

Бродовский Максим Алексеевич

**ОБЗОР НЕЙРОННЫХ СЕТЕЙ В РАКУРСЕ ЗАДАЧИ ПРОГНОЗИРОВАНИЯ ПОТРЕБЛЕНИЯ
ЭЛЕКТРОЭНЕРГИИ**

Адрес статьи: www.gramota.net/materials/1/2009/12-1/2.html

Статья опубликована в авторской редакции и отражает точку зрения автора(ов) по рассматриваемому вопросу.

Источник

Альманах современной науки и образования

Тамбов: Грамота, 2009. № 12 (31): в 2-х ч. Ч. I. С. 10-13. ISSN 1993-5552.

Адрес журнала: www.gramota.net/editions/1.html

Содержание данного номера журнала: www.gramota.net/materials/1/2009/12-1/

© Издательство "Грамота"

Информация о возможности публикации статей в журнале размещена на Интернет сайте издательства: www.gramota.net

Вопросы, связанные с публикациями научных материалов, редакция просит направлять на адрес: almanac@gramota.net

Кондукторы монтируются на весь ряд стеновых панелей:

- по завершению монтажа кондукторов следует приступить к монтажу стеновых панелей следующего ряда;

- для размещения технологического оборудования внутри башенного сооружения мы предлагаем конструкцию металлических консолей, которые могут крепиться к стеновым панелям, как в процессе, так и по завершению монтажа остова башни.




Рис. 2. Принципиальная схема консоли для технологического оборудования: 1 - панель; 2 - траверса; 3 - подвесная люлька; 4 - временное ограждение; 5 - консоль; 6 - закладные детали в панели; 7 - консоли крепления основной консоли

Конструкции консолей предварительно могут собираться на стенде укрупнительной сборки или на заводе металлоконструкций и отправляться в полной готовности или отдельными разрезными элементами (в зависимости от габаритов) на строительную площадку.

ОБЗОР НЕЙРОННЫХ СЕТЕЙ В РАКУРСЕ ЗАДАЧИ ПРОГНОЗИРОВАНИЯ ПОТРЕБЛЕНИЯ ЭЛЕКТРОЭНЕРГИИ

*Бродовский Максим Алексеевич
Ивановский государственный энергетический университет*

В наше время многие отрасли рынка являются динамически изменяющимися. Поэтому в компаниях из этих отраслей зачастую имеются специалисты, которые занимаются прогнозированием каких-либо событий. Обычно процесс прогнозирования не автоматизирован и специалистам приходится осуществлять большую часть процесса вручную. Нашей задачей является автоматизация процесса прогнозирования, что позволит облегчить труд такого специалиста или вообще, в случае создания стабильной системы прогнозирования, заменить его. Все это подкрепляется еще и наличием реального практического применения данной задачи. Вследствие недавних реформ в сфере энергетики на территории Российской Федерации были образованы энергосбытовые компании, целью которых является покупка электроэнергии у государства и реализация ее среди пользователей. Одной из основных их задач являлась определение объемов энергии, которые будут потреблены, поскольку сначала осуществлялся выкуп необходимой электроэнергии у государства, а уже потом эта энергия продавалась пользователям. Наибольшие проблемы с определением объемов потребления возникают с физическими лицами, поскольку юридические лица заранее подают заявку с указанием требуе-

мого объема электроэнергии. Поэтому нашей основной задачей является прогнозирование потребления электроэнергии физическими лицами с точностью до 2% (данная точностью обусловлена нюансами процесса закупки и продажи электроэнергии). Для прогнозирования были представлены следующие данные: температура воздуха, осадки, облачность, продолжительность светового дня и характер дня (будни, выходные и праздники). Данные за предыдущий день поступают в 11:00 и до 13:00 необходимо сделать прогноз на следующий день, причем в течение этого времени (11:00-13:00) может осуществляться корректировка данных.

В качестве метода прогнозирования были выбраны нейронные сети, поскольку их структура позволяет осуществить настройку для получения результатов с необходимой точностью. Для выбора подходящей для данной задачи архитектуры нейронной сети были изучены уже известные нейронные сети. По теоретическим данным (не прибегая к практическому применению) был проведен анализ моделей нейронных сетей и высказаны гипотезы о том, насколько они подходят для решения поставленной задачи. Для этого сначала были проанализированы входные данные. В результате выяснилось, что параметр осадки мало влияет на потребление электроэнергии, поскольку интенсивность осадков не указывалась, а предлагались данные только о виде осадков (дождь, снег). Поэтому данный параметр решено было не учитывать. Всего же для обучающего множества решено было выбрать данные за один год. Поскольку эти данные представляют довольно большой массив, необходимо чтобы размер нейронной сети не зависел от размера обучающего множества.

