

ЭКСПЕРИМЕНТАЛЬНЫЙ ДАТЧИК ВОЛНОВОГО ФРОНТА ДЛЯ АСТРОНОМИЧЕСКИХ ПРИЛОЖЕНИЙ, РАБОТАЮЩИЙ ПО АЛГОРИТМУ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ

Е.А. Копылов, В.В. Лавринов, М.В. Туев

EXPERIMENTAL WAVE FRONT SENSOR FOR ASTRONOMICAL APPLICATIONS ON THE BASE OF NEURAL NET ALGORITHM

Е.А. Kopylov, V.V. Lavrinov, M.V. Tuev

Приведены первые результаты исследований по разработке датчика волнового фронта на основе алгоритма искусственной нейронной сети, распознающей аберрации волнового фронта. Определен оптимальный объем выборки кадров распределения интенсивности для обучения искусственной нейронной сети.

We present first results of development of wave front sensor on the base of artificial neural network algorithm are. Optimal volume of the sample of intensity distribution frames for training the artificial neural network has been determined.

Необходимость осуществления фазовой коррекции в реальном масштабе времени предъявляет жесткие технологические требования к одному из основных конструктивных элементов адаптивных систем – датчику волнового фронта (ДВФ). Основными являются высокое пространственное разрешение, большой динамический диапазон, высокое быстродействие. Наличие мелкомасштабных и крупномасштабных искажений предъявляет повышенные требования к динамическому диапазону ДВФ. С учетом этих требований авторы разрабатывают ДВФ, работающий по алгоритму искусственной нейронной сети (ИНС). Выбор структуры ИНС осуществляется в соответствии с особенностями и сложностью задач, для решения некоторых уже существуют оптимальные на сегодняшний день конфигурации. Если же задача не может быть сведена ни к одному из известных типов, разработчику приходится решать проблему синтеза новой конфигурации. При этом он руководствуется следующими принципами [Антошкин и др., 2010]: 1) возможности сети возрастают с увеличением числа слоев сети и числа нейронов в них; 2) введение обратных связей поднимает вопрос о так называемой динамической устойчивости сети; 3) сложность алгоритмов функционирования сети также способствует усилению мощи ИНС. Разработка критериев для ИНС – одна из задач, решаемая в данной работе.

Входные данные для ИНС являются обучающей выборкой (ОВ) и контрольной выборкой (КВ). Именно от состава, полноты, качества ОВ существенно зависит время обучения ИНС и достоверность получаемых моделей.

В условиях работы АОС входными данными ИНС являются массивы суммарной интенсивности на элементе разбиения кадра, полученные камерой в эксперименте. Для построения ОВ использовалась модель распространения лазерного излучения в случайно-неоднородной среде [Уоссерман, 1992], где вместо случайного фазового экрана использовалось распределение фазы, задаваемое одним из шести первых полиномов Цернике. Гауссов пучок после прохождения такого экрана формирует распределение интенсивности, характерное для определенных аббераций волнового фронта. ИНС в качестве входных данных использует набор суммарных интен-

сивностей в определенном количестве зон, задаваемых на распределении интенсивности. Для определения аббераций, соответствующих заданному распределению интенсивности, использовался ДВФ Шэка–Гартмана. Таким образом, для обучения сети генерировался набор распределений интенсивности в пучке, соответствующих измеренным абберациям фазы волнового фронта, в виде набора коэффициентов при полиномах Цернике.

Алгоритм обучения – это набор формул, который позволяет по вектору ошибки вычислить требуемые поправки для весов сети. Одну и ту же ОВ мы можем предъявлять сети много раз. После этого веса сети стабилизируются, сеть начинает давать правильные ответы на примеры их КВ. В процессе обучения сети функции ошибки (чаще всего, сумма квадратов ошибки по всем выходам) постепенно уменьшается. Когда функция ошибки достигает нуля или приемлемого малого уровня, обучение останавливают, а полученную ИНС считают тренированной и готовой к применению на новых данных. Процесс обучения ИНС показан на рис. 1.

Математически процесс обучения можно описать следующим образом [Антошкин и др., 2010]. В процессе функционирования ИНС формирует выходной сигнал Y в соответствии с входным сигналом X , реализуя некоторую функцию $Y=G(X)$. Если архитектура задана, вид функции G определяется значениями синаптических весов и смещений сети. Пусть решением некоторой задачи является функция $Y=F(X)$, заданная парами входных/выходных данных $(X^1, Y^1), (X^2, Y^2), \dots, (X^N, Y^N)$, для которых $Y^k=F(X^k), k=1, 2, \dots, N$. Обучение состоит в поиске (синтезе) функции G , близкой



Рис. 1. Алгоритм процесса обучения искусственной нейронной сети.

