

МЕТОДЫ ИДЕНТИФИКАЦИИ И АДАПТИВНОГО УПРАВЛЕНИЯ

УДК 004.852

О.Г. Руденко, А.А. Бессонов

НЕЙРОСЕТЕВАЯ АППРОКСИМАЦИЯ НЕЛИНЕЙНЫХ ЗАШУМЛЕННЫХ ФУНКЦИЙ НА ОСНОВЕ КОЭВОЛЮЦИОННОГО КООПЕРАТИВНО-КОНКУРЕНТНОГО ПОДХОДА

Введение

Решение широкого круга задач различных отраслей науки, техники и экономики, таких как идентификация, фильтрация, восстановление, прогнозирование и т.д., связано с аппроксимацией некоторых нелинейных функций

$$y(x) = f(x) + \xi, \quad (1)$$

где $x = [x_1, x_2, \dots, x_N]^T$ — $N \times 1$ — вектор обобщенного входного сигнала; $f(\bullet)$ — неизвестная нелинейная функция; ξ — помеха, т.е. заключается в получении оценки функции $f(\bullet)$ по измерениям входных и выходных переменных.

Отсутствие информации о виде нелинейности зачастую приводит к неэффективности традиционных методов аппроксимации, а в ряде случаев — к их неприменимости. Альтернативой традиционным методам является применение нейросетевых технологий.

Являясь универсальными аппроксиматорами, некоторые типы искусственных нейронных сетей (ИНС) позволяют восстановить с заданной точностью любую сколь угодно сложную непрерывную нелинейную функцию, используя представления аппроксимируемой функции в виде нейронной сети, образованной нейронами, параметры которых определяются путем ее обучения. Наибольшее распространение при решении такой задачи получили многослойный персептрон (МП), радиально-базисные сети (РБС) и сеть СМАС (Cerebellar Model Articulation Controller) [1–5], использующие соответственно аппроксимации нелинейного оператора $f(\bullet)$ вида

$$\hat{y}(x) = \hat{f}(x) = f^q[(W^q)^T f^{q-1}[(W^{q-1})^T f^{q-2}[\dots f^1[(W^1 x + b_1)^T] \dots]]] + b_q, \quad (2)$$

$$\hat{y}(x) = \hat{f}(x) = w_0 + \sum_{i=1}^N w_i \hat{O}_i; \quad \hat{O}_i(x) = w_0 + W^T \Phi(x), \quad (3)$$

$$\hat{y}(x) = \hat{f}(x) = w^T a(x), \quad (4)$$

где W^i — вектор весовых параметров нейронов i -го слоя сети; $f^i[\bullet]$ — активационная функция (АФ) i -го слоя; b_i — смещение i -го нейрона; $\Phi(x)$ — вектор выбранных базисных функций (БФ); $a(x)$ — вектор ассоциаций.

Использование ИНС требует решения задач структурной и параметрической оптимизации, соответствующих выбору оптимальной топологии сети и ее обучению (настройке параметров в МП (2) — это весовые параметры и параметры АФ, в РБС (3) — весовые параметры, центры базисных функций и их дисперсии, а в СМАС (4) — весовые параметры и параметры кодирования информации).

Попытки устранить недостатки традиционных методов синтеза и функционирования ИНС (возможность оверфитинга, необходимость использования для обучения сети градиентных методов оптимизации, требование наличия априорной информации о виде распределения помехи, влияющего на выбор критерия обучения и т.д.) привели к появлению нового класса сетей — эволюционирующих ИНС (ЭИНС), в которых в дополнение к традиционному обучению используется другая фундаментальная форма адаптации — эволюция, реализуемая путем применения эволюционных вычислений [6, 7].

При переходе от ИНС к ЭИНС для всех типов сетей применяются общие эволюционные процедуры, а различия заключаются лишь в способе кодирования структуры и параметров той или иной ИНС в виде хромосомы [8]. Следует отметить, что в последнее время указанные задачи все чаще стремятся решать одновременно с помощью коэволюционирующих адаптивных систем, т.е. систем, состоящих из разнообразных эволюционирующих групп особей (популяций), которые действуют совместно для выполнения сложных вычислений или выработки совместного эффективного поведения.

