Полученные в процессе оптимизации векторы варьируемых параметров могут рассматриваться как возможно оптимальные. Они включаются в план эксперимента, отрабатываются на стенде для уточнения целевой функции и в случае повышения показателей эффективности включаются в банк альтернативных оптимальных технических решений для дальнейшего анализа и выбора окончательного варианта проекта.

Заключение

Разработка методологических и алгоритмических аспектов системы нейросетевого моделирования физических процессов давно назрела, так как, несмотря на очевидную эффективность использования, внедрение ее на предприятиях в проектно-конструкторские работы незначительно. Эволюционные методы моделирования с момента их появления рассматриваются как некая альтернатива традиционным фундаментальным подходам научных исследований, и использование их при проектировании можно назвать в большой степени новым и нетрадиционным научным подходом. Органичное сочетание его с современной технологией оптимизации позволит получить принципиально новые важные практические результаты.

НЕЙРОСЕТЕВОЙ ПОРТРЕТ ФУНКЦИОНИРОВАНИЯ НАСОСНОГО АГРЕГАТА

Стогней В.Г., Кретинин А.В., Гуртовой А.А.
Воронежский государственный технический университет, Воронеж

Сложность рабочих процессов, протекающих в ЖРД, невозможность при современном состоянии науки надежного теоретического определения с необходимой точностью характеристик рабочих процессов, функционирования узлов и агрегатов двигателя делают неизбежными экспериментальные работы на модельных и натурных объектах. Объем этих работ определяет основные затраты на разработку ЖРД, достигающие сотен миллионов долларов [1].

В настоящее время все процессы в двигателе, для которых имеются физические и математические модели, просчитываются на ЭВМ. Вычислительная техника используется как на стадии проектирования, так и управления испытаниями (управляемый эксперимент), при обработке и анализе результатов испытаний. Имитационные модели функционирования агрегатов позволяют анализировать их поведение в условиях реальной работы в составе ДУ, моделировать и выявлять различные отклонения от нормальной работы.

Создание системы автоматизированного анализа стендовых испытаний ЖРД является актуальной задачей процессов проектирования и доводки узлов и агрегатов двигателей для повышения достоверности оценки работоспособности изделий, оперативной диагностики функционирования и выработки проектных решений для ликвидации дефектов. Мощные аппроксимационные возможности нейросетевой вычислительной архитектуры позволяют создавать многопараметрические имитационные математические модели сложных технических систем, предназначенные для идентификации параметров функционирования и критериев работоспособности, и на их основе строить оптимизационную стратегию проектирования и доводки ЖРД, модернизации систем диагностики и аварийной защиты.

Разрабатываемая методика создания нейросетевых моделей рабочих процессов в ЖРД иллюстрируется на примере бустерного насосного агрегата ЖРД (БНА), конструктивно состоящего из оседиагонального насоса и гидротурбины. Входными параметрами, изменение которых влияет на функционирование БНА и значения которых измеряются на стенде, можно считать давление компонента топлива на входе в насос p_0 и давления компонента на входе в сопловой аппарат гидротурбины p_{c1} и p_{c2} (для рассматриваемой конструктивной схемы привод турбины осуществляется по различным гидравлическим линиям в зависимости от режима функционирования агрегата). Выходными параметрами, характеризующими работоспособность агрегата, являются давление компонента на выходе p_2 и число оборотов вала БНА n, причем n часто используется в качестве контрольного параметра системы аварийной защиты ЖРД.

При работе с более или менее реалистичными моделями механических, гидравлических, тепловых и др. систем ЖРД, которые основаны на всеобщих физических законах, необходимо использовать всевозможного вида математические абстракции и прибегать к аппроксимации для получения подходящей модели. Кроме того, получающиеся системы уравнений обычно не могут быть решены без дальнейших упрощений. Естественно, все эти упрощения вводятся на основе эксперимента и так, чтобы результаты не выходили за рамки эксперимента. Альтернативный подход заключается в использовании при моделировании результатов экспериментов, которые уже проведены или проводятся в процессе текущей отработки изделий, и построить достоверную имитационную модель только на основе экспериментальных данных, которая для любого входного вектора данных из допустимой и известной области определения рассчитывает нужный критерий, что и требуется от математической модели функционирования.

Создание нейросетевой имитационной математической модели, воспроизводящей функциональную зависимость критериев работоспособности от входных параметров в эксплуатационных пределах их изменения, позволяет повысить качество анализа экспериментальных данных и своевременно диагностировать дефекты и проблемы функционирования. Одним из основных требований к создаваемым многопараметрическим портретам функционирования агрегатов ЖРД является высокая точность модельных результатов для снижения допусков на определение параметров работоспособности при диагностировании и контроле технического состояния.

