

Нейросетевые алгоритмы в задаче счисления пути судна

В. В. ДЕРЯБИН, старший преподаватель филиала ГМА им. адм. С. О. Макарова (филиал в г. Архангельске), победитель конкурса «Молодые ученые транспортной отрасли — 2011»



Система из двух нейронных сетей позволяет прогнозировать относительную скорость судна в условиях воздействия ветра и волнения. Учебный набор образцов формируется при помощи имитационной модели. Работа сети сравнивается с результатами, полученными при использовании имитационной модели. Нейронная сеть заменяет традиционный алгоритм расчета счислимых координат судна с высокой точностью.

Для описания движения судна в условиях внешних возмущений (ветра, волнения и течения) широко используется аппарат дифференциальных уравнений [1]. Интегрирование последних производится численными методами, обеспечивающими требуемую точность решения. Альтернативой системам дифференциальных уравнений являются нейронные сети. К их преимуществам следует отнести нелинейность преобразования входного сигнала в выходной, помехоустойчивость, быстроту вычислительных процессов.

Мы предлагаем использовать систему из двух нейронных сетей, прогнозирующую относительную скорость судна в неподвижной (локальной) системе координат. Первая нейронная сеть (сеть № 1) прогнозирует скорость дрейфа судна V_{0x1} , а набор учебных данных формируется в соответствии с дифференциальным уравнением [2; 3], интегрированием которого вычисляется скорость дрейфа судна при воздействии ветра и волнения. Во второй нейронной сети (сеть № 2) входным сигналом служат величины, характеризую-

щие кинематику судна, а выходным — компоненты вектора относительной скорости судна в неподвижной системе координат (рис. 1).

Из теории нейронных сетей [4] известно, что решение дифференциального уравнения, описанного в [2; 3], может быть представлено при помощи динамической нейронной сети, имеющей обратные связи, а точнее — нейронной сети, представляющей модель нелинейной авторегрессии с внешними входами (NARX). Определим сначала набор внешних входных сигналов X , необходимых для обучения сети № 1.

$$X = \begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \end{pmatrix} = \begin{pmatrix} \rho \cdot |V_{0x1}| \\ \rho_A \cdot V_r^2 \cdot \sin \alpha_r \\ F_W \\ \frac{dK}{dt} \cdot V_{0x1} \end{pmatrix}$$

где ρ — плотность морской воды; ρ_A — плотность атмосферного воздуха; V_{0x1} — продольная составляющая относительной скорости судна; V_r — модуль относительного ветра; α_r — курсовой угол относительного ветра; F_W — поперечная сила со стороны взволнованной поверхности моря; dK/dt — угловая скорость поворота судна; выходной сигнал — скорость дрейфа $Y = V_{0y1}$.

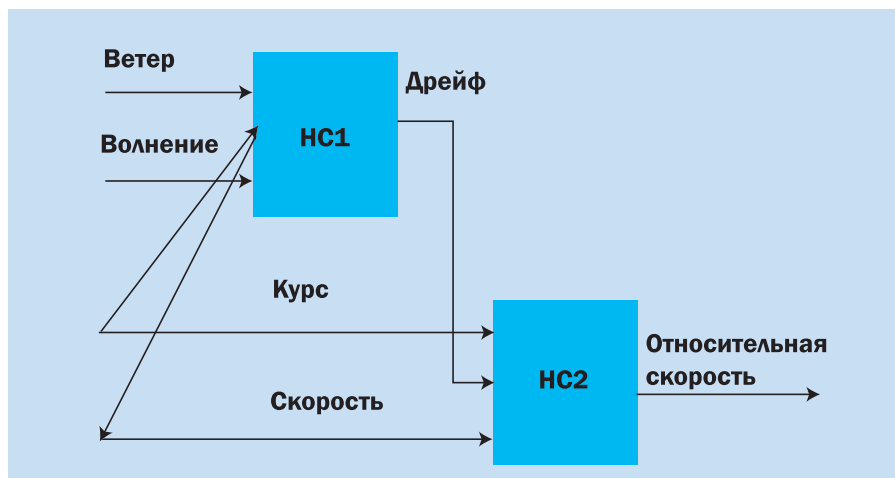


Рис. 1. Общая схема системы




Рис. 2. Общий вид нейронной сети № 1




Рис. 3. Общий вид нейронной сети № 2

Поскольку сеть № 1 является рекуррентной, определимся с числом в линиях единичных задержек. В нашем случае мы имеем дело с двумя линиями единичных задержек: по внешним входным величинам и по выходному сигналу, подаваемому по линии обратной связи на вход сети. Дискретность модели — 1 с. Число задержек для обеих линий — по 15. Это означает, что сеть накапливает информацию о динамике системы за предыдущие 14 с, а выдает прогноз на 15-ю секунду. То есть нейронная сеть прогнозирует скорость дрейфа судна на шаг вперед.