Взаимодействие между различными популяциями может приводить к следующим формам коэволюционирующих систем:

- системам, в которых реализуется кооперативное поведение (каждое действие осуществляется на основе консенсуса особей на основе сотрудничества);
- системам, в которых реализуется конкурентное поведение (каждое действие осуществляется одной особью, выбранной по конкурсу для решения текущей задачи);
- гибридным системам, в которых одновременно реализуется и кооперативное и конкурентное поведение.

Козволюционный алгоритм

Рассмотрим коэволюционный алгоритм определения архитектуры нейронных сетей прямого распространения и их обучения, основанный на гибридной стратегии кооперации и конкуренции, схема которого представлена на рис. 1. Алгоритм обучения реализует среду, способствующую сотрудничеству и конкуренции популяций, в которых каждая особь представляет собой ИНС прямого распространения, решающую специфическую задачу. Так, для аппроксимации исследуемой функции предлагается использовать популяции универсальных аппроксиматоров (МП, РБС, сеть СМАС), а для борьбы с возможными помехами ввести дополнительную популяцию шумоподавляющих автоэнкодеров (АЭ) — специализированных многослойных нейронных сетей, осуществляющих автоассоциативную аппроксимацию функции, при которой выходной сигнал сети наиболее точно соответствовал бы входному. Между популяциями аппроксиматоров происходит конкуренция за право решать поставленную задачу, в то время как каждая из популяций аппроксиматоров может сотрудничать с популяцией АЭ для получения робастных решений, устойчивых к различным типам помех как во входных, так и выходных сигналах. Вся же совокупность популяций несет ответственность за окончательное решение поставленной задачи.

Кооперация популяций АЭ и аппроксиматоров осуществляется по принципу комменсализма, где роль хозяина выполняет АЭ, а комменсала — сеть-аппрок-

симатор (комменсал при этом извлекает выгоду и возлагает на хозяина регуляцию своих отношений с внешней средой, но не вступает с ним в тесные взаимоотношения).

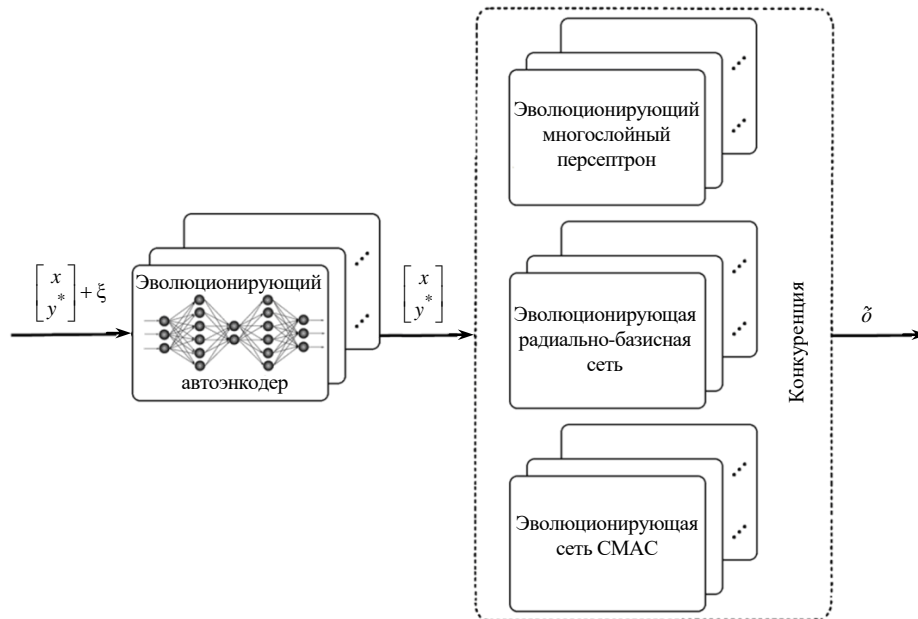


Рис. 1

Архитектура эволюционирующего МП и сети РБФ подробно рассмотрена в работах [9, 10]. В данной статье для устранения помех (в том числе и негауссовских) предлагается использование эволюционирующего шумоподавляющего автоэнкодера (ШАЭ), структуру которого рассмотрим более подробно.

