

Нейросетевые модели в задачах исследования строительных конструкций

Н.Ю.Батурина

Актуальными являются обратные коэффициентные задачи по определению свойств строительной конструкции на основе экспериментальных данных [1,2]. Решение таких задач возможно с использованием аппарата нейронных сетей [3-9]. Нейросетевые модели целесообразно применять для начальной интерпретации диапазонов сигналов, а также для прогноза поведения конструкции при возможном изменении ее характеристик.

Пусть набор критериев $F_1, F_2, \dots, F_{N_{kp}}$ определяет качественные свойства конструкции. Каждый из критериев $F_l, l = \overline{1, N_{kp}}$ является функцией входных сигналов (параметров) $x_1, x_2, \dots, x_{N_{bx}}$, диапазоны изменения которых $\Delta_i, i = \overline{1, N_{bx}}$ известны. По данным эксперимента найдены значения критериев F_l на определенных наборах входных параметров. Число таких наборов (образцов) равно N_p . Обозначим x_i^j - входы или значения i -го входного параметра для j -го образца; y_{0l}^j - выходы или значения l -го критерия для j -го образца, найденные в результате эксперимента.

В качестве модели используется нейронная сеть в виде полутораслоного предиктора [10]. Сеть позволяет моделировать две задачи: задачу многомерной аппроксимации (прогноза) значений критериев и обратную задачу определения входных параметров по заданным значениям критериев.

Моделирование первой задачи заключается в том, что аппроксимируемые функции представляются в виде частичных сумм сходящегося ряда

$$F_l = F_{1l} + F_{2l} + \dots + F_{kl} + \dots, \quad l = \overline{1, N_{kp}},$$

где $F_{kl} = \omega_{kl}^{(2)} f_k \left(\sum_{i=1}^{N_{bx}} \omega_{ikl}^{(1)} x_i \right)$, $k = 1, 2, \dots$ - составляющая ряда, соответствующая

k -му потоку нейронов; f_k - активационная функция; $\omega_{ikl}^{(1)}, \omega_{kl}^{(2)}$ - коэффициен-

ты синоптических связей первого и второго слоев потока нейронов. Схема сети для k -го потока показана на рис.1.

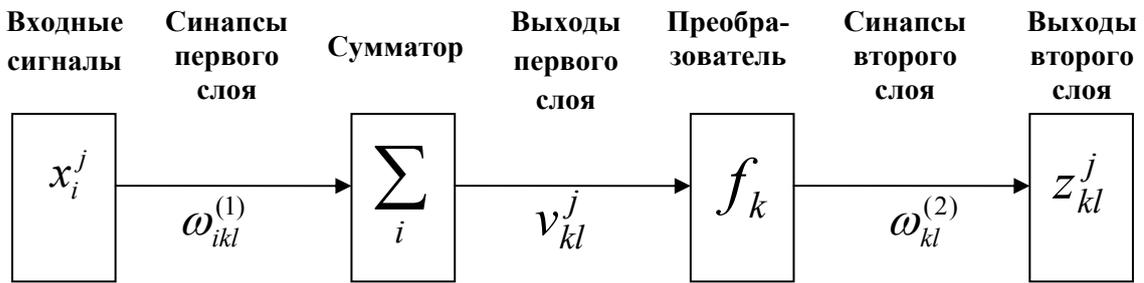


Рис.1. – Схема k -го потока сети

Особенностью сети такого типа является итерационное наращивание объема. Каждый последующий шаг, связанный с добавлением нового потока нейронов, осуществляется только после обучения предыдущего потока. При этом в качестве требуемых выходов добавленного потока нейронов рассматриваются ошибки аппроксимации предыдущего шага:

$$y_{kl}^j = y_{k-1,l}^j - z_{kl}^j, \quad z_{kl}^j = \omega_{kl}^{(2)} f_k(v_{kl}^j), \quad v_{kl}^j = \sum_{i=1}^{N_{bx}} \omega_{ikl}^{(1)} x_i^j, \quad k = 1, 2, \dots,$$

где $y_{k-1,l}^j, z_{kl}^j$ - требуемые и найденные выходы для k -го потока.