Теперь необходимо выбрать число слоев и тип нейронов в них. Будем использовать двухслойную нейронную сеть. Первый слой содержит 15 нейронов с сигмоидальной функцией активации, второй состоит из одного нейрона, имеющего тождественную функцию активации. В системе MATLAB 7.10.0 необходимо создать объект класса «нейронная сеть» (рис. 2).

Сеть № 2 преобразует кинематические характеристики в компоненты относительной скорости (V_{0x} , V_{0y}) поэтому целесообразно использовать сеть прямого распространения (FFBP). Она имеет два слоя: первый содержит 20 нейронов, обладающих сигмоидальными функциями активации; второй состоит из двух нейронов с тождественными функциями активации. Вектор входного сигнала имеет вид

$$X = \begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \end{pmatrix} = \begin{pmatrix} \cos(K) \\ \sin(K) \\ V_{ox1} \\ V_{oy1} \end{pmatrix},$$

где K — курс судна,

а вектор выходного сигнала $Y = \begin{pmatrix} V_{ox} \\ V_{oy} \end{pmatrix}$.

Схема нейронной сети представлена на рис. 3.

Теперь необходимо сформировать учебный набор образцов (X, Y) для последующего обучения сети. Понятие «учебный набор» обозначает качество и количество именно входных образцов. Выходные же определяются однозначно при помощи имитационной модели. Качество образцов подразумевает пространство возможных значений входного вектора, определяемое границами возможных значений его компонент, и распределение вектора по пространству, зависящему от дискретности компонент и закона распределения, по которому происходит выборка составляющих вектора.

Определим сначала границы входного вектора X сети № 1. Для этого необходимо определить границы промежутков возможных значений величин, формирующих входной вектор. Кроме того, необходим выбор дискретности этих возможных значений, поскольку слишком близкие значения, как показывает наша практика, могут осложнять процесс обучения нейронной сети. Второй, третий и четвертый компоненты входного сигнала представляют собой функции исходных величин, следовательно, так как для их получения используется стохастический алгоритм, существует вероятность, что после обучения в рабочем режиме входные величины x_1, x_2, x_3 не будут принадлежать тем промежуткам, на которых сеть обучалась. Это приведет к существенной потере точности. Во избежание подобной ситуации расширим промежутки возможных значений некоторых величин, ответственных за формирование сигналов x_1, x_2, x_3 (см. табл.).

Теперь имеется четыре конечных множества возможных значений компонент входного сигнала X , хранящихся в оперативной памяти в виде векторов некоторой длины. В системе MATLAB существует функция, позволяющая псевдослучайным образом генерировать натуральные числа от 1 до некоторого максимального заданного значения по закону равномерного распределения. Если в качестве этого значения выбрать число элементов вектора возможных значений соответ-

Таблица. Величины, формирующие входной сигнал

Величина	Обозначение	Единица измерения	Промежуток возможных значений	Промежуток для обучения	Дискретность
Продольная составляющая относительной скорости	V_{ox1}	узл	[-2;17]	[-4;19]	0,1
Скорость относительного ветра	V_r	м/с	[0;35]	[0;38]	0,1
Курсовой угол относительного ветра	α_r	°	[-179;180]	[-179;180]	1
Угловая скорость поворота	dK/dt	°/мин	[-180;180]	[-185;185]	1
Высота волны	b	м	[0;12]	[0;17]	0,5
Курсовой угол волны	γ	°	[-170;180]	[-170;180]	10
Длина волны	λ	м	[10;250]	[10;250]	10
Кажущийся период волны	τ	с	[5;30]	[5;30]	1

ствующей исходной величины из табл., то, применяя всякий раз данную функцию, мы получим псевдослучайное значение этой величины. Так создается псевдослучайная временная последовательность для каждой исходной величины. После переходим к соответствующей временной последовательности векторов входного сигнала $\{X\}_{i=1+n}$. Используя алгоритм решения дифференциального уравнения, находим соответствующую последовательность выходного сигнала $\{Y\}_{i=1+n}$. Таким образом, набор учебных данных $\{X, Y\}_{i=1+n}$ успешно сформирован.

