

Моделирование гидродинамической задачи при помощи комбинированной нейросетевой и динамической модели

И.Ф. Ясинский, Ф.Н. Ясинский
ФГБОУВПО «Ивановский государственный энергетический университет имени В.И.Ленина»,
г. Иваново, Российская Федерация
E-mail: igor2266@yandex.ru

Авторское резюме

Состояние вопроса: Исследование физического процесса состоит в построении математической модели, представляющей собой систему дифференциальных уравнений. Для их решения разработаны аналитические и численные методы. Однако получающиеся системы на практике могут оказаться громоздкими, что требует значительных вычислительных и временных затрат. В связи с этим перспективным направлением является разработка комбинированных нейросетевых и динамических моделей объектов, позволяющих сократить вычислительные и временные затраты.

Материалы и методы: Используются численные методы прикладной математики, компьютерное моделирование физических процессов, теория нейронных сетей.

Результаты: Предложен способ построения нейросетевой и динамической модели физического процесса на примере гидродинамической задачи. Представлены результаты численных экспериментов с программными моделями. Установлено существенное увеличение скорости вычислений комбинированной системы по сравнению с динамическими расчетами от 30 до 90 раз.

Выводы: Дополнение динамической модели нейронной сетью по мере обучения позволит более полно и быстро исследовать физические процессы, определять неизвестные скрытые параметры и начальные условия. Такие возможности позволят применять предложенный метод во многих прикладных областях, в частности при математическом моделировании энергетических процессов.

Ключевые слова: гидродинамика, комбинированные модели, нейронные сети, математическое моделирование.

Modeling of Hydrodynamic Problem Using Combined Connectionist and Dynamical Models

I.F. Yasinskiy, F.N. Yasinskiy
Ivanovo State Power Engineering University, Ivanovo, Russian Federation
E-mail: igor2266@yandex.ru

Abstract

Background: Research of physical process consists of the mathematical model designing which represent the system of the differential equations. Analytical and numerical methods are developed for their solution. However, on practice these systems can turn out bulky that demands considerable computing and time expenditure. Thus, the perspective field is to develop the combined connectionist and dynamic objects models with the aim to reduce computing and time expenditure.

Materials and methods: The authors use numerical methods of applied mathematics, computer modeling of physical processes, the theory of neural networks.

Results: The designing way of connectionist and dynamic model of physical process based on the example of a hydrodynamic task is offered. Numerical experiments with program models showed essential increase in speed of calculations (from 30 to 90 times) of the combined system in comparison with dynamic calculations.

Conclusion: Addition to dynamic model with a neural network will allow studying physical processes more completely and faster, to determine the unknown hidden parameters and initial conditions. These capabilities will allow applying the proposed method in many application areas, such as the mathematical modeling of energy processes.

Key words: hydrodynamics, combined models, neural networks, mathematical modeling.

Исследование физического процесса на начальном этапе обычно заключается в формировании математической модели этого процесса, которая представляет собой систему дифференциальных уравнений. Для их решения разработаны эффективные аналитические и численные методы. Однако получающиеся системы на практике зачастую оказываются громоздкими и их решение может требовать значительных вычислительных и временных

затрат. К тому же применение численных методов ограничивается в ряде случаев тем, что часть переменных может быть ненаблюдаема, включая их начальные значения.

Одним из перспективных способов решения этой проблемы является совместное использование нейронной сети и «классического» дифференциального представления в модели объекта (рис. 1).

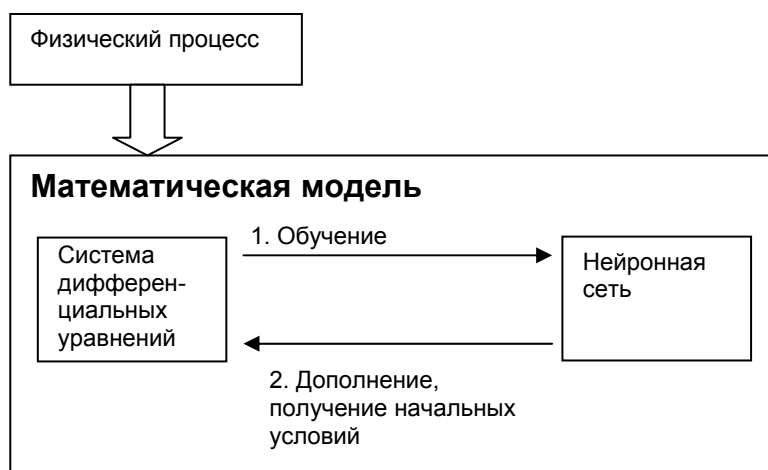


Рис. 1. Комбинированная математическая модель

Указанная методика позволяет соединить динамическое прогнозирование с нейросетевым. Прогнозирование процессов с помощью нейронных сетей основывается на результатах длительного наблюдения за поведением открытых переменных. При этом значения скрытых переменных не требуются.