Коэффициенты $\omega_{ikl}^{(1)}, \omega_{kl}^{(2)}$ синоптических связей рассчитываются с помощью процедуры обратного распространения из условия минимума функции оценки

$$H_k = \frac{1}{2} \sum_{l=1}^{N_{kp}} \sum_{j=1}^{N_p} \left(y_{k-1,l}^j - z_{kl}^j \right)^2 \text{ по итерационным формулам}$$

$$\omega_{ikl}^{(1)}(t) = \omega_{ikl}^{(1)}(t-1) - h \Delta \omega_{ikl}^{(1)}(t-1), \quad \omega_{kl}^{(2)}(t) = \omega_{kl}^{(2)}(t-1) - h \Delta \omega_{kl}^{(2)}(t-1),$$

где $t = 1, 2, \dots$ - номер итерации. Поправки $\Delta \omega_{ikl}^{(1)}, \Delta \omega_{kl}^{(2)}$ выражаются через проекции $\text{grad } H_k$ на оси $\omega_{ikl}^{(1)}, \omega_{kl}^{(2)}$.

Шаг h в процессе расчета корректируется для обеспечения монотонного убывания функции оценки. Если для очередного потока в результате корректировки весов достигается требуемый минимум функции оценки, то сле-

дующий поток нейронов не добавляется, и аппроксимируемая функция считается построенной.

Алгоритм реализации задачи аппроксимации

1. Инициализация: присвоение $k = 0$; ввод значений $x_i^j, y_{0l}^j, \varepsilon$.
2. Добавление k -го потока: присвоение $k = k + 1$.
 - a. Инициализация: присвоение $t = 0$; ввод значений $\omega_{ikl}^{(1)}(0), \omega_{kl}^{(2)}(0), h, H_k(0) = \max, \Delta\omega_{ikl}^{(1)}(0) = 0, \Delta\omega_{kl}^{(2)}(0) = 0$.
 - b. Итерация по t : присвоение $t = t + 1$.
 - c. Корректировка коэффициентов $\omega_{ikl}^{(1)}(t), \omega_{kl}^{(2)}(t)$; расчет $z_{kl}^j(t), H_k(t)$.
 - d. Проверка условия $H_k(t) < H_k(t-1)$: если «true», то $h = 2h$ и переход на 2.e (проверка достижения заданной точности); если «false», то $h = h/2$ и переход на 2.c (пересчет итерации с измененным шагом).
 - e. Проверка условия $|H_k(t)| > \varepsilon$ и $t < N_t$: если «true», то вычисление поправок $\Delta\omega_{ikl}^{(1)}(t), \Delta\omega_{kl}^{(2)}(t)$ и переход на 2.b (нахождение следующей итерации для коэффициентов); если «false», то переход на 2.f (завершение программы или добавление нового потока).
 - f. Проверка условия $|H_k(t)| \leq \varepsilon$: если «true», переход на 3 (аппроксимация завершена); если «false», то переход на 2.g.
 - g. Проверка условия сходимости $k < N_{cx}$: если «true», то расчет y_{kl}^j (требуемые выходы для следующего потока); запоминание $\omega_{ikl}^{(1)}(t), \omega_{kl}^{(2)}(t)$; переход на 2 (добавление нового потока); если «false», то переход на 3 (аппроксимация не выполнена).
3. Завершение программы.