После определения «качества» образцов для обучения необходимо выбрать их оптимальное количество. Несмотря на то, что в некоторых исследованиях по нейронным сетям [4] предлагаются формулы для оценки необходимого числа образцов, на практике эти методики не всегда работают. В таком случае приходится обращаться к методу проб и ошибок. Нейронная сеть № 1 обучается на образцах, если их число, в частности, равно 20 000. Этот факт устанавливается непосредственно при попытках обучения сети.

Для нейронной сети № 2 необходимо определить множество значений курса и скорости дрейфа. Для курса выбирается промежуток $[0; 360]^\circ$ с дискретностью 0,1°. Скорость дрейфа примем принадлежащей промежутку $[-5; 5]$ уз. с дискретностью 0,1 уз. Величину продольной составляющей относительной скорости V_{ox1} возьмем из табл. Число образцов для обучения составляет 10 000. Для сети № 2 необходимо меньшее число образцов, чем для сети № 1 — возможно, потому, что в структуре второй сети нет линий единичных задержек и, как следствие, она имеет меньшее число свободных параметров (весов и порогов).

Сформировав множества учебных примеров для обеих сетей, можно приступить к их обучению. Первым делом необходимо определиться с выбором алгоритма обучения. В нашем случае мы будем использовать алгоритм регуляризации Байеса в комбинации с методом Левенберга — Марквардта, реализованный в среде MATLAB 7.10.0.

По завершении процесса обучения наибольшие значения модулей ошибки скорости дрейфа и вектора погрешности относительной скорости для обученных сетей составили, соответственно, $5,72 \times 10^{-4}$ и $9,46 \times 10^{-4}$ м/с по сравнению с выходными образцами из обучающей выборки.

После обучения нейронных сетей возникает задача проверки их работоспособности с использованием таких последовательностей входного и выходного сигнала, которые не применялись для обучения. Для проверки работы системы сетей необходимо сформировать последовательности входных величин, получить выходные последовательности системы и сравнить их с результатами, полученными с использованием имитационной модели.

Будем проверять работу сети № 1, а затем всей системы в целом, не останавливаясь отдельно на тестировании сети № 2, так как выход сети № 1 служит одним из четырех входов сети № 2. Необходимость отдельного тестирования сети № 1 вызвана тем, что появляется возможность оценить границы промежутка возможных значений ее выхода, т. е. скорости дрейфа V_{oy1} .

Тестирование сети осложняется тем, что она работает во временной области, т. е. необходимо сформировать именно временные последовательности входного сигнала. При этом будем исходить из следующих принципов. Во-первых, значение входной величи-

ны в любой момент времени не должно выходить за пределы того промежутка, значения, из которого использовались для обучения сети. Во-вторых, необходимо учесть взаимосвязь между величинами во времени. В связи с этим можно предложить два этапа тестирования.

Первый этап характеризуется тем, что формируются псевдослучайные последовательности входных величин без учета взаимосвязи между ними, а также временной корреляции для одной и той же величины. С вероятностью 50% генерируются либо полностью стационарные сигналы, либо полностью хаотичные. В первом случае генератор псевдослучайных чисел равномерного распределения работает только один раз для всего времени плавания (4 ч), во втором — в каждый момент времени (с дискретностью 1 с). При первом варианте не учитываются взаимосвязи только между кажущимся периодом волнения, длиной волны, ее курсовым углом и скоростью судна, хотя период в действительности и является функцией перечисленных величин. Во втором случае корреляция отсутствует полностью.

Второй этап нужен, чтобы учесть взаимозависимость между величинами таблицы, исходя из их физического смысла. Например, любое изменение курса неизбежно приведет к изменению, скажем, курсового угла относительного ветра и т. д. Для решения данной задачи необходима модель поведения ветра, волнения и движения судна в данном районе океана, подробно описанная в [2]. На этом этапе также рассматриваются как стационарный характер сигналов, так и меняющийся со временем.