На первой стадии нейронная сеть «наблюдает» за расчетами динамической модели и по ним учится прогнозировать параметры процесса. При достижении требуемого качества работы обученная нейронная сеть может выступать в качестве математической программной модели объекта и использоваться для исследования его свойств и установления скрытых параметров или неизвестных начальных условий процесса.

Предложенные идеи были опробованы при моделировании гидродинамической задачи с использованием нейронной сети. Неуставившееся движение воды в открытых руслах описывается следующими дифференциальными уравнениями:

$$\frac{\partial \omega}{\partial t} + \frac{\partial Q}{\partial x} = q, \quad (1)$$

$$\frac{\partial Q}{\partial t} + \frac{\partial}{\partial x} \left(P - \frac{Q^2}{\omega} \right) = g\omega \left(i - \frac{Q|Q|}{K^2} \right) + R_x, \quad (2)$$

$$\omega = \int_0^h b(x, \xi) d\xi, \quad (3)$$

$$P = g \int_0^h (h - \xi) b(x, \xi) d\xi, \quad (4)$$

$$R_x = g \int_0^h (h - \xi) \frac{\partial b}{\partial x} d\xi, \quad (5)$$

$$K = \omega \cdot C \cdot \sqrt{R}, \quad (6)$$

где $Q(x,t)$ – объемный расход; $\omega(x,h)$ – площадь поперечного сечения потока, $h = z(x,t) - z_0(x)$ – глубина потока, $z(x,t)$ – ордината свободной поверхности потока, $z_0(x)$ – ордината дна русла; $b(x,\xi)$ – ширина поперечного сечения потока;

$i = z'_0(x)$ – уклон дна; $K(x,h)$ – модуль расхода; $q(x)$ – путевой приток в основной поток с берегов; g – ускорение свободного падения; C – коэффициент Шези; R – гидравлический радиус.

В разработанной компьютерной программе динамическая модель на основе представленных дифференциальных уравнений вычисляет значения объемного расхода $Q(x,t)$ в узлах сетки на заданном отрезке времени. При этом программная модель искусственной нейронной сети «наблюдает» за процессом и использует полученные в динамической модели значения $Q(x,t)$ для настройки весовых коэффициентов связей и выполнения собственного прогноза расхода (рис. 2). На входе нейронной сети также учитывается параметр глубины потока $z(x,t)$.

При обучении был использован метод сжатия информации нейросетевой воронкой.

Структура сети со сжимающим слоем представлена на рис. 2.




Рис. 2. Структура нейронной сети со слоем «воронка»

Видно, что входной и выходной слои нейронной сети имеют одинаковое количество элементов. Скрытый средний слой – горловина нейросетевой воронки – имеет меньшее количество элементов. Воронка выполняет функцию отбора наиболее характерных важных свойств, прису-

щих распознаваемым образом. Такой отбор чрезвычайно важен при решении таких задач, когда на входной слой нейронной сети поступают большие массивы информации. Процесс обучения такой сети состоит из двух этапов.

На первом этапе происходит обучение слоя «воронка». Нейронная сеть учится воспроизводить с заданной точностью образ входного слоя i на выходном слое k . Другими словами, сеть учится восстанавливать информацию после сжатия. Для этого настраиваются веса W_{ij} (сжатие) и W_{jk} (восстановление).

На втором этапе отбрасываем слой k , который служил для обучения "воронки" и настраиваем веса W_{jk1} на классификацию представленных образов. При этом веса W_{ij} , обученные на сжатие информации, остаются неизменными.

