

ПРИМЕНЕНИЕ ТЕОРИИ ВЕЙВЛЕТ-ПРЕОБРАЗОВАНИЙ В РЕШЕНИИ ЗАДАЧИ ПОИСКА ГЛОБАЛЬНОГО МИНИМУМА ФУНКЦИИ ОШИБКИ

Марьина О. А.

ГОУВПО «Мордовский государственный университет им. Н. П. Огарева», г. Саранск
Тел.: 89276446987, e-mail: fd_oxy@mail.ru

Аннотация. В статье рассматривается подход к моделированию композиционных материалов с использованием нейросетевых технологий. Оцениваются методы обучения многослойного персептрона, и предлагается применение вейвлет-преобразования в качестве варианта решения задачи поиска глобального аттрактора функции энергии.

Ключевые понятия: многослойный персептрон, обучение, метод градиентного спуска, функция ошибки, вейвлет-преобразование.

В результате исследования в разных областях естественных наук происходит быстрое развитие науки о материалах. Благодаря техническому прогрессу в последние годы были получены совершенно новые материалы с заранее заданными свойствами, разработана технология их производства и методы расчета.

Особое место занимают композиционные материалы, обладающие комплексом различных свойств, рациональное сочетание которых позволяет получать оптимальные конструкции. Любое реальное вещество можно рассматривать как многокомпонентную систему, являющуюся системой веществ. В частности к многокомпонентным системам относят и композиционные материалы.

В настоящее время часто требуется спрогнозировать поведение и свойства многокомпонентных систем, которые еще не существуют в природе. Развивается подход к моделированию многокомпонентных систем с использованием нейросетевых технологий. Преимущество применения искусственных нейронных сетей – возможность работы с неточными данными и нелинейность моделей, что позволяет выиграть в качестве и во времени по сравнению со стандартными методами. Нейросетевой подход особенно эффективен в задачах экспертной оценки [1].

Для поиска закономерностей и классификации образов широко используется многослойная полносвязанная нейронная сеть прямого распространения. Обучение многослойного персептрона представляет собой процесс настройки архитектуры сети и весов синаптических связей.

Наиболее успешным методом обучения сети является метод обратного распространения ошибки – итеративный градиентный алгоритм обучения многослойного персептрона. Основная идея состоит в распространении сигналов ошибки от выходов сети к ее входам, в направлении, обратном прямому распространению сигналов в обычном режиме работы.

Реализовывается стохастический градиентный спуск, то есть подправляются веса после каждого тестового примера. Для узлов определяется поправка, и это зависит от слоя, к которому относится узел [2, 3]:

$$\Delta w_{ij} = -\eta \cdot \frac{\partial E}{\partial w_{ij}},$$

где η – скорость обучения.

Несмотря на многочисленные успешные применения данный алгоритм не лишён недостатков. Обучение может происходить достаточно долго. В сложных задачах сеть может и вообще не обучиться. Одна из причин – возможность попадания алгоритма в локальный минимум, когда рядом имеется гораздо более глубокий минимум (рис. 1).




Рис. 1. Метод градиентного спуска при минимизации ошибки сети

Для избегания подобной ситуации используются специальные приемы, позволяющие «выбить» найденное решение из локального экстремума. Существуют современные алгоритмы второго порядка, которые на многих задачах работают существенно быстрее (иногда на порядок). Разработаны также эвристические модификации этого алгоритма, хорошо работающие для определенных классов задач.

При обучении каждым из этих методов нейронная сеть считается наилучшим образом натренированной, если был найден глобальный минимум функции ошибок. Для определения его расположения требуется разное время. Представляется возможным ускорить процесс обучения нейронной сети и, в первую очередь, сделать результат задачи поиска глобального минимума более точным, если подвергнуть функцию ошибки быстрому вейвлет-преобразованию.

Вейвлет-преобразование локализует решение на определенном интервале оцениваемого значения. Рассмотрим поверхность функции ошибки, построенную в базисе вес – смещение – ошибка (рис. 2).




Рис. 2. Поверхность функции ошибки

Возьмем сечения этой поверхности для проведения вейвлет-анализа. Анализируя полученные результаты, в первом приближении можно сказать о том, что уже на втором и третьем уровнях разложения заметны особенности, которые соответствуют области минимума функции. Светлые области характеризуют большое значение коэффициентов вейвлет-разложения.

К сожалению, нет определенного критерия выбора вейвлет-функции для решения конкретной задачи. Поэтому необходимо использовать различные вейвлет-преобразования и анализировать полученные результаты. Дальнейшее рассмотрение вопроса применимости теории вейвлет-преобразований к решению поставленной задачи требует большого экспериментального опыта. Возможно исследование поверхности функции ошибки с использованием двумерного вейвлет-анализа.




