \mu$ наименее приспособленных по значению функции цели особей, где ρ – коэффициент элиминирования (обычно он принимается равным 0,1 [7]). Оставшиеся $(1-\rho) \cdot \mu$ особей составляют родительскую группу, которая используется для генерации потомства (новых координатных точек).

5. Из родительской группы равновероятно $\rho \cdot \mu$ раз выбираются пары родительских особей, к которым последовательно применяются генетические операторы. В результате генетических операций генерируются $\rho \cdot \mu$ потомков (новых координатных точек). Полученные потомки помещаются в исходную популяцию, и для них вычисляются функции цели.

6. Алгоритм переходит к п. 3 на новый этап эволюции.

Генетические алгоритмы при поиске глобального экстремума используют вероятностный подход. В связи с этим целесообразно говорить не о глобальном экстремуме, а о наилучшем достигнутом решении в принятом диапазоне поиска. Успех работы генетического алгоритма прежде всего обеспечивается идеей коллективного поиска, т.е. поиска с помощью популяции поисковых точек и генетических операторов, заимствованных из природы. Генетические операторы, воздействуя с некоторой вероятностью на хромосомы родителей, обеспечивают, с одной стороны, передачу потомству информации о состоянии популяции, а с другой – поддерживают на протяжении всей эволюции достаточный уровень его изменчивости, что сохраняет поисковую способность алгоритма.

Поисковая способность генетических алгоритмов в значительной степени зависит от размера популяции μ . Очевидно, чем больше размер популяции, тем больше вероятность приближения к искомому глобальному экстремуму. Однако на практике размер популяции μ ограничен возможностями вычислительной техники и лежит в пределах 10 ... 500 [6].

Важной особенностью генетических алгоритмов является то, что ни один из генетических операторов (кроссовер, мутация, инверсия) в процессе генерирования потомков не опирается на знание локального рельефа поверхности целевой функции [6]. Формирование потомков происходит случайным образом, и нет гарантии, что найденные решения будут лучше родительских. Поэтому в процессе эволюции встречаются “неудачные” потомки, которые расширяют число обращений к функции цели, увеличивая, тем самым, время поиска глобального экстремума.

В настоящее время генетические алгоритмы в основном имеют специализированное применение в нейросетевых технологиях для решения многопараметрических задач распознавания образов и прогнозирования. Однако при всей внешней простоте замысла генетические алгоритмы требуют значительных усилий при настройке под

конкретную задачу. В настройке нуждаются прежде всего вероятности применения генетических операторов.

В задачах настройки систем регулирования на детерминированные возмущения в качестве функций цели обычно выбирается интегральный критерий, вычисляемый на интервале времени переходного процесса, требующий значительного объема вычислений. Для таких задач к алгоритму оптимизации предъявляются жесткие требования по числу обращений к функции цели.

С учетом отмеченного предлагается модификация генетического алгоритма для универсального использования в задачах сравнительно небольшой размерности. Модифицированный генетический алгоритм сохраняет в себе генетические качества статистической селекции популяции поисковых точек. Для исключения неудачных потомков при их генерировании в МГА реализована процедура регулярного поиска локальных экстремумов с использованием операций деформируемого многогранника.

Ниже приведено описание работы предлагаемого МГА. В описании алгоритм представлен набором функциональных блоков, содержащих одно или несколько вычислительных или логических выражений.

В блоке 1 алгоритма вводится размерность задачи оптимизации N , число особей в популяции μ , точность решения задачи ε , а также две матрицы начальных предельных максимальных и минимальных значений координат оптимизируемого вектора популяции. В первом пункте блока 2 создается матрица случайных чисел для координат μ начальных векторов оптимизации Xn :

$$xn_{i,j} = rnd(0, xn_{i,j}^{\max} - xn_{i,j}^{\min}) + xn_{i,j}^{\min}; \quad i \in \overline{1, N}; \quad j \in \overline{1, \mu}. \quad (3)$$

