

Сегодня нейронные сети применяются как для управления электроприводом (этот тип системы называется нейроконтроллер), так и для идентификации переменных состояния электропривода (нейронный наблюдатель или нейроэмулятор). Областью применения обоих типов систем являются нелинейные системы с переменными параметрами. Очевидно, что асинхронный электропривод в полной мере принадлежит к данному классу систем. В различных исследованиях проводится анализ нейронного наблюдателя для асинхронного двигателя на основе сети с сигмоидальной активационной функцией. Рассматриваются как прямонаправленные сети, так и рекуррентные.

В заключение следует отметить, что применение нейронных сетей – весьма перспективное направление современной теории управления. К его преимуществам относятся возможность обучения и самообучения, возможность управления нелинейными объектами, слабая чувствительность к изменению параметров объекта. С точки зрения реализации, сети могут выполняться на традиционных микропроцессорных системах, однако заложенный в них принцип параллельного вычисления позволяет существенно увеличить производительность контроллера за счет применения специальной аппаратной базы.

М. М. Шевелев

ИДЕНТИФИКАЦИЯ КОЛЕБАТЕЛЬНОГО ЗВЕНА МЕТОДОМ ГРУППОВОГО УЧЕТА АРГУМЕНТОВ И ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТЬЮ С ГЕНЕТИЧЕСКИМ АЛГОРИТМОМ ОБУЧЕНИЯ

В настоящее время наблюдается повторный «всплеск» количества публикаций в области искусственных нейронных сетей. Первый имел место в 1960-х гг., после выхода в свет работы Ф. Розенблатта «Принципы нейродинамики». Большая первоначальная активность вскоре сменилась большим разочарованием, поскольку стало ясно, что простые в организации персептроны для самообучения в решении сложных задач требуют слишком много времени.

И все же идея самообучения слишком привлекательна для того, чтобы ее надолго забыли. Причиной нового бума в этой области послужили

работы Хопфилда (нейронные сети Хопфилда) и Хинтона (нейронные сети с обратным распространением ошибки). Были получены обнадеживающие результаты в сфере применения нейронных сетей различных типов в самых разных областях. Это, к примеру, распознавание очень зашумленных сигналов, распознавание текстов по их матричному изображению, прогнозирование курсов валют.

Однако иногда нейронные сети пытаются применить в областях, где существуют более эффективные методы. Попытаемся оценить возможные области применения искусственных нейронных сетей и выяснить пути, повышающие их эффективность в остальных случаях.

Модель нейронной сети. Нейронная сеть состоит из множества одинаковых элементов – нейронов, поэтому рассмотрение работы искусственной нейронной сети начнем с модели одиночного нейрона.

Биологический нейрон моделируется как устройство, имеющее несколько входов (дендриты) и один выход (аксон). Каждому входу ставится в соответствие некоторый весовой коэффициент w , характеризующий пропускную способность канала и оценивающий степень влияния сигнала с этого входа на сигнал на выходе. В зависимости от конкретной реализации обрабатываемые нейроном сигналы могут быть аналоговыми или цифровыми (1 или 0). В теле нейрона происходит взвешенное суммирование входных возбуждений, и далее это значение является аргументом активационной функции нейрона, как это представлено на рис. 1.




Рис. 1. Передаточная функция

При этом суммирующий элемент реализует функцию $d=f(w_i x_i)$, а активационная функция F может иметь самый различный характер, например, $y=F(d)=1/(1+e^{-d})$ (сигмоидная функция), или $y=F(d)=e^{-|d|}$.

Будучи соединенными определенным образом, нейроны образуют нейронную сеть. Работа сети состоит из различных процессов обучения. Под обучением понимается процесс адаптации сети к предъявляемым эталонным образцам путем модификации (в соответствии с тем или иным ал-

горитмом) весовых коэффициентов связей между нейронами. Заметим, что этот процесс является результатом алгоритма функционирования сети, а не предварительно заложенных в нее знаний человека, как это часто бывает в системах искусственного интеллекта.

Общая схема построения алгоритмов метода группового учета аргументов (МГУА). Заимствование алгоритмов переработки информации у природы является одной из основных идей кибернетики. «Гипотеза селекции» утверждает, что алгоритм массовой селекции растений или животных является оптимальным алгоритмом переработки информации в сложных задачах. При массовой селекции высевается некоторое количество семян.

В результате опыления образуются сложные наследственные комбинации. Селекционеры выбирают некоторую часть растений, у которых интересующее их свойство выражено больше всего (эвристический критерий). Семена этих растений собирают и снова высевают для образования новых, еще более сложных комбинаций. Через несколько поколений селекция останавливается и ее результат является оптимальным. Если чрезмерно продолжать селекцию, то наступит «инцухт» – вырождение растений. Существует оптимальное число поколений и оптимальное количество семян, отбираемых в каждом из них.