Рассмотрим наиболее известные модели нейронных сетей. Мы не стали рассматривать сети, которые нам изначально не подходили: простейшие сети с одним слоем нейронов и сложные сети (например, когнитроны и неокогнитроны). Первые являются слишком примитивными и не позволяют нам добиться нужной точности прогнозирования, а вторые являются наоборот слишком сложными, и их реализация на нашем оборудовании пока не может быть осуществлена.

Сети обратного распространения. На возможность построения нейронных сетей с несколькими слоями указал Ф. Розенблатт, однако проблема обучения не была решена. Межнейронные синаптические связи такой сети устроены таким образом, что каждый нейрон на данном уровне иерархии принимает и обрабатывает сигналы от каждого нейрона более низкого уровня. Таким образом, в данной сети имеется выделенное направление распространения нейроимпульсов - от входного слоя через один (или несколько) скрытых слоев к выходному слою нейронов. Алгоритм обратного распространения можно разделить на два этапа: проход вперед (сигнал распространяется по сети от входа к выходу) и обратный проход (вычисляемый сигнал ошибки распространяется обратно по сети и используется для подстройки весов). По существу он представляет собой минимизационный метод градиентного спуска [Лю, 2005, с. 55]. Преимущество данной модели состоит в ее относительной универсальности, поскольку с помощью нее можно решать широкий класс задач. Однако недостатком данной модели можно считать длительное обучение.

При решении нашей задачи данная модель может быть полезна благодаря своей универсальности, но поскольку процесс обучения может занять длительное время, а сроки реализации модели ограничены, этот вариант нам подходит только в случае наличия достаточных вычислительных мощностей.

Сети встречного распространения. Во встречном распространении объединены два хорошо известных алгоритма: самоорганизующаяся карта Кохонена и звезда Гроссберга. В простейшей форме в слое Кохонена для каждого входного вектора один и только один нейрон Кохонена выдает на выходе логическую единицу, а все остальные выдают ноль. Самоорганизующаяся карта Кохонена является специальным случаем сети, обучающейся методом соревнования и представляет собой векторный квантователь [Комашинский, 2003, с. 23]. Слой Гроссберга функционирует в сходной манере. Его выход является взвешенной суммой выходов слоя Кохонена, образующих вектор. В данном случае вычисления очень просты. Фактически каждый нейрон слоя Гроссберга лишь выдает величину веса, который связывает этот нейрон с единственным ненулевым нейроном Кохонена.

Обучение слоя Кохонена является самообучением, протекающим без учителя. Слой Гроссберга обучается относительно просто. Входной вектор, являющийся выходом слоя Кохонена, подается на слой нейронов Гроссберга, и выходы слоя Гроссберга вычисляются как при нормальном функционировании. Далее, каждый вес корректируется только в том случае, если он соединен с нейроном Кохонена, имеющим ненулевой выход. Величина коррекции веса пропорциональна разности между весом и требуемым выходом нейрона Гроссберга, с которым этот вес соединен.

По своим возможностям сети встречного распространения превосходят возможности однослойных сетей, а время их обучения значительно сокращается по сравнению с обратным распространением. Однако встречное распространение не настолько общее, как обратное распространение.

Данная модель видится подходящей для нашей задачи. Здесь слой Кохонена позволяет сделать грубый прогноз (например, потребляется большой, средний или малый объем электроэнергии), а слой Гроссберга позволяет сделать прогноз более точным.

Сети с обратными связями. Основными примерами сетей с обратными связями являются сети Хопфилда и Хэмминга. Рассмотрим простейшую сеть Хопфилда. Она состоит из двух слоев: нулевого, который распределяет выходы сети обратно на входы, и первого, где каждый нейрон вычисляет взвешенную сумму своих входов, давая сигнал, который затем с помощью нелинейной функции преобразуется в выходной сигнал. В общем случае задачи, решаемые данной сетью можно сформулировать следующим образом. Имеется некоторый набор двоичных сигналов, которые считаются образцовыми. Сеть должна уметь из произвольного

неидеального сигнала, поданного на ее вход, выделить соответствующий образец или сделать вывод о том, что входные данные не соответствуют ни одному из образцов. Одним из важных свойств сети Хопфилда является то, что она способна ассоциативно узнавать образ по его небольшому фрагменту. Процесс обучения сети формирует зоны притяжения (аттракции) некоторых точек равновесия, соответствующих обучающим данным [Осовский, 2002, с. 178].