Шумоподавляющий автоэнкодер

Как отмечалось выше, АЭ — это тип многослойной ИНС, осуществляющей автоассоциативную аппроксимацию функции, наиболее соответствующей заданной. Такое тождественное соответствие оказывается нетривиальным, если наложить некоторые специфические ограничения на нейронную сеть АЭ, например ограничение количества нейронов в скрытом слое и введение критериев разреженности на активацию этих нейронов.

В общем случае АЭ характеризуются следующим:

- имеют симметричную структуру;
- содержат нечетное количество слоев;
- состоят из кодера и декодера;
- содержат так называемое «бутылочное горлышко» — выходной слой кодера (входной слой декодера), в котором используются линейные функции активации;
- количество нейронов в «бутылочном горлышке» должно быть меньше, чем размерность входных данных, или же должна происходить лишь частичная активация этих нейронов (разреженная активация);
- во входном и выходном слоях АЭ обычно используются гауссовские функции активации.

Симметричность архитектуры значительно облегчает задачу настройки параметров АЭ, поскольку необходимо определять лишь половину всех параметров сети.

Рассмотрим классический АЭ с одним скрытым слоем. Обозначим входные сигналы сети как x_1, x_2, \dots, x_n .

Вначале АЭ преобразует (кодирует) входной сигнал $x \in [0, 1]$ в некоторое внутреннее представление $y \in [0, 1]$, используя преобразование вида

$$y = f(Wx + b), \quad (5)$$

где W и b — общие матрицы весов и смещений сети; f — нелинейная функция преобразования (например, гиперболический тангенс).


Затем внутреннее представление (код) входного сигнала y преобразуется обратно (декодируется) в сигнал z , являющийся реконструкцией входного сигнала и имеющий такую же размерность. Данное преобразование можно записать следующим образом:

$$z = g(W'y + b'), \quad (6)$$

где W' и b' — настраиваемые матрицы весов и смещений сети декодирующего преобразования.

Параметры моделей (5) и (6) (W, W', b, b') настраиваются таким образом, чтобы минимизировать ошибку реконструкции входного сигнала, что может быть осуществлено с использованием различных функций потерь, например квадратичной либо кросс-энтропии.

Классическая архитектура АЭ показана на рис. 2 [11]. Здесь слой $L1$ является



входным слоем, который кодируется в слое $L2$ с использованием скрытого представления, а восстановление входного сигнала происходит в слое $L3$. Так как количество скрытых нейронов меньше, чем количество входов, то АЭ осуществляет сжатие данных. Следует отметить, что процедура преобразования данных в АЭ похожа на аналогичную процедуру в методе анализа основных компонент. Если же количество скрытых нейронов превышает количество входов, АЭ может по-прежнему обнаруживать некоторую полезную информацию во входных данных, устанавливая определенные ограничения разреженности.

Рис. 2

Шумоподавляющий автоэнкодер (ШАЭ–DAE–Denoising Autoencoder) является вариантом АЭ, в котором входы сочетаются с некоторыми искажениями (такими как аддитивный шум или маскирование) и система обучается для восстановления данных без помех [12]. Таким образом, ШАЭ можно рассматривать как стохастическое расширение классического АЭ, которое вынуждает модель обучаться восстановлению входного сигнала при подаче на вход его зашумленной версии. Стохастический процесс повреждения данных случайным образом устанавливает некоторые из входных данных в нуль, заставляя ШАЭ прогнозировать отсутствующие (поврежденные) значения для случайно выбранных подмножеств отсутствующих шаблонов. Схема обучения ШАЭ может использоваться в приложениях для шумоподавления и является популярным способом обучения автокодера более значимым скрытым представлениям данных [11].