Алгоритмы МГУА воспроизводят схему массовой селекции, показанной на рис. 2. В них есть генераторы усложняющихся из ряда в ряд комбинаций и пороговые самоотборы лучших из них.




Рис. 2. Схема МГУА

Так называемое «полное» описание объекта

$$j = f(x_1, x_2, x_3, \dots, x_m),$$

где f – некоторая элементарная функция, например степенной полином, заменяется несколькими рядами «частных» описаний:

$$1\text{-ряд селекции: } y_1 = f(x_1, x_2), y_2 = f(x_1, x_3), \dots, y_s = f(x_{m-1}, x_m),$$

$$2\text{-ряд селекции: } z_1 = f(y_1, y_2), z_2 = f(y_1, y_2), \dots, z_p = f(y_{s-1}, y_s), \text{ где } s = C_n^2, p = C_s^2 \text{ и т. д.}$$

Входные аргументы и промежуточные переменные сопрягаются парно, и сложность комбинаций на каждом ряду обработки информации возрастает (как при массовой селекции), пока не будет получена единственная модель оптимальной сложности.

Каждое частное описание является функцией только двух аргументов. Поэтому его коэффициенты легко определить по данным обучающей последовательности при малом числе узлов интерполяции. Исключая промежуточные переменные (если это удастся), можно получить «аналог» полного описания. Математика не запрещает обе эти операции. Например, по десяти узлам интерполяции можно получить результат оценки коэффициентов полинома сотой степени и т. д.

Из ряда в ряд селекции пропускается только некоторое количество самых регулярных переменных. Степень регулярности оценивается по величине среднеквадратичной ошибки (средней для всех выбираемых в каждом поколении переменных или для одной самой точной переменной) на отдельной проверочной последовательности данных. Иногда в качестве показателя регулярности используется коэффициент корреляции.

Ряды селекции наращиваются до тех пор, пока регулярность повышается. Как только достигнут минимум ошибки, селекцию, во избежание «кинхухта», следует остановить. Практически рекомендуется остановить селекцию даже несколько раньше достижения полного минимума, как только ошибка начинает падать слишком медленно. Это приводит к более простым и более достоверным уравнениям.

Алгоритм с ковариациями и с квадратичными описаниями. В этом алгоритме используются частные описания, представленные в следующих формулах:

$$y_i = a_0 + a_1 x_i + a_2 x_j + a_3 x x_j,$$

$$y_k = a_0 + a_1 x_i + a_2 x_j + a_3 x x_j + a_4 x_i^2 + a_5 x_j^2.$$

Сложность модели увеличивается от ряда к ряду селекции как по числу учитываемых аргументов, так и по степени. Степень полного описания быстро растет. На первом ряду – квадратичные описания, на втором – описания четвертой степени, на третьем – восьмой и т. д. (рис. 3). В связи с этим минимум критерия селекции находится быстро, но не совсем точно. Кроме того, имеется опасность потери существенного аргумента, особенно на первых рядах селекции (в случае отсутствия протекции). Специальные теоремы теории МГУА определяют условия, при которых результат селекции не отличается от результата полного перебора моделей.

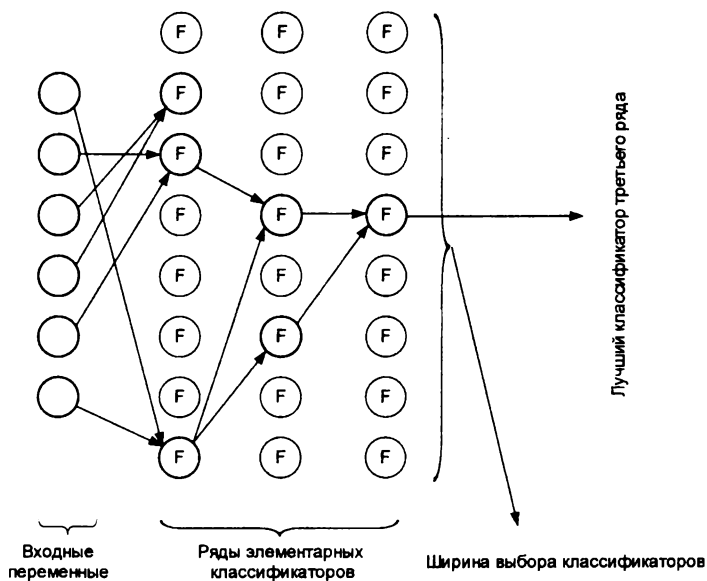


Рис. 3. Элементы нейронной сети

Для того, чтобы степень полного уравнения повышалась с каждым рядом селекции на единицу, достаточно рассматривать все аргументы и их ковариации как обобщенные аргументы и пользоваться составленными для них линейными описаниями.