Во втором пункте блока 2 для матрицы координат векторов начальной популяции вычисляются значения функции цели:

$$F^i = f(Xn^i); \quad i \in \overline{1, \mu}. \quad (4)$$

Функция цели задается в аналитическом виде или ее значения вычисляются численным методом по программе. В третьем пункте блока 2 производится объединение матрицы Xn и вектора F , и создается матрица состояния популяции X :

$$X = \begin{pmatrix} x_{1,1} & x_{1,2} & \dots & x_{1,\mu-1} & x_{1,\mu} \\ x_{2,1} & x_{2,2} & \dots & x_{2,\mu-1} & x_{2,\mu} \\ \dots & \dots & \dots & \dots & \dots \\ x_{N,1} & x_{N,2} & \dots & x_{N,\mu-1} & x_{N,\mu} \\ x_{N+1,1} & x_{N+1,2} & \dots & x_{N+1,\mu-1} & x_{N+1,\mu} \end{pmatrix}, \quad (5)$$

где элементами последней $N+1$ строки являются значения вектора F .

Матрица X в процессе генетического отбора обновляется от поколения к поколению и является показателем степени приближения решения к наилучшему или глобальному экстремуму.

В блоке 3 производится сортировка столбцов матрицы X по возрастанию элементов $N+1$ строки. После сортировки последние столбцы матрицы X будут содержать перспективные особи, которые при смене поколения популяции должны быть элиминированы, т.е. заменены на новые, более перспективные. В блоке 4 популяция оценивается на вырожденность матрицы состояния X . Если условия блока 4 выполняются, задача считается решенной и алгоритм выходит на окончание расчета, и в блоке 5 выводится первый столбец матрицы X . В противном случае в блоке 5

устанавливается начальное значение счетчика поколений $r=0$, и алгоритм переходит к блоку 7.

В первом пункте блока 7 создается вектор $N+1$ целых случайных неповторяющихся чисел P . Случайные числа выбираются из интервала $1 \dots 0,9 \cdot \mu$ (по числу оставшихся в популяции перспективных особей):

$$P_j = \text{rnd}(0,9 \cdot \mu); \quad j \in \overline{1, N+1}. \quad (6)$$

Во втором пункте блока 7 из матрицы состояния X выбираются столбцы родительской группы $N+1$ особей для r -го регулярного поиска потомка. Принцип формирования матрицы родительской группы An показан ниже:

$$An = \begin{pmatrix} x_{1,P_1} & x_{1,P_2} & \dots & x_{1,P_N} & x_{1,P_{N+1}} \\ x_{2,P_1} & x_{2,P_2} & \dots & x_{2,P_N} & x_{2,P_{N+1}} \\ \dots & \dots & \dots & \dots & \dots \\ x_{N,P_1} & x_{N,P_2} & \dots & x_{N,P_N} & x_{N,P_{N+1}} \end{pmatrix}. \quad (7)$$

В третьем пункте блока 7 вычисляются $N+1$ элементов вектора значений функции цели Fr для столбцов матрицы An , а в четвертом создается матрица состояния родительской группы особей r -го регулярного поиска локального экстремума A . Элементами $N+1$ строки матрицы A является вектор значений функции цели Fr :

$$A = \begin{pmatrix} a_{1,1} & a_{1,2} & \dots & a_{1,N} & a_{1,N+1} \\ a_{2,1} & a_{2,2} & \dots & a_{2,N} & a_{2,N+1} \\ \dots & \dots & \dots & \dots & \dots \\ a_{N,1} & a_{N,2} & \dots & a_{N,N} & a_{N,N+1} \\ a_{N+1,1} & a_{N+1,2} & \dots & a_{N+1,N} & a_{N+1,N+1} \end{pmatrix}. \quad (8)$$

В блоке 8 производится сортировка столбцов матрицы A по возрастанию $N+1$ строки, а в блоке 9 оценивается степень сжатия столбцов матрицы A . Оценка делается по элементам $N+1$ строки. Если условие блока 9 выполняется, то считается, что локальный экстремум найден, и в блоке 10 первый столбец матрицы A записывается в $0,9\mu+r$ -ый столбец матрицы X и устанавливается новое значение счетчика поколений $r=r+1$. Затем, в блоке 11 проверяется число найденных локальных экстремумов r .

Если выполняется условие:

$$r < \text{int}(0,1 \cdot \mu), \quad (9)$$

где $\text{int}(\dots)$ – целое число от аргумента, то алгоритм возвращается к блоку 3; в противном случае – к блоку 7. Если условие (9) не выполняется, то алгоритм переходит ко второй части блок-схемы – к блокам регулярного поиска локального экстремума.