Пусть в результате решения задачи аппроксимации найдено разложение $F_l = F_{1l} + F_{2l} + \dots + F_{N_k l}$, $l = \overline{1, N_{kp}}$ для всех критериев, т.е. сеть обучена, и коэффициенты синоптических связей уже известны. В обратной задаче по известным значениям критериев $y_{01}, y_{02}, \dots, y_{0N_{kp}}$ находятся соответствующие значения входных параметров $x_1, x_2, \dots, x_{N_{bx}}$. Отличие в решениях прямой и обратной задач состоит в том, что в задаче аппроксимации обучение сети осуществляется по коэффициентам синоптических связей, а в обратной задаче – по входным параметрам x_i . На входы обученной сети подаются начальные значения $x_i(0)$ из рассматриваемых диапазонов Δ_i , $i = \overline{1, N_{bx}}$. Далее вычисляются значения выходов $z_1, z_2, \dots, z_{N_{kp}}$ по формулам

$$z_l = \sum_{k=1}^{N_k} \omega_{kl}^{(2)} f_k(v_{kl}), \quad v_{kl} = \sum_{i=1}^{N_{bx}} \omega_{ikl}^{(1)} x_i, \quad l = \overline{1, N_{kp}}.$$

Последующие итерации x_i , $i = \overline{1, N_{bx}}$ рассчитываются с помощью процедуры обратного распространения из условия минимума функции оценки

$$H = \frac{1}{2} \sum_{l=1}^{N_{kp}} (y_{0l} - z_l)^2$$

по итерационным формулам $x_i(t) = x_i(t-1) - h \Delta x_i(t-1)$,

где $t = 1, 2, \dots$ - номер итерации. Поправки Δx_i выражаются через проекцию $\text{grad } H$ на ось x_i . Сходящийся итерационный процесс останавливается по условию достижения требуемого минимума функцией оценки H .

Список литературы:

1. Кадомцев М.И., Ляпин А.А., Шатилов Ю.Ю. Вибродиагностика строительных конструкций. [Электронный ресурс] // «Инженерный вестник Дона», 2012. – № 3. – Режим доступа: <http://ivdon.ru/magazine/archive/> (доступ свободный) – Загл. с экрана. – Яз. рус.
2. Кадомцев М.И., Ляпин А.А., Тимофеев С.И. К вопросам построения эффективных алгоритмов расчета системы «сооружение-грунт». [Электронный ресурс] // «Инженерный вестник Дона», 2012. – № 1. – Режим доступа:

<http://ivdon.ru/magazine/archive/> (доступ свободный) – Загл. с экрана. – Яз. рус.

3. Абовский Н.П., Максимова О.М. Нейропрогнозирование результатов натуральных испытаний строительных конструкций на основе эволюционной пошаговой модели с доучиванием. // Научная сессия МИФИ-2007. IX Всероссий. науч.-техн. конф. «Нейроинформатика – 2007». Сборник научных трудов. В 3-х частях. Ч.1. М.: МИФИ, 2007. – С.122-131.
4. Максимова О.М. Разработка и применение нейросетевой технологии прогнозирования к задачам строительной механики и конструкций. //Труды Междунар. Конгресса «Наука и инновации в строительстве» SIB – 2008, Воронеж, 2008. – С.146-151.
5. Абовский, Н. П. Нейросетевые модели в задачах строительной механики / Н. П. Абовский, Т. В. Белобородова, О. М. Максимова, Л. Г. Смолянинова // Изв. вузов. Строительство, 2000. – № 7. – С. 6–14.
6. Watkins, S., Akhavan, F., Dua, R., Chandrashekhara, K., and Wunsch. Impact-induced damage characterization of composite plates using neural networks. // Smart Materials and Structures, 2007, 16(2). – pp. 515-524.
7. Park, J., Kim, J., Hong, D., Ho, D., and Yi. Sequential damage detection approaches for beams using time-modal features and artificial neural networks. // Journal of Sound and Vibration, 2009, 323(1-2). – pp. 451-474.
8. Tsaregorodtsev V.G. Parallel implementation of back-propagation neural network software on SMP computers / Lecture Notes In Computer Science 3606 (PaCT-2005 Proceedings), Springer-Verlag, 2005. –pp.185-192.
9. Нейронные сети и анализ данных. [Электронный ресурс]: <http://neuropro.ru/links.shtml>.
10. Дорпер М.Г. Аппроксимация многомерных функций полутораслойным предиктором с произвольными преобразователями. Методы нейроинформатики. //Сборник научных трудов. Под ред. А.Н. Горбаня, КГТУ, Красноярск, 1998. – С.130-151.