Если нет необходимости вывода образца в явном виде и достаточно получать номер образца, то можно использовать сеть Хэмминга. Данная сеть характеризуется, по сравнению с сетью Хопфилда, более экономным использованием памяти и меньшим объемом вычислений. Сеть состоит из двух слоев. Первый и второй слои имеют по одинаковое количество нейронов, которое соответствует числу образцов. Синапсы нейронов первого слоя соединены с входами сети. Нейроны второго слоя связаны между собой отрицательными обратными синаптическими связями. Единственный синапс с положительной обратной связью для каждого нейрона соединен с его же аксоном. Идея работы сети состоит в нахождении расстояния Хэмминга от тестируемого образа до всех образцов. Расстоянием Хэмминга называется число отличающихся битов в двух бинарных векторах. Сеть должна выбрать образец с минимальным расстоянием Хэмминга до неизвестного входного сигнала, в результате чего будет активизирован только один выход сети, соответствующий именно этому образцу.

В результате многочисленных экспериментов доказано, что рекуррентная сеть Хэмминга дает лучшие результаты, чем сеть Хопфилда, особенно в ситуациях, когда взаимосвязанные векторы x и y являются случайными [Там же, с. 187].

Обратные связи могут приводить к возникновению неустойчивостей. В нейронных сетях неустойчивость проявляется в блуждающей смене состояний нейронов, не приводящей к возникновению стационарных состояний.

Представленные модели сетей с обратными связями проводят общую классификацию, а, следовательно, и прогноз данных сетей является не достаточно точным. Для реализации же данной модели с необходимой точностью потребуется введение большого количества нейронов (поскольку, как уже оговаривалось выше, размер обучающего множества довольно велик), что приведет к увеличению времени обучения и требуемых ресурсов. Однако в случае некоторой модификации данной модели (например, добавление дополнительного слоя), она может оказаться полезной для нас.

Обобщение модели Хопфилда. Возможность забывания ненужной, лишней информации является одним из замечательных свойств биологической памяти. Идея приложения этого свойства к искусственной нейросети Хопфилда проста: при запоминании образов обучающей выборки вместе с ними запоминаются и ложные образы. Данные ложные образы необходимо удалить из памяти. Соответствующие алгоритмы получили название алгоритмов разобучения. Суть их сводится к следующему. На первой фазе происходит обучение сети по стандартному правилу Хебба. Память наполняется истинными образами и множеством ложной информации. На следующей фазе сети предъявляется некоторый случайный образ. Сеть эволюционирует к некоторому состоянию, которое при большом объеме обучающей выборки чаще всего оказывается ложным. Затем матрицу связей исправляют с целью удаления данного ложного состояния.

В данной обобщенной модели не решена приведенная выше проблема, поэтому вопрос о ее необходимости остается открытым.

Двунаправленная ассоциативная память. Модели ассоциативной памяти, рассмотренные на примерах сетей Хэмминга и Хопфилда, являются автоассоциативными (образ может быть завершен или исправлен, но не может быть ассоциирован с другим образом). Двунаправленная ассоциативная память (ДАП) является гетероассоциативной; входной вектор поступает на один набор нейронов, а соответствующий выходной вектор появляется на другом наборе нейронов. Сеть, реализующая модель ДАП состоит из двух слоев - по одному для каждого из образцов пары - и оба слоя соединяются двунаправленными связями (т.е. активность может передаваться по связям в обоих направлениях) [Каллан, 2001, с. 116]. Входной вектор обрабатывается матрицей весов сети, в результате чего вырабатывается вектор выходных сигналов нейронов. Выходной вектор затем обрабатывается транспонированной матрицей весов сети, которая вырабатывает новые выходные сигналы, представляющие собой новый входной вектор. Процесс повторяется до тех пор, пока сеть не достигнет стабильного состояния, в котором ни входной вектор, ни выходной вектор не изменяются. Для восстановления ассоциированного образа входной вектор или его часть кратковременно устанавливаются на выходах первого слоя. Затем входной вектор удаляется, и сеть приводится в стабильное состояние, вырабатывая ассоциированный вектор на выходе второго слоя. Далее этот вектор воздействует через транспонированную матрицу, воспроизводя воздействие исходного входного вектора на выходе слоя 1. Каждый такой цикл вызывает уточнение выходных векторов первого и второго слоя до тех пор, пока не будет достигнута точка стабильности в сети.

Данная модель также связана с реализацией ассоциативной памяти, которая позволяет проводить подробную классификацию только при введении большого количества нейронов, что значительно удлиняет процесс обучения и увеличивает объем требуемых ресурсов. Поэтому данная модель требует определенных модификаций.