В качестве критерия соответствия нейронной сети имитационной модели выбирается наибольшее значение модуля невязки на четырехчасовом промежутке времени. На каждом этапе тестирования было рассмотрено 1000 модельных ситуаций. Невязка на первом этапе для сети № 1 составляла 13,1 м, для всей системы — 17,0 м, на втором этапе — 29,2 и 138 м соответственно.

Таким образом, по результатам тестирования можно сделать вывод, что построенная система двух нейронных сетей в 2000 модельных ситуаций прогнозирует относительную скорость судна так, что расхождение прогнозируемых ею координат с координатами, полученными с использованием имитационной модели, не превосходит в невязке 138 м за 4 ч плавания.

Нейронная сеть, созданная и обученная, представляет собой некоторый ал-



горитм, преобразующий входной сигнал в выходной. Аналогичную роль выполняет имитационная модель, основанная на численном решении дифференциального уравнения. На первый взгляд может показаться, что тестировать работу сети на входных сигналах, которые имели место при натуральных наблюдениях, излишне. Однако нейронная сеть представляет собой качественно иной алгоритм по сравнению с любым из алгоритмов численного решения дифференциальных уравнений, поэтому проверка сети с использованием натуральных реализаций входного сигнала будет, по меньшей мере, целесообразной.

Использовались данные трех натуральных наблюдений для теплохода «Инженер Плавинский» [1]. Для каждого эксперимента был сформирован вектор входа X , а затем с использованием нейронной сети и имитационной модели рассчитаны координаты центра тяжести судна в неподвижной системе. В серии из трех опытов наибольшее расхождение в невязке по сравнению с координатами, полученными с использованием имитационной модели, составило 2,2, 1,2 и 2,2 м за 4 ч плавания. Таким образом, в натуральных экспериментах нейронная сеть демонстрирует свою работоспособность в сравнении с имитационной моделью.

Синтезированная нейронная сеть работает в пространстве скоростей. Первая сеть преобразует силовые воздействия со стороны внешних факторов в скорость бокового дрейфа судна, заменяя, таким образом, дифференциальное уравнение. Вторая сеть на выходе имеет компоненты вектора относительной скорости судна в неподвижной системе координат. Абсолютная скорость судна получается сложением относительной скорости и скорости течения. Выбор архитектуры сетей во многом определяется ролью, которую они играют в модели счисления. Для обучения сетей необ-

ходимо сформировать учебный набор образцов с использованием имитационной модели. Количество и качество этих образцов определяется методом проб и ошибок. Далее используется метод регуляризации Байеса применительно к задаче обучения сетей. После окончания обучения возникает необходимость двухэтапного тестирования системы сетей: на первом этапе взаимосвязь между входными величинами не учитывается, во втором предлагается модель взаимосвязи между ними. Результаты тестирования позволяют сделать вывод, что обученная нейронная сеть практически соответствует имитационной модели. Проверка сети с использованием входных сигналов натуральных наблюдений также позволяет сделать вывод в пользу адекватности нейронной модели.

Настоящее исследование может развиваться в двух направлениях. Во-первых, необходимо стремиться к синтезу такой нейронной модели, которая бы работала в пространстве координат, а не скоростей и обучалась на образцах, полученных по результатам натуральных наблюдений. Во-вторых, построение нейронной модели, представленное в статье, открывает путь к созданию нейрорегулятора, который позволит создать адаптивную систему, обеспечивающую стабилизацию судна на заданной траектории по информации от автономных навигационных систем.

ЛИТЕРАТУРА

1. Справочник по теории корабля / под ред. Я. И. Войткунского. — Т. 3. — Л.: Судостроение, 1985.
2. Дерябин В. В. Модель счисления пути судна в условиях воздействия внешних факторов // Эксплуатация морского транспорта. — 2011. — № 1 (63).
3. Дерябин В. В. Применение нейронной сети в модели счисления пути судна // Эксплуатация морского транспорта. — 2011. — № 3 (65).
4. Хайкин С. Нейронные сети: полный курс / пер. с англ. — М.: Изд. дом «Вильямс», 2006.