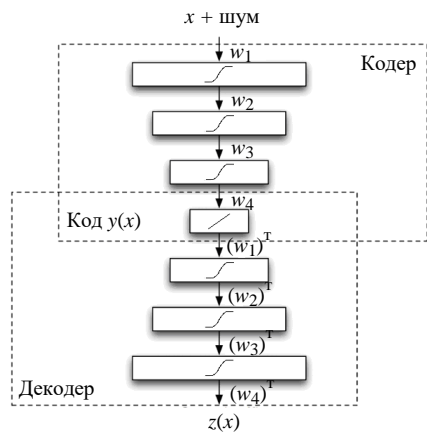


Рис. 3

завать лишь данные из набора ранее занесенных в память образцов, в связи с чем возникает проблема формирования обучающей выборки.

Широкому использованию ШАЭ в практических приложениях, связанных с обработкой данных, зачастую препятствует отсутствие обучающей последовательности действительно чистых (незашумленных) данных, необходимых для настройки энкодеров. Кроме того, для настройки параметров ШАЭ обычно используются градиентные алгоритмы, обладающие целым рядом недостатков.

В данной работе предлагается модификация ШАЭ, в которой используется нейроэволюционный подход, позволяющий не только настроить параметры сети, но и определить ее структуру. В дальнейшем эту модификацию будем именовать как ЭШАЭ (эволюционирующий шумоподавляющий автоэнкодер).

Эволюционирующий шумоподавляющий автоэнкодер

Одним из наиболее распространенных видов эволюционных алгоритмов являются генетические алгоритмы (ГА), предложенные Дж. Холландом. Основными этапами работы ГА являются: инициализация популяции, оценивание популяции (вычисление функции приспособленности), селекция, скрещивание, мутация. Критерием останова ГА обычно служит либо выполнение максимально допустимого количества итераций, либо достижение функцией приспособленности какой-либо особи (варианта решения) некоторого заранее заданного порогового значения.

Основное отличие нейроэволюционного алгоритма (НА) от градиентных алгоритмов, реализуемых с помощью ИНС, заключается в том, что все операции здесь производятся не с одной сетью, а с некоторым их множеством (популяцией). С одной стороны, это увеличивает объем требуемой памяти, так как необходимо хранить информацию обо всех сетях в популяции, а с другой — не требуется проводить такие сложные операции, как обращение матриц при обучении сети.

В начале работы НА случайным образом инициализируется популяция P_0 , состоящая из N особей (АЭ): $P_0 = \{H_1, H_2, \dots, H_N\}$. Каждая особь в популяции при этом получает свое уникальное описание, закодированное в хромосоме $H_j = \{h_{1j}, h_{2j}, \dots, h_{Lj}\}$, которая состоит из L генов, где $h_{ij} \in [w_{\min}, w_{\max}]$ — значение i -го гена j -й хромосомы (w_{\min} — минимальное и w_{\max} — максимальное допустимое значение соответственно). Формат хромосомы и соответствие между генами и параметрами АЭ представлены на рис. 4. Следует отметить,

Архитектура ШАЭ представлена на рис. 3. По окончании процесса обучения сети ее можно использовать в реальных условиях. Следует отметить, что данные в реальных условиях иногда получаются зашумленными или частично поврежденными. После предъявления таких данных ранее обученному ШАЭ из его памяти будет извлечен наиболее близкий к представленному вектор данных, и частичная потеря информации будет устранена. Очевидно, что ШАЭ может при этом использовать

что длина хромосомы ограничивается максимально допустимым количеством нейронов.