В блоке 12 вычисляются координаты центра тяжести матрицы A , который определяется без $N+1$ -го наихудшего столбца. Там же, во втором пункте выполняется операция “отражения” от наихудшего столбца, и вычисляется значение функции цели для отраженного $N+2$ -го столбца.

Если значение функции цели в отраженной точке $a_{N+1,N+3}$ меньше или равно, чем наилучшее $a_{N+1,1}$, то в блоке 14 выполняется операция “растяжения” матрицы в перспективном направлении. Для нового $a_{N+1,N+4}$ столбца вычисляется функция цели и сравнивается с наилучшим значением $a_{N+1,1}$. Если $a_{N+1,N+4} < a_{N+1,1}$, то столбец матрицы A^{N+4} записывается на место наихудшего столбца A^{N+1} , и алгоритм возвращается к блоку 8 для новой сортировки столбцов матрицы A . В противном случае в столбец A^{N+1} записываются элементы столбца A^{N+3} , и алгоритм также переходит к блоку 8.

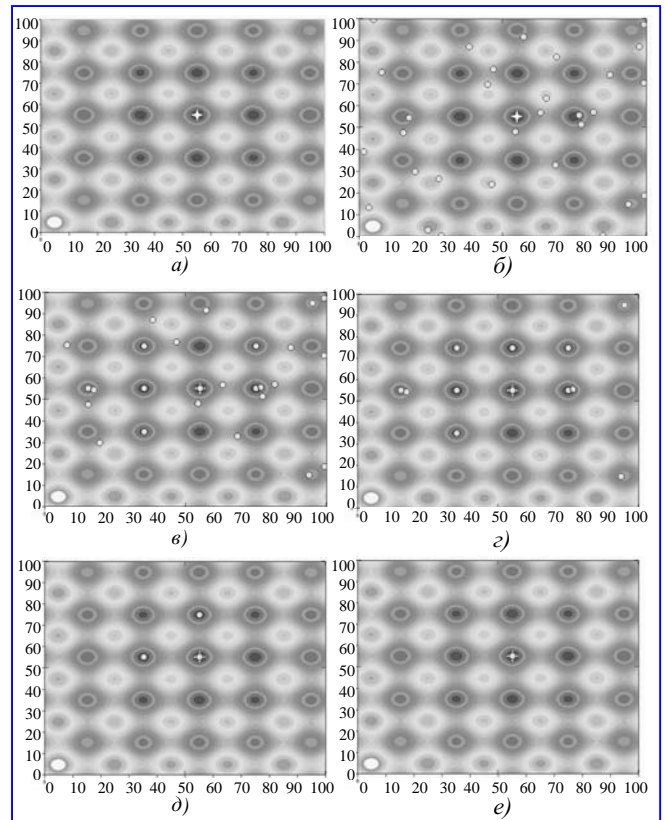


Рис. 1. Поверхности отклика тестовой функции цели

Если в блоке 13 $a_{N+1,N+3} > a_{N+1,1}$, то в блоке 18 элемент $a_{N+1,N+3}$ сравнивается с элементом $a_{N+1,N}$, второго после наихудшего столбца. Если $a_{N+1,N+3} < a_{N+1,N}$, то в столбец A^{N+1} записываются элементы столбца A^{N+3} , и алгоритм возвращается к блоку 8. В противном случае функция цели в $N+3$ столбце сравнивается с наихудшим $N+1$ значением.

Если $a_{N+1,N+3} < a_{N+1,N+1}$, то в столбец A^{N+1} записываются элементы столбца A^{N+3} , и алгоритм переходит к блоку 20. В противном случае алгоритм переходит к блоку 20 без передачи элементов столбца. В блоке 20 выполняется операция “сжатия” матрицы A в пространстве между центром тяжести и наихудшим столбцом и, соответственно, вычисление функции цели в новом $N+5$ столбце. Если $a_{N+1,N+5} < a_{N+1,N+1}$, то в блоке 22 в столбец A^{N+1} записываются элементы столбца A^{N+5} , и алгоритм возвращается к блоку 8. В противном случае в блоке 23 происходит “редукция” матрицы A . Редукция – это уменьшение вдвое расстояния всех столбцов от наилучшего столбца A^1 . Для новых значений элементов первых N строк всех столбцов матрицы A вычисляются и записываются в $N+1$ строку значения функции цели. Затем алгоритм возвращается к блоку 8.