Вероятностная нейронная сеть. В вероятностной сети образцы классифицируются на основе оценок их близости к соседним образцам [Каллан, 2001, с. 153]. Данная сеть в своем простейшем виде имеет три слоя:

входной, радиальный и выходной. Радиальные элементы берутся по одному на каждое обучающее наблюдение (элемент из обучающего множества). Каждый из них представляет гауссову функцию с центром в этом наблюдении. Каждому классу, по которому будет производиться классификация, соответствует один выходной элемент. Каждый такой элемент соединен со всеми радиальными элементами, относящимися к его классу, а со всеми остальными радиальными элементами он имеет нулевое соединение. Таким образом, выходной элемент просто складывает отклики всех элементов, принадлежащих к его классу. В основе этой сети лежит байесова статистика, в которой правильность модели оценивается по имеющимся достоверным данным.

Данная модель также представляется неподходящей для нас вследствие необходимости введения большого числа радиальных элементов, что обусловлено размером обучающего множества. Число нейронов в выходном слое также необходимо выбрать большим, поскольку для обеспечения необходимой точности требуется создание большого количества классов.

Задачей на следующем этапе является практический анализ данных моделей нейронных сетей. Реализовав данные модели нейронных сетей с помощью имеющегося программного обеспечения, необходимо спрогнозировать потребление электроэнергии и выбрать оптимальную модель сети на практике. После необходимо проанализировать получившиеся результаты с помощью математического аппарата, а именно с помощью статистических методов. На данном этапе необходимо определить характер получившихся в результате прогнозирования отклонений. Основной же целью работы является получение критериев отбора архитектуры нейронной сети, которые зависят от поставленной задачи.

Список литературы

1. **Каллан Р.** Основные концепции нейронных сетей / пер. с англ. и ред. А. Г. Сивака. М.: Издательский дом «Вильямс», 2001. 287 с.
2. **Комашинский В. И.** Нейронные сети и их применение в системах управления и связи / В. И. Комашинский, Д. А. Смирнов. М.: Горячая линия-Телеком, 2003. 94 с.
3. **Лю Б.** Теория и практика неопределенного программирования / пер. с англ. Ю. В. Тюменцева, Ю. Т. Каганова; под ред. Ю. В. Тюменцева. М.: БИНОМ. Лаборатория знаний, 2005. 416 с.
4. **Основы теории нейронных сетей** [Электронный ресурс]: курс лекций / Интернет университет информационных технологий; авт. курса Г. Э. Яхьева. URL: <http://www.intuit.ru/department/ds/neuronnets/1>
5. **Осовский С.** Нейронные сети для обработки информации / пер. с польского И. Д. Рудинского. М.: Финансы и статистика, 2002. 344 с.

ПАРАЛЛЕЛЬНАЯ СТРОЧНО ОРИЕНТИРОВАННАЯ СХЕМА (2,1)-МЕТОДА РЕШЕНИЯ ЖЕСТКИХ ЗАДАЧ

Ващенко Геннадий Васильевич

Сибирский государственный технологический университет, г. Красноярск

Представлены параллельная строчно ориентированная схема (2,1)-метода из класса (m, k) -методов численного решения начальной задачи для жестких систем обыкновенных дифференциальных уравнений первого порядка, а также параллельный алгоритм ориентированный на многопроцессорные вычислительные системы кластерной архитектуры с применением топологии полный граф и гиперкуб.

Введение

Во многих приложениях возникает необходимость численного решения задачи Коши для жестких систем обыкновенных дифференциальных уравнений. Стремление к более точному описанию физических процессов приводит к постоянному росту размерности и жесткости соответствующих задач. Одним из методов численного решения жестких задач являются (m, k) -методы [Новиков, Шитов, Шокин, 1988]. В работе представлены параллельная вычислительная схема (2,1)-метода и алгоритм, ориентированный на применение в многопроцессорных вычислительных системах кластерной архитектуры с применением топологии полный граф и гиперкуб. Основной подход при формировании параллельного алгоритма (2,1)-метода состоял в использовании декомпозиции на подзадачи и установлении взаимосвязи между ними [Воеводин, 2002], [Hendrickson, Kolda, 2002].

1. Последовательный (2,1)-метод

Рассматривается задача Коши для автономной системы обыкновенных дифференциальных уравнений первого порядка

$$y' = f(y), y(t_0) = y^0 \quad (1)$$

Для численного решения задачи (1) применяется (2,1) - метод из семейства (m, k) -методов, $(n + 1)$ -й шаг этого метода задается формулами

$$y^{(n+1)} = y^{(n)} + p_1 K_1^{(n)} + p_2 K_2^{(n)}, \quad (2)$$

$$D_n = E - ah_n f'_n, D_n K_1^{(n)} = h_n f_n, D_n K_2^{(n)} = K_1^{(n)}$$

Конкретный вид (2) определяется коэффициентами a , p_1 и p_2 [Новиков, 2008], [Новиков, 1997].

Для определенности зададимся некоторым отрезком $[t_0, T]$ и введем равномерную сетку $w_n = \{t_k; t_k = kh,$