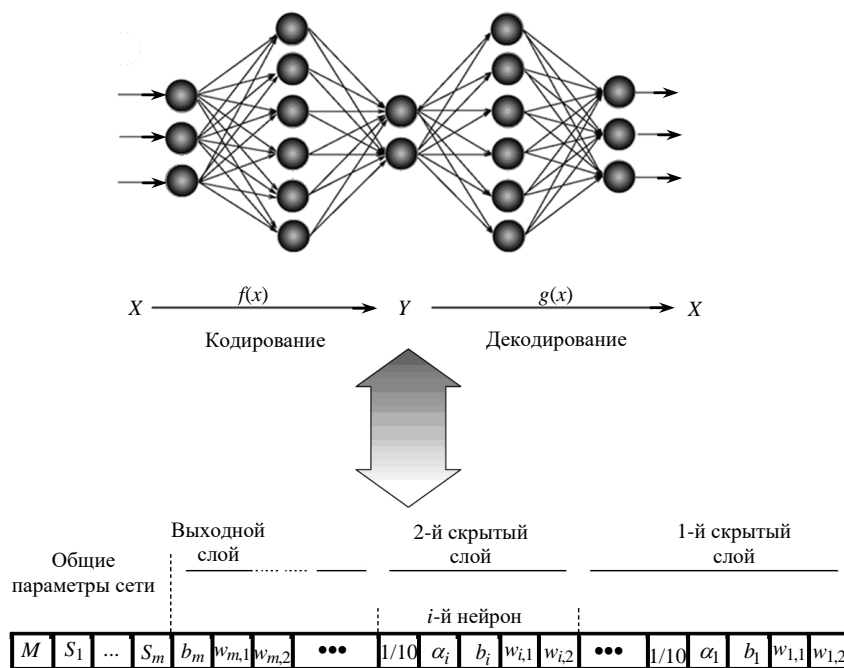


Рис. 4

Как видно из рис. 4, каждая хромосома состоит из генов, в которых хранится информация о соответствующих параметрах АЭ. В начале хромосомы идут гены, которые содержат информацию об общих параметрах сети (максимальное количество скрытых слоев M , максимальное количество нейронов в каждом слое S_1, \dots, S_M). Следующие гены кодируют информацию о смещении нейронов выходного слоя АЭ. Затем идут блоки генов, кодирующие параметры соответствующих нейронов скрытого слоя. Первый ген каждого такого блока ($1/10$) определяет присутствие соответствующего нейрона в структуре сети, т.е. участвует ли он в вычислении выходной реакции сети на поступивший входной сигнал. Особенность архитектуры АЭ определяет структуру лишь его кодирующей части, а структура декодирующей части является ее зеркальным отображением. Если в качестве $f(\bullet)$ в АЭ используются сигмоидальные АФ, например вида

$$f(x) = (1 + e^{-\alpha x})^{-1}, \quad (7)$$

то следующий ген в его хромосоме (α) определяет форму АФ данного нейрона.

После того как начальная популяция сформирована, производится оценка приспособленности каждой входящей в нее особи путем вычисления функции приспособленности (фитнесс-функции). Обычно при решении задач оптимизации, конечная цель работы ГА неизвестна и с его помощью производится поиск некоторого оптимального решения. Однако при решении задачи аппроксимации известными являются желаемая реакция сети $y^*(k)$ и ее реальный выходной сигнал $\hat{y}(k)$. Очевидно, что сеть, для которой разность $y^*(k) - \hat{y}(k)$ является минимальной, и будет считаться наиболее приспособленной для решения поставленной задачи. При

наличии полной выборки входных–выходных значений аппроксимируемой функции значение приспособленности i -й особи можно записать следующим образом:

$$f_i(x_j) = \frac{1}{M} \sum_{j=1}^M |y_j^*(x_j) - \hat{y}_j(x_j)|,$$

где M — размер выборки.

Для упрощения дальнейших операций сортировки популяции обычно функция приспособленности нормализуется:

$$f_i^N(x_j) = \frac{f_i(x_j)}{\sum_{j=1}^N f_j(x_j)}.$$

Таким образом, для того чтобы определить приспособленность сети, производится ее симуляция на всей выборке, и затем сравнивается реакция сети с требуемыми значениями аппроксимируемой функции. Усредненная ошибка и будет искомым значением функции приспособленности.

После окончания формирования нового поколения осуществляется его оценка. При выполнении критерия останова ГА начинает работу градиентный алгоритм настройки весовых параметров, осуществляющий «тонкую» настройку наилучшей сети, отобранной с помощью ГА. В качестве такого алгоритма может быть взята какая-либо модификация алгоритма обратного распространения, алгоритм Гаусса–Ньютона, Левенберга–Марквардта и т.п.