Сравним полученные результаты. На рис. 4 представлены результаты моделирования инерционного звена второго порядка (модель электрической машины постоянного тока независимого возбуждения) нейроэмулятором с генетическим алгоритмом оптимизации.

Передачная функция эталонного объекта управления (ОУ):

$$\Phi = \frac{k}{T^2 s^2 + 2T\zeta s + 1},$$

где $k = 1$, $T = 0,5$ и $V = 0,1$. Значения параметров подобраны таким образом, чтобы колебательные свойства ОУ были выражены хорошо. Нейронная сеть, использованная в работе, была трехслойной, с тремя узлами во входном слое (входной сигнал, выходной сигнал эмулятора на предыдущем шаге и его производная), восемь узлами в скрытом слое и двумя узлами в выходном слое (первая и вторая производная выходного сигнала).




Рис. 4. Результаты моделирования инерционного звена второго порядка нейроэмулятором с генетическим алгоритмом оптимизации:

1 – эталонная характеристика; 2 – расчетная характеристика

Для исследования способности МГУА к моделированию динамических объектов была создана программная система на языке *Delphi*, которая имеет возможность генерировать программный модуль на языке Паскаль, реализующий логику полученного дерева МГУА. Этот модуль может затем использоваться различными программами в качестве математической модели.

Для моделирования колебательного звена построим для начала переходный процесс для графика, представленного на рис. 4. После этого в электронных таблицах *Excel* построим данные в следующем виде: каждый последующий столбец повторяет предыдущий с запаздыванием на 1 такт (1 такт примем равным 0,1 с). Всего тактов возьмем 100. Для проверки способности МГУА отбрасываем лишнюю информацию, на вход сети подадим данные за четыре последних такта.

Сравним полученные результаты с эталоном (таблица) (данные в таблице приведены за такты 90...100, соответствующие 9...10 с):

Сравнение данных переходного процесса эталонного колебательного звена и его модели

Расчет	Эталон
1,35921205906378E+0000	1,35923
1,37237263595137E+0000	1,37239
1,38151170083833E+0000	1,38152
1,38661758311519E+0000	1,38663
1,38771955537757E+0000	1,38772
1,38488671317641E+0000	1,38488
1,37822647536123E+0000	1,37821
1,36788272797653E+0000	1,36786
1,35403363778640E+0000	1,35400
1,33688916428515E+0000	1,33686

Даже на сотом такте разница между эталоном и расчетом имеется только в шестой значащей цифре, поэтому показывать эту разницу на графике не имеет смысла.

Именно поэтому МГУА на линейной задаче дал такие прекрасные результаты и оказался точнее нейронной сети. Использование последней представляется в данном случае стрельбой из пушки по воробьям. Однако при переходе к нелинейным задачам МГУА уже не имеет такого явного преимущества, хотя в большинстве случаев получаемая точность все-таки достаточна для практического применения.

Это отнюдь не означает, что нейронные сети – это плохо, а МГУА – хорошо. Это всего лишь «животные» с различным, хотя и частично пересекающимся, ареалом обитания. На основании проведенного сравнения

представляется, что искусственные нейронные модели будут более эффективны при следующих условиях:

- моделируемый объект очень сложен;
- моделируемый объект существенно нелинеен;

Для моделирования участков объекта, имеющих несложное математическое описание, предпочтительно использование вспомогательных частных моделей (использующих, к примеру, алгоритмы типа МГУА).

М. М. Шевелев

МОДЕЛИРОВАНИЕ, РАЗРАБОТКА И НАСТРОЙКА ФИЗИЧЕСКИХ РЕГУЛЯТОРОВ С ПОМОЩЬЮ ПЭВМ

Современные исследования автоматизированных электроприводов станков – качалок для добычи нефти напрямую связаны с использованием математических моделей. Это объясняется сложностью и нестабильностью процессов, происходящих в скважине. Математическая модель, если она достаточно адекватно описывает поставленную задачу, позволяет исследователю проанализировать влияние различных факторов на те или иные параметры, получить достоверные данные, на основании которых можно сделать выводы и в конечном итоге дать конкретные рекомендации.

Это существенно ускоряет и удешевляет процесс исследования, а в ряде случаев позволяет изучить процессы, ранее недоступные. Для исследования переходных процессов в глубиннонасосной установке создана математическая модель, включающая в себя ряд уравнений с граничными условиями, описывающих эти процессы с определенными допущениями. Корректность математической модели определяется обоснованностью принятых при ее разработке допущений и правильностью ее адаптации к реальным условиям и конкретной установке.

Специалисты нефтяной промышленности еще в 1960-х гг. делали попытки использовать электронные вычислительные машины непрерывного действия и соответствующую технику моделирования для настройки физических автоматических регуляторов. И в научных трудах тех лет описывались результаты анализа возможности сочетания математических моделей дизель-генераторов как объектов управления с устройствами автоматизации электростанций. Опыт показал, что при уровне технических