Рис.3. Сечение поверхность функции ошибки плоскостью $\text{bias} = -4$

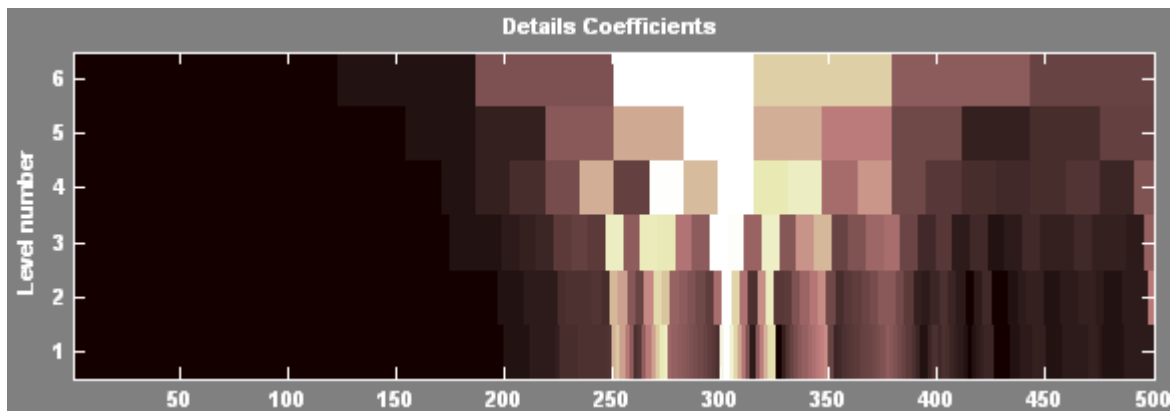


Рис.4. Разложение сечения функции ошибки под действием вейвлет-функции Добеши (коэффициент равен 2, уровень 6)




Рис.5. Разложение сечения функции ошибки под действием вейвлет-функции Хаара (уровень 7)




Рис.6. Сечение поверхность функции ошибки плоскостью $\text{bias} = -2$




Рис.7. Разложение сечения функции ошибки под действием вейвлет-функции Хаара (коэффициент равен 4, уровень 4)

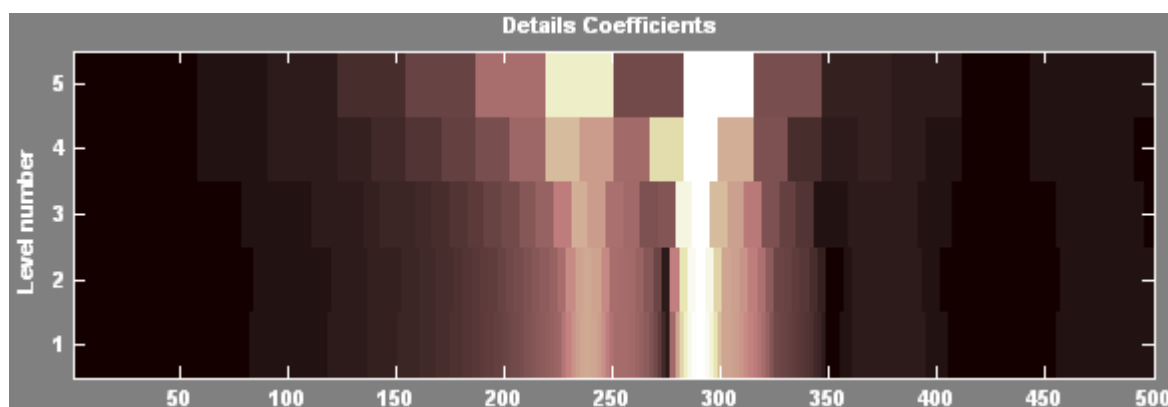


Рис.8. Разложение сечения функции ошибки под действием вейвлет-функции Хаара (уровень 5)

Литература

1. Кудашкин С.В., Черкасов В.Д., Федосин С.А., Юркин Ю.В. Применение искусственных нейронных сетей для моделирования многокомпонентных систем. Информационные технологии моделирования и управления, №9, 2007 г.
2. Даниил Кальченко, «КомпьютерПресс» №1, январь 2005 г.:
http://www.neuroproject.ru/articles_dak_nn.php
3. Уоссермен Ф. Нейрокомпьютерная техника: теория и практика / перевод с англ. Ю.А. Зуев, В.А. Точенов. 1992. – 118 с.