F в смысле некоторой функции ошибки E . Если выбраны множество обучающих примеров – пар (X^k, Y^k) , где $k=1, 2, \dots, N$ и способ вычисления функции ошибки E , то обучение нейронной сети превращается в задачу многомерной оптимизации, имеющую большую размерность. При этом, поскольку функция E может иметь произвольный вид, обучение в общем случае – многоэкстремальная невыпуклая задача оптимизации. Обзор показал, что в качестве подавляющего большинства алгоритмов обучения ИНС для задач прогнозирования искажения ВФ выступает алгоритм обратного распространения ошибки (ОРО) Румелхарта, подробно описанный в работе [Уоссерман, 1992]. Рассмотрим идею одного из самых распространенных алгоритмов обучения [Riedmiller, Braun, 1992] – алгоритма Румелхарта. Это итеративный градиентный алгоритм обучения, который используется с целью минимизации среднеквадратичного отклонения текущего выхода и желаемого выхода многослойных нейронных сетей. Пошаговое описание алгоритма следующее: 1) весам сети присваиваются небольшие начальные значения; 2) выбирается очередная обучающая пара (X, Y) из обучающего множества и вектор X подается на вход сети; 3) вычисляется выход сети; 4) вычисляется разность между требуемым и вычисленным выходами сети; 5) веса сети корректируются так, чтобы минимизировать ошибку; 6) шаги 2)–5) повторяются для каждой пары обучающегося множества до тех пор, пока ошибка на всем множестве не достигнет приемлемой величины.

Описанный алгоритм является классическим, на сегодняшний день существует множество его оптимизированных форм. Для случая задач адаптивной оптики, когда на сеть подается большой массив однотипных данных (количество входных нейронов более 10), уместно использовать так называемый улучшенный эластичный метод ОРО (RPROP), описанный в [Калан, 2001; Крючин, 2009]. В отличие от стандартного метода ОРО, метод RPROP использует только знаки частных производных для подстройки весовых коэффициентов, а коррекция весов происходит после предъявления всей ОБ. Кроме того, данный алгоритм является распараллеливаемым [Крючин, 2009], что существенно ускоряет процесс обучения ИНС. В качестве обучающих выборок выступают записи (размер записи составляет 500 кадров) распределения интенсивности. Типичный кадр распределения интенсивности по кадру показан на рис. 2.

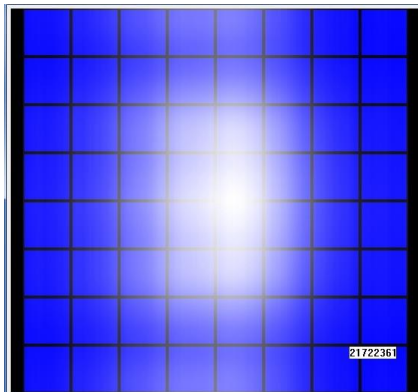


Рис. 2. Пример распределения интенсивности по кадру.

Имеется ИНС с двумя скрытыми слоями, которую необходимо обучить (с использованием метода RPROP) вычислению значения коэффициентов при полиномах Цернике на основе имеющихся кадров с камеры. Для этого необходимо найти оптимальный размер обучающей выборки и величину тренда. Вначале ИНС обучалась 25-кадровым набором. После обучения ИНС (если оно состоялось) проверялась ее способность к вычислению коэффициентов на контрольной выборке и вычислялось среднеквадратичное отклонение координат всех центровидов. Затем увеличивали количество кадров ОБ с шагом 25. Такое увеличение идет до 475 кадров, чтобы оставалось 25 кадров на проверку. Эксперимент показал, что, начиная с обучающей выборки размером в 100 кадров, ИНС дает на выходе удовлетворительные (отличающиеся от проверочных на ± 0.05) значения коэффициентов при полиномах Цернике. Следующим этапом работы является обучение ИНС ДВФ на экспериментально измеренных распределениях интенсивности излучения, а также излучения, прошедшего атмосферные искажения на открытой трассе. В качестве обучающего элемента планируется использовать ДВФ Шека–Гартмана.

Работа выполнена при финансовой поддержке: РФФИ в рамках научного проекта № 12-08-31111 мол_а; Министерства образования и науки Российской Федерации (соглашение 8703); фонда Дмитрия Зимина «Династия».

СПИСОК ЛИТЕРАТУРЫ

- Антошкин Л.В., Лавринов В.В., Лавринова Л.Н. и др. Особенности опережающей коррекции турбулентных искажений по измерениям датчика Шека–Гартмана // Оптика атмосферы и океана. 2010. Т. 23, № 11. С. 1042–1047.
- Калан Р. Основные концепции нейронных сетей: Пер. с англ. М.: Издательский дом «Вильямс», 2001. 291 с.
- Крючин О.В. Обучение искусственной нейронной сети при помощи распараллеленных градиентных алгоритмов RPROP, QuickProp и метода наискорейшего спуска: Автореф. дис. канд. тех. наук // Тамбовский государственный университет им. Державина. Тамбов. 2009. 16 с.
- Уоссерман Ф. Нейрокомпьютерная техника: теория и практика. М.: Мир, 1992. 184 с.
- Riedmiller M., Braun H. A direct adaptive method for faster backpropagation learning: the RPROP algorithm. Technical Report // Karlsruhe: University Karlsruhe. 1992. P. 115–121.

Институт оптики атмосферы им. В.Е. Зуева СО РАН, Томск, Россия