Для моделирования зависимости частоты вращения ротора БНА на стационарных и переходных режимах работы используется ИНС типа ОСП, скрытый слой которой содержит 16 нейронов. Входные параметры нейросетевой модели

$n = f_{NET}(p_0, p_{c1}, p_{c2}, n_{-1}, n_{-2})$ дополнены значениями n_{-1} и n_{-2}, т.е. числом оборотов ротора в моменты времени $t_i - \Delta t$ и $t_i - 2\Delta t$, для моделирования нестационарных режимов работы. Обучающая выборка формируется из результатов огневых испытаний двигателей одного типа с идентичной конструкцией БНА. Размерность массивов результатов по каждому из параметров составляет для одного испытания 4500 значений, измеренных на стенде с интервалом времени $\Delta t = 0{,}01\,c$ вплоть до t=10 c согласно циклограмме работы ЖРД. Таким образом, разрабатываемая модель может использоваться для анализа функционирования БНА на запуске вплоть до выхода на основной режим тяги (ОРТ).

СПИСОК ЛИТЕРАТУРЫ

1. Основы расчета и теории жидкостных ракетных двигателей/ А.П.Васильев, В.М.Кудрявцев, В.А.Кузнецов и др.; Под ред. В.М.Кудрявцева. – М.: Высш. Шк., 1993.

СИНТЕЗ АППРОКСИМИРУЮЩИХ НЕЙРОСЕТЕЙ ПРИ РАЗРАБОТКЕ ЭКСПЕРИМЕНТАЛЬНЫХ ФАКТОРНЫХ МОДЕЛЕЙ

Стогней В.Г., Кретинин А.В.
Воронежский государственный технический университет, Воронеж

Поиск оптимальной структуры искусственных нейронных сетей (ИНС) является до сих пор нерешенной проблемой. Как правило, структура ИНС определяется исходя из опыта и интуиции исследователя. Проблема выбора осложняется тем обстоятельством, что при решении задачи аппроксимации заданной статистической выборки может быть найдено несколько вариантов ИНС одинаковой структуры, обеспечивающих необходимую точность аппроксимации в узлах, но описывающих различные функциональные континуумы. Приведенные в докладе результаты посвящены проблеме повышения адекватности нейросетевых поверхностей отклика на базе персептрона с одним скрытым слоем (ОСП) и рассматриваются в контексте создания методики оптимизации структуры ИНС для решения задач аппроксимации и моделирования.

Для получения корректного решения задачи синтеза ИНС фиксированной структуры в отсутствие идеального и бесконечно большого обучающего множества необходима регуляризация процедуры обучения, направленная на предотвращение переобученности сети [1]. При достаточном объеме экспериментальных данных проблема может быть с успехом решена методом контрольной кросс-проверки, когда часть данных не используется в процедуре обучения ИНС, а служит для независимого контроля результата обучения [2].

Включение в алгоритм обучения дополнительной информации о нейросетевой функции (ограниченность, гладкость, монотонность) приводит к модификации целевой функции и необходимости минимизации двух и более критериев при обучении. В работе [3] был предложен байесовский подход для решения задач интерполяции зашумленных данных. Метод байесовской регуляризации основан на использовании субъективных предположений относительно исследуемой функции и может применяться как на этапе структурной оптимизации ИНС, так и на этапе обучения. В работе [4] регуляризация осуществляется путем представления целевой функции в виде свертки

$$F = \beta \cdot E_D + \alpha \cdot E_W, \qquad (1)$$

где E_D – суммарная квадратическая ошибка, E_W – сумма квадратов весов сети.

Здесь основной акцент делается на проблеме определения корректных значений параметров целевой функции α и β. В то же время существует возможность модификации регуляризационного критерия в формуле (1), основанной на аналитическом определении кривизны аппроксимационной поверхности отклика. В соответствии с полученными результатами изложим разработанную методику оптимизации структуры ИНС с использованием энергетического фактора.

1. Находится приближенное значение энергетического фактора для заданного набора экспериментальных данных

$$K_* = \sum_i \left(\nabla^2 y(\mathbf{x}_i)\right)^2.$$

Вторые производные в этой формуле определяются либо по дискретным аппроксимационным зависимостям, либо с использованием кусочно-многочленной интерполяции.

2. Определяется начальное приближение числа нейронов в скрытом слое:

$$L = \frac{mN}{(1+\log_2 N)(n+m)},$$

где n – размерность входного сигнала; m – размерность выходного сигнала; N – число элементов обучающей выборки.

3. В гиперпространстве синаптических весов $L_w \in \mathbf{R}^{\frac{mN}{1+\log_2 N}}$ генерируются равномерные последовательности точек размерности M_0 при помощи LP_τ алгоритма [5], которые будут являться поочередно начальными приближениями для процессов обучения разных вариантов ОСП фиксированной структуры.

4. Решается M_0 задач обучения ОСП. Из них выбираются $M_* \le M_0$ различных вариантов ОСП одинаковой структуры, которые обеспечивают заданную точность. Для M_* различных ОСП рассчитываются значения энергетического фактора

$$K = \sum_i \left(\nabla^2 f_{NET}(\mathbf{w}, \mathbf{x}_i)\right)^2 \qquad (2)$$

5. Если $M_* \ne 0$, то количество нейронов в скрытом слое уменьшается на 1 *L=L-1*. Если $M_* = 0$, то *L=L+1*. Осуществляется переход на п. 3. Если пункт 5