Моделирование

Эксперимент 1. В данном эксперименте проводилось исследование шумодавляющих свойств ЭШАЭ на примере восстановления следующей зашумленной функции четырех переменных:

$$F(x_1, x_2, x_3, x_4) = x_1 + \sin(\pi x_1) \cdot \cos(\pi x_2) \cdot \sin(\pi x_3) \cdot (\sin(\pi x_4))^2 - 1 + \xi).$$

Для этого использовалась популяция ЭШАЭ, состоящая из 150 особей. Каждый автоэнкодер имел соответственно пять входных и выходных нейронов (x_1, \dots, x_4, F). Внутренняя структура сети (количество слоев и нейронов в них) определялась с помощью эволюционного процесса с учетом особенностей структуры ЭШАЭ, рассмотренных выше. Входной сигнал, соответствующий значению функции F , зашумлялся помехами ξ с различными распределениями: a — Лапласа, b — Релея и v — Гаусса. Результаты эксперимента представлены на рис. 5, где приведены гистограммы помех (слева) и соответствующие им графики изменения ошибки обучения (справа). Как видно из результатов моделирования, автоэнкодер показывает удовлетворительные результаты при любом типе помех.





Рис. 5

Продолжение рисунка



б

Эксперимент 2. В данном эксперименте решалась задача коэволюционной аппроксимации многомерной нелинейной функции

$$F(x_1, x_2, x_3, x_4, x_5, x_6) = \sin(\pi x_1) \cdot \sin(\pi x_2) \cdot \sin(\pi x_3) + \sin(\pi x_4) \times \\ \times \sin(\pi x_5) \cdot \sin(\pi x_6) + \exp(-(x_1^2 + x_2^2)) + \exp(-(x_3^2 + 6x_3x_4 + 10x_4^2))$$

при отсутствии помех измерений. Для этого использовались четыре популяции эволюционирующих нейронных сетей прямого распространения: МП, РБС, WaveNet (осуществляющей аппроксимацию (3) при выборе в качестве БФ вейвлет-функций) и СМАС. Каждая популяция состояла из 150 особей. В данном эксперименте использовался лишь один критерий — точность аппроксимации функции. Результаты работы коэволюционного метода на основе конкуренции приведены на рис. 6. Здесь показана точность аппроксимации заданной функции наилучшей сетью на каждой эпохе эволюционного процесса. Как видно из рисунка, наилучшую точность для данной задачи на последних этапах эволюции дает МП. Следует отметить, что одним из преимуществ коэволюционного подхода является то, что в любой момент эволюции можно использовать наилучшую архитектуру нейронной сети.




Рис. 6

Эксперимент 3. Решалась задача коэволюционной аппроксимации многомерной нелинейной функции, описываемой уравнением (11) при наличии помех измерений с различными типами распределения — равномерным, нормальным, Лапласа и Релея. В отличие от предыдущего эксперимента, входные сигналы и желаемые выходные предварительно подавались на ЭШАЭ. Таким образом, в процессе эксперимента происходила конкурентная борьба между популяциями сетей-аппроксиматоров за право решать задачу аппроксимации функции, в которой учитывались такие параметры, как время реакции сети, объем требуемой памяти для хранения весовых параметров и точность аппроксимации. Кроме того, происходила кооперация по принципу комменсализма между популяцией ЭШАЭ и популяциями сетей-аппроксиматоров. Результаты эксперимента приведены на рис. 7. Здесь показан график изменения фитнес-функции сети победителя на каждом шаге эволюции для различных типов помех.




Рис. 7

Заключение

Использование нейроэволюционного подхода, сочетающего ИНС и эволюционные вычисления для решения задачи аппроксимации многомерных функций, является достаточно универсальным и весьма эффективным при наличии помех. Как показали результаты экспериментов, нейроэволюционный подход к аппроксимации функций, основанный на принципах сотрудничества и конкуренции нейросетевых популяций, позволяет весьма эффективно бороться с любыми типами возможных помех, что свидетельствует о высокой эффективности рассматриваемого подхода. Однако данному подходу присущи и недостатки, являющиеся общими для всех эволюционных алгоритмов, в частности, существует проблема выбора операторов скрещивания, мутации и т.д. Следует также отметить, что несмотря на хорошую распараллеливаемость коэволюционных алгоритмов, остается проблема избыточности вычислений при их использовании. Кроме того, в настоящее время не разработаны практические рекомендации по выбору оптимального размера популяций, что может быть предметом дальнейших исследований.