Для тестирования и иллюстрации работы МГА была составлена двумерная многоэкстремальная целевая функция вида:

$$y(x_1, x_2) = (\sin(\pi \cdot x_1) + \sin(\pi \cdot x_2)) \cdot 0,2 + 0,01 \cdot [0,4 \cdot (x_1 - 5,5)^2 + 0,5 \cdot (x_2 - 5,5)^2] + 0,4, \quad (10)$$

имеющая глобальный экстремум в точке $(5,5; 5,5)$. На рис. 1 показаны 6 состояний поверхности отклика тестовой функции (10).

На рис. 1а звездочкой отмечена точка глобального экстремума. Состояния задачи оптимизации для различных поколений эволюции популяции представлены

на рис 1 б, в, г, д, е. На рис. 1б показан начальный разброс точек в первом поколении. В каждом поколении удалялись по 3 наихудших особи. На замену им находились точки в локальных экстремумах. Расположение точек популяции в 5-м, 10-м и в 15-м поколениях представлены соответственно на рис. 1 в, г, д. Состояние решенной задачи, когда все точки стянулись в одну точку глобального экстремума, представлено на рис 1 е. Для получения окончательного решения потребовалось 17 поколений.

Как было отмечено выше, задача определения глобального экстремума является вероятностной. Причем вероятность успешного поиска в первую очередь зависит от размера популяции μ . Результаты исследования влияния размера популяции на вероятность гарантированного определения глобального экстремума представлены на рис. 2. Для каждого заданного размера популяции μ проводилось по 1000 экспериментов, в которых определялось число неудачных решений.

Из графика, представленного на рис. 2, видно, что при достаточном количестве особей в популяции модифицированный генетический алгоритм с высокой вероятностью находит глобальный экстремум. Так, при количестве особей в популяции $\mu=40$ вероятность определения глобального экстремума составила величину, близкую к 100 %.

В качестве примера, иллюстрирующего вычислительные возможности МГА, рассмотрен оптимальный синтез двухсвязной системы регулирования с многоканальным

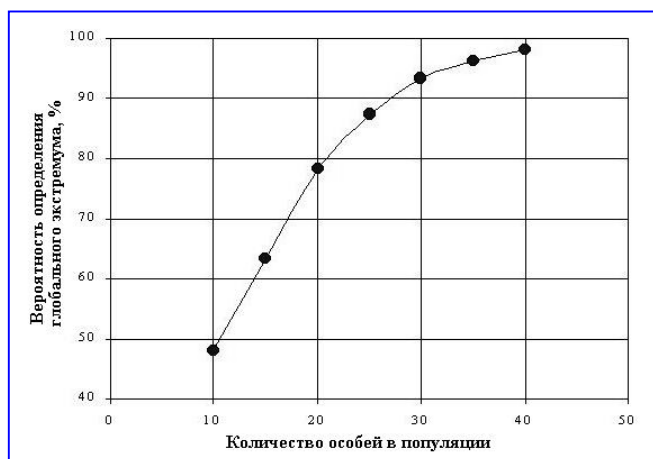


Рис. 2. Результаты исследования влияния размера популяции на вероятность гарантированного определения глобального экстремума

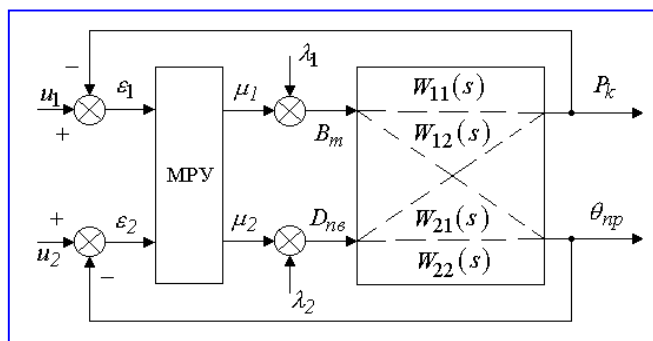


Рис. 3. Структурная схема двухсвязной АСР

регулирующим устройством (МРУ) (рис. 3). Объектом регулирования является проточный котел с взаимосвязанными регулируемым параметрами: давлением пара за котлом P_k с регулирующим воздействием на расход топлива B_m и температурой в промежуточной точке пароводяного тракта θ_{np} с регулирующим воздействием на расход питательной воды D_{ne} . Передаточные функции по каналам регулирования и каналам взаимных связей в соответствии с динамическими характеристиками, полученными на реальном котле [8], имеют вид:

$$W_{11}(s) = \frac{1}{(18 \cdot s + 1)^3}; \quad W_{22}(s) = -\frac{0,5}{(50 \cdot s + 1)^3};$$

$$W_{12}(s) = \frac{0,5 \cdot (23,7 \cdot s + 1)}{(18 \cdot s + 1)^3 \cdot (37 \cdot s + 1)};$$

$$W_{21}(s) = \frac{0,5 \cdot (105 \cdot s + 1)}{(28 \cdot s + 1)^3 \cdot (27 \cdot s + 1)}. \quad (11)$$

Исследование проводилось методом имитационного моделирования во временной области для регулируемых устройств, реализованных с помощью:

- двух не связанных между собой ПИ регуляторов (4 настроечных параметра);
- нейросетевого двухканального регулятора [9] с взаимными связями между каналами (12 настроечных параметров).

Структура нейросети для реализации нейросетевого регулятора представлена на рис. 4.

Параметрическая оптимизация анализируемой двухсвязной АСР для рассматриваемых вариантов реализации регулирующего устройства проводилась с помощью МГА. Переходные процессы для P_k и θ_{np} при найденных настроечных параметрах ПИ регуляторов (первый способ) и оптимальных параметрах нейросети (второй способ) представлены на рис 5 а, б (соответственно, графики 1, 2). Для сравнения там же показаны переходные процессы этих параметров в АСР с ПИ регуляторами, настройки которых найдены аналитическим методом по эквивалентным объектам, учитывающим взаимные связи (графики 3). На рис. 5 в, г переходные процессы в анализируемой АСР с оптимально настроенным двухканальным нейросетевым регулятором (графики 2) сравниваются с процессами, полученными в работе [10] для регулирующего устройства с двумя ПИ регуляторами и динамическим компенсатором




Рис. 4. Структура нейросети двухканального регулятора

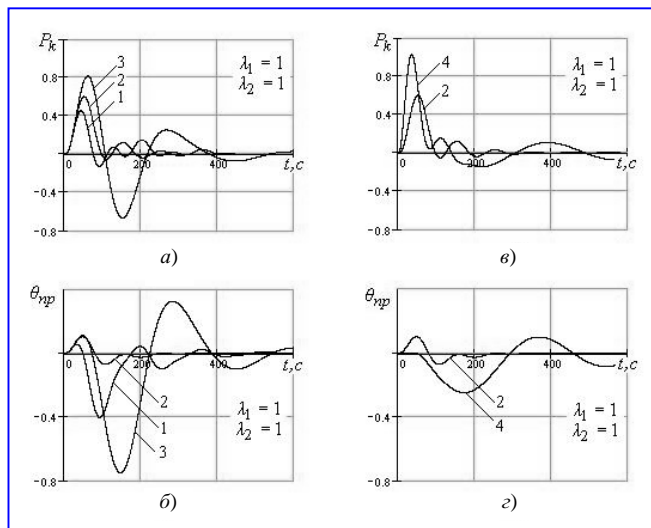


Рис. 5. Переходные процессы

“топливо V_m - вода D_{nv} ” в виде РД-звена, параметры которых определялись с помощью алгоритма автоматизированной настройки (графики 4).

Проведенные исследования показали, что предлагаемый МГА одинаково успешно позволяет оптимизировать настроечные параметры регулирующих устройств как в АСР с традиционными линейными алгоритмами, так и в АСР с нейросетевыми регуляторами. При этом структура регулирующих устройств может быть и более сложной, чем в приведенном примере.

Наряду с применением МГА в задачах анализа и синтеза сложных автоматических систем регулирования открываются широкие возможности его использования для оптимизации диагностических процедур, реализуемых в АСУТП. В работах [11,12] рассмотрен метод диагностирования информационной подсистемы АСУТП ТЭЦ, в основу которого заложена искусственная нейросеть, обученная на выборке параметрических отказов средств измерения и результатов корректирующих поправок по избыточной информации балансовых соотношений тепломеханического оборудования.

