



МОДИФИЦИРОВАННЫЙ МЕТОД Ψ -ПРЕОБРАЗОВАНИЯ ДЛЯ ОБУЧЕНИЯ СЕТЕЙ НА БАЗЕ ГИБРИДНЫХ НЕЙРОПОДОБНЫХ ЭЛЕМЕНТОВ

Попов С.В., Шкуро К.А.

Харьковский национальный университет радиоэлектроники

Оптимизация архитектуры и параметров сетей на базе гибридных нейроподобных элементов является актуальной задачей современной теории вычислительного интеллекта. При этом качество работы эволюционного метода оптимизации архитектуры сети [1, 2] коренным образом зависит от качества ее параметрической настройки (обучения). Низкокачественный алгоритм обучения может полностью свести на нет все усилия по поиску оптимальной архитектуры, поэтому методам параметрической оптимизации необходимо уделить особое внимание. Основные сложности обучения сети возникают вследствие нескольких причин: высокая размерность оптимизационной задачи; сложность рельефа критерия обучения (наличие множества локальных и глобальных экстремумов, плато и оврагов); разрывы производных критерия обучения (в частности, при использовании треугольных функций принадлежности в нелинейных синапсах).

В силу перечисленных причин возникает необходимость создания новых методов обучения, которые были бы эффективны, несмотря на специфику сетей на базе гибридных нейроподобных элементов. В качестве основы для решения этой задачи используем известный метод Ψ -преобразования [3], обладающий рядом замечательных свойств, а именно: способностью находить глобальный экстремум функции и отсутствием требования дифференцируемости функции. Однако, применение метода Ψ -преобразования становится невозможным, если гиперповерхность критерия обучения сети обладает каким-либо видом симметрии: перестановочной и/или знаковой. Для исключения подобной ситуации предлагается модифицированный метод Ψ -преобразования.

Целью обучения является минимизация критерия $E = \sum_{k=1}^N \|e(k)\|^2$ по синаптическим весам $w_i, (i=1, \dots, N_p)$. Первым шагом для этого является определение границ множества D , на котором определена функция $E(w)$, т. е. необходимо установить границы интервалов $[w_1^{\min}, w_1^{\max}]$, ..., $[w_{N_p}^{\min}, w_{N_p}^{\max}]$ для генерации случайных чисел. Затем генерируется S наборов равномерно распределенных в вышеуказанных интервалах случайных чисел, образующие вектора синаптических весов сети $w^v, (v=1, \dots, S)$. Для исключения эквивалентных областей в пространстве параметров сети необходимо проанализировать ее архитектуру и определить все скрытые элементы сети, создающие знаковую симметрию, а также все группы эквивалентных элементов сети, создающие перестановочную симметрию. После чего определяются ограничения вида $w_{10}^{[s]} < w_{20}^{[s]} < \dots < w_{h^{[s]}0}^{[s]}$, где s – номер группы эквивалентных элементов сети и $w_{j0} \geq 0$, где j – номер скрытого элемента сети, которые выделяют единственную эквивалентную область в пространстве параметров сети.

Каждый вектор w^v проверяется на принадлежность к этой области и в случае нахождения за ее пределами w^v заменяется на его проекцию внутри этой области \bar{w}^v , которая находится путем изменения знака и перестановки элементов внутри вектора w^v в соответствии с заданными выше ограничениями. После этого в каждой точке w^v вычисляется значение функции $E(w^v)$ и определяются нижняя E_{\min} и верхняя E_{\max} границы изменения функции $E(w)$ на D . Интервал $[E_{\min}, E_{\max}]$ разбивается на T равных частей и вычисляются значения $\zeta_\tau = E_{\min} + \tau \frac{E_{\max} - E_{\min}}{T}, (\tau = 1, \dots, T)$. Для каждого τ



Секция 1. Информационные системы и технологии: опыт создания, модели, инструменты, проблемы

вычисляется количество случаев s_τ , где $E(w) \leq \zeta_\tau$, и определяется статистическая вероятность, которая является оценкой $\bar{\Psi}(\zeta_\tau)$. По полученным точкам тем или иным способом строится аппроксимирующая кривая $\bar{\Psi}(\zeta)$ и путем ее экстраполяции находится значение $\hat{\zeta}^*$, при котором $\bar{\Psi}(\zeta) = 0$, являющееся оценкой глобального минимума функции $E(w)$.

Поскольку в задаче обучения сети на базе гибридных нейроподобных элементов важно не само значение экстремума, а его координаты, определим их на основе полученной оценки $\hat{\zeta}^*$. Для этого на основе данных, полученных в ходе статистических испытаний для построения функции $\bar{\Psi}(\zeta)$, строится функция $\bar{w}(\zeta)$, где $\bar{w}_i(\zeta)$ – среднее значение тех реализаций w_i , где $E(w_1, w_2, \dots, w_{N_p}) \leq \zeta$. Функции $\bar{w}_i(\zeta)$ также аппроксимируются и по ним путем подстановки $\hat{\zeta}^*$ вычисляется оценка координат глобального экстремума \hat{w}^* .

Для проверки достоверности полученной оценки значение \hat{w}^* подставляется в функцию $E(w)$ и значение $E(\hat{w}^*)$ сравнивается с оценкой $\hat{\zeta}^*$. В случае расхождения полученных оценок более, чем на заданную погрешность δ , необходимо уточнение функций $\bar{\Psi}(\zeta)$ и $\bar{w}(\zeta)$, для чего проводится еще S статистических испытаний на множестве D . После чего все оценки пересчитываются с учетом общего числа статистических испытаний $2S$.

Если же $|E(\hat{w}^*) - \hat{\zeta}^*| \leq \delta$, то оценка координат глобального экстремума выполнена верно, однако это еще не гарантирует равенство оценки \hat{w}^* и истинных координат w^* , поскольку все проделанные операции носят статистический характер и получаемые оценки сходятся по вероятности к истинным значениям только при $S \rightarrow \infty$, что требует слишком больших вычислительных затрат. Поэтому для уточнения координат целесообразно, используя в качестве стартовой точки полученную оценку, применить некоторый метод локального поиска, в частности для этого хорошо подходит комплекс-метод Бокса [4]. При этом полагается, что оценка \hat{w}^* находится в области притяжения глобального экстремума и эта область выпукла, следовательно, где бы ни располагалась оценка \hat{w}^* относительно истинного значения w^* , это значение возможно отыскать методом локального поиска.

Предложенный метод обучения является достаточно универсальным и может применяться ко многим популярным архитектурам искусственных нейронных и нейро-фаззи сетей, а частности, многослойному перцептрону, сети с конечной импульсной характеристикой и другим, являющимся частными случаями сети на базе гибридных нейроподобных элементов.

1. Popov S. Evolutionary Optimized Network of Hybrid Neuron-Like Units / Popov S., Shkuro K. // Neural Networks and Artificial Intelligence (ICNNAI-2012): proceedings of the 7th International Conference (Minsk, Belarus, 10-12 October, 2012). – Minsk: BSUIR, 2012 – P. 32-35.

2. Гибридный метод прогнозирования гололедной нагрузки на ВЛ / Попов С.В., Шкуро К.А., Черемисин Н.М., Пархоменко О.В. // Энергетика и электрификация. – 2013. – №5. – С. 33-38.

3. Чичинадзе В.К. Решение невыпуклых нелинейных задач оптимизации / Чичинадзе В.К. – М.: Наука, 1983. – 256 с.

4. Химмельблау Д. Прикладное нелинейное программирование / Химмельблау Д. – М.: Мир, 1975. – 536 с.