Численные эксперименты показали, что такая нейросетевая модель гидродинамического процесса может быть быстро обучена до высокой точности прогнозирования. В частности, начиная с тридцатого шага обучения, разница в прогнозе расхода $Q(x,t)$ при помощи нейронной сети и динамической модели во всех узлах пространственной сетки составляла менее 3 %. Эксперименты с компьютерной программой (рис. 3) также показали существенное увеличение скорости вычислений при прямом ходе обученной нейронной сети, по сравнению с динамическими расчетами. При различных условиях преимущество в скорости составляло от 30 до 90 раз.

Наша позиция отличается от указанной выше. На основании вычислительного опыта считаем, что выход следует искать на путях построения сетевых гибридов, включающих динамические и нейросетевые элементы.

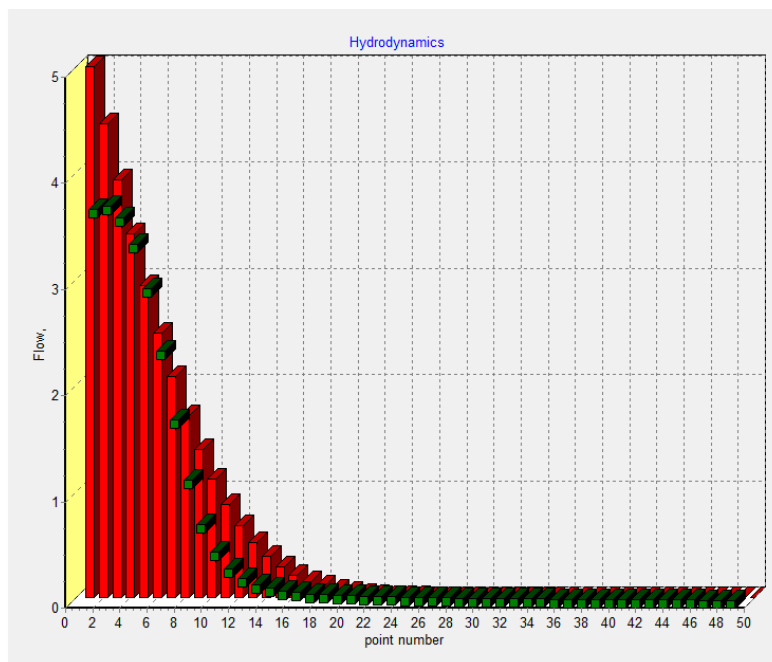


Рис. 3. Визуализация обучения нейросетевой модели, наблюдающей за дифференциальным решением

Заключение

Таким образом, перспективным направлением является разработка комбинированных нейросетевых и динамических моделей объектов. Дополнение динамической модели нейронной сетью по мере обучения позволит более полно и быстро исследовать физические процессы, определять неизвестные скрытые параметры и начальные условия. Такие возможности позволят применить предложенный метод во многих прикладных областях, в частности при математическом моделировании энергетических процессов.

Список литературы

1. Ланкин Ю.П., Сакаш И.Ю. Прогнозирование концентрации озона в стратосферно-тропосферном слое с помощью нейронных сетей // Тр. VIII Всерос. конф. «Нейрокомпьютеры и их применение» НКП–2002 с международным участием, Москва, 21–22 марта 2002 г. – М., 2002. – С. 218–225.

References

1. Lankin, Yu.P., Sakash, I.Yu. Prognozirovanie kontsentratsii ozona v stratosferno-troposfernom sloe s pomoshch'yu neyronnykh setey [Prediction of Ozone Concentration in Stratosphere and Troposphere using Neural Networks]. *Trudy VIII Vserossiyskoy konferentsii «Neurokomp'yutery i ikh primeneniye» NKП–2002 s mezhdunarodnym uchastiem* [Proceedings of the 8th All-Russian Conference «Neurocomputers and Their Application» NKП–2002 with International Participation]. Moscow, 2002, pp. 218–225.

Ясинский Игорь Федорович,
ФГБОУВПО «Ивановский государственный энергетический университет имени В.И. Ленина»,
кандидат технических наук, доцент кафедры высокопроизводительных вычислительных систем,
e-mail: igor2266@yandex.ru

Ясинский Федор Николаевич,
ФГБОУВПО «Ивановский государственный энергетический университет имени В.И. Ленина»,
доктор физико-математических наук, профессор кафедры высокопроизводительных вычислительных систем,
телефон (4932) 26-98-29.