По статистическим характеристикам, полученным в последовательных циклах работы алгоритма коррекции, нейросеть формирует вектор признаков состояния каждого информационно-измерительного канала, совокупность которых позволяет проводить процедуры диагностирования. Модифицированный генетический алгоритм позволяет успешно проводить поиск оптимального вектора корректирующих поправок и параметрическую настройку нейросети.

В заключение следует отметить, что для практического использования предложенного алгоритма разработана программа для ЭВМ *Optim-MGA* как инструментальное средство многопараметрической и многоэкстремальной оптимизации [13]. Программа позволяет находить наилучшее значение функций, представленных в виде динамически присоединяемой библиотеки (dll-файла).

Владимир Романович Сабанин – канд. техн. наук, доцент,
Николай Иванович Смирнов – канд. техн. наук, доцент,
Андрей Иванович Репин – аспирант Московского энергетического института (технического университета).

Телефоны: (095) 362-72-05, 362-77-20.

E-mail: SabaninVR@mprei.ru

E-mail: SmirnovNI@mprei.ru

E-mail: RepinAI@mprei.ru

Список литературы

1. Сабанин В.Р., Смирнов Н.И., Репин А.И. Оптимальный синтез АСР методом имитационного моделирования с использованием генетических алгоритмов оптимизации // Труды всероссийской научной конференции ИММОД 2003. Санкт-Петербург: ФГУП ЦНИИ технологии судостроения. 2003.
2. Nelder J.A., Mead R., A Simplex Method For Function Minimization // Computer J., 1964, No 7.
3. Сабанин В.Р., Смирнов Н.И. Расчеты автоматических систем регулирования в теплоэнергетике / МЭИ, 2002.
4. Сабанин В.Р., Смирнов Н.И., Репин А.И. Оптимизация настроечных параметров регулирующих устройств в АСР // Сборник трудов конференции Control 2003. МЭИ, 2003.
5. Goldberg D.E. Genetic Algorithms in Search Optimizations and Machine Learning / Addison.Wesly, 1989.
6. Вороновский Г.К., Махотило К.В., Петрашев С.Н., Сергеев С.А. Генетические алгоритмы, искусственные нейронные сети и проблемы виртуальной реальности. Харьков: Основа, 1997.
7. Махотило К.В. Разработка методик эволюционного синтеза нейросетевых компонентов систем управления / Диссертация на соискание ученой степени кандидата технических наук. Харьков: ХГПУ, 1998.
8. Биленко В.А., Давыдов Н.И. и др. Анализ динамики многосвязной системы регулирования мощности и температуры энергоблока с прямоточным котлом // Теплоэнергетика. 1987. №10.
9. Сабанин В.Р., Смирнов Н.И., Репин А.И. Автоматические системы регулирования на основе нейросетевых технологий // Сборник трудов конференции Control 2003. МЭИ, 2003.
10. Ротач В.Я., Кузицин В.Ф., Башарин Д.Ю. Анализ применимости алгоритма автоматизированной настройки для двухсвязной АСР подачи топлива и питательной воды прямоточного котла // Сб. Научных трудов “Теория и практика построения и функционирования АСУТП”. МЭИ. 1993.
11. Сабанин В.Р., Смирнов Н.И., Репин А.И., Аракелян Э.К., Макаров О.Н., Андреев С.Н. Математическое и программное обеспечение алгоритма коррекции измеряемых параметров для расчета технико-экономических показателей на ТЭЦ // Вестник МЭИ. 2003. №1.
12. Репин А.И., Сабанин В.Р., Смирнов Н.И. Диагностика информационной подсистемы АСУТП с использованием технологий искусственного интеллекта // Тез. докл. Десятой Международной научно-технической конференции студентов и аспирантов. Т 3. МЭИ. 2004.
13. Сабанин В.Р., Смирнов Н.И., Репин А.И. Универсальная программа для оптимизации многоэкстремальных задач “Optim-MGA” // Свидетельство об официальной регистрации программы для ЭВМ № 2004610862. Российское агентство по патентам и товарным знакам (Роспатент). Москва, 8 апреля 2004.