О.Г. Руденко, О.О. Безсонов

НЕЙРОМЕРЕЖЕВА АПРОКСИМАЦІЯ НЕЛІНІЙНИХ ЗАШУМЛЕНИХ ФУНКЦІЙ НА ОСНОВІ КОЕВОЛЮЦІЙНОГО КООПЕРАТИВНО-КОНКУРЕНТНОГО ПІДХОДУ

Запропоновано еволюційний алгоритм апроксимації нелінійних зашумлених функцій, заснований на коєволюційних моделях кооперації та конкуренції. Алгоритм реалізує середовище, що сприяє співпраці та конкуренції популяцій, в яких кожна особа є нейромережею прямого розповсюдження, що вирішує специфічну задачу. Для апроксимації досліджуваної функції пропонується використовувати популяції універсальних апроксиматорів, а для боротьби з можливими завадами — ввести додаткову популяцію автоенкодерів, що усувають завади. Наведено результати імітаційного моделювання, що підтверджують ефективність запропонованого методу апроксимації нелінійних зашумлених функцій.

O.G. Rudenko, A.A. Bezsonov

NEURAL NETWORK APPROXIMATION OF NONLINEAR NOISY FUNCTION, BASED ON COEVOLUTIONARY COOPERATIVE-COMPETITIVE APPROACH

An evolutionary algorithm is proposed for approximating nonlinear noisy functions, based on coevolutionary models of cooperation and competition. The proposed algorithm implements an environment that is conducive to cooperation and competition of populations in which each individual is a feedforward neural network that solves a specific problem. It is proposed to use populations of universal approximators for the studied function approximation, and to introduce an additional population of denoising autoencoders for reduction of possible noise. The simulation results confirm the effectiveness of the proposed method of nonlinear noisy functions approximation.

1. Хайкин С. Нейронные сети: полный курс. — М. : Вильямс, 2006. — 1104 с.
2. Бодянский Е.В., Руденко О.Г. Искусственные нейронные сети: архитектура, обучение, применение. — Харьков : ТЕЛЕТЕХ, 2004. — 372 с.
3. Руденко О.Г., Безсонов А.А. Идентификация нелинейных нестационарных объектов с помощью эволюционирующей радиально-базисной сети // Международный научно-технический журнал «Проблемы управления и информатики». — 2012. — № 4. — С. 5–14.
4. Руденко О.Г., Безсонов А.А. Нейронная сеть СМАС и ее применение в задачах идентификации и управления нелинейными динамическими объектами // Кибернетика и системный анализ. — 2005. — № 5. — С. 16–28.
5. Руденко О.Г., Безсонов А.А. О выборе схемы кодирования информации в нейронной сети СМАС // Там же. — 2007. — № 3. — С. 18–25.
6. Yao X. Evolving artificial neural networks // Proc. of the IEEE. — 1999. — **87**, N 9. — P. 1423–1447.
7. Yao X., Lin Y. A new evolutionary system for evolving artificial neural networks // IEEE Trans. on Neural Networks. — 1997. — **3**, N 3. — P. 694–713.
8. Руденко О.Г., Безсонов А.А. Робастная многокритериальная идентификация нелинейных объектов на основе эволюционирующих радиально-базисных сетей // Международный научно-технический журнал «Проблемы управления и информатики». — 2013. — № 5. — С. 22–32.
9. Безсонов А.А., Руденко С.О. Идентификация нелинейных нестационарных объектов с помощью эволюционного многослойного персептрона // Вестник Херсонского национального технического университета. — 2012. — № 1(44). — С. 117–121.
10. Безсонов А.А., Руденко С.О. Робастная многокритериальная идентификация нелинейных объектов с помощью сетей прямого распространения // Там же. — 2013. — № 1(46). — С. 142–145.

11. *Auger A., Hansen N.* Theory of evolution strategies: A new perspective // Theory of randomized search heuristics: foundations and recent developments. — Singapore : World Scientific Publishing, 2011. — P. 289–325.
12. *Vincent P., Larochelle H., Bengio Y., Manzagol P.A.* Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion // The Journal of Machine Learning Research. — 2010 — **11**. — P. 3371–3408.

Получено 25.10.2017