



4. Деревья решений – CART математический аппарат [Электронный ресурс]. – <https://basegroup.ru/community/articles/math-cart-part1> (дата обращения 19.03.2018).

5. Воронцов, К.В. Математические методы обучения по прецедентам [Электронный ресурс]. – <http://www.ccas.ru/voron/download/SVM.pdf> (дата обращения 20.03.2018).

А.В. Сурков, В.Г. Литвинов

## АВТОМАТИЗИРОВАННАЯ СИСТЕМА МОНИТОРИНГА И ПРОГНОЗИРОВАНИЯ МЕТЕОРОЛОГИЧЕСКИХ ПОКАЗАТЕЛЕЙ

(Самарский университет)

В настоящее время искусственные нейронные сети используются во множестве сфер человеческой деятельности и показывают весьма впечатляющие результаты. Одной из задач, которую можно решать с помощью этого инструмента является предсказание погоды для разных временных промежутков. Конкретная задача интересна как с научной точки зрения, так и с коммерческой.

Существует несколько основных методов прогнозирования погоды:

1. Синоптический метод составления прогнозов погоды основан на анализе карт погоды. Сущность этого метода состоит в одновременном обзоре состояния атмосферы на обширной территории, позволяющем определить характер развития атмосферных процессов и дальнейшее наиболее вероятное изменение погодных условий в интересующем районе. Осуществляется такой обзор с помощью карт погоды, на которые наносятся данные метеорологических наблюдений на различных высотах, а также у поверхности земли, производимых одновременно по одной программе в различных точках земного шара. На основе подробного анализа этих карт синоптик определяет дальнейшие условия развития атмосферных процессов в определенный период времени и рассчитывает характеристики метеоэлементов – температуру, ветер, облачность, осадки и т.д.

2. Численные (гидродинамические) методы прогноза погоды основаны на математическом решении системы полных уравнений гидродинамики и получение прогностических полей давления, температуры на определенные промежутки времени. Точность численных прогнозов зависит от скорости расчета вычислительных систем, от количества и качества информации, поступающей с метеостанций. Чем больше данных, тем точнее расчет.

3. Статистические методы прогноза позволяют по прошлому и настоящему состоянию атмосферы спрогнозировать на определенный будущий период времени состояние погоды, т.е. предсказать изменения различных метеоэлементов в будущем. Часто выбирается комплексный подход – использование сразу нескольких частных методов прогноза одной и той же характеристики состояния атмосферы с целью выбора окончательной формулировки прогноза.



Одним из статистических методов прогнозирования погоды является применение искусственных нейронных сетей обученных на основе большого количества собранных в прошлом данных. Точность прогнозирования зависит от количества и качества статистики, а также от алгоритмов обучения и архитектуры нейронных сетей.

Данная работа посвящена созданию аппаратно-программного комплекса прогнозирования погодных условий. Для достижения этой цели требуется решить следующие задачи:

1. Создание аппаратного комплекса для сбора и обработки метеоданных.
2. Сбор достаточного количества метеорологических данных для обучения нейронных сетей.
3. Создание и обучение нейронной сети с использованием предварительно обработанных данных.

Принцип работы всей системы должен быть таким, что на некоторой местности, для которой будет строиться прогноз, заранее устанавливается устройство сбора метеоданных, которое начинает накапливать необходимую для первого прогноза информацию. Когда устройство соберет достаточное количество данных, оно должно в режиме реального времени строить краткосрочный прогноз погодных условий.

Разработанная аппаратная часть представляет собой два портативных устройства (рис. 1) под управлением микроконтроллеров. Одно служит для сбора, хранения и передачи метеоданных. Устройство включает в себя следующие датчики: барометрический датчик давления и датчик температуры (находится непосредственно в корпусе устройства), датчик влажности и температуры (расположен снаружи, так что считывает температуру потока) а также крыльчатка в паре с датчиком холла для считывания скорости ветра. Кроме того, в составе устройства присутствует карта памяти и радио модуль. Второе устройство служит для обработки и отображения получаемой по радио каналу информации. Система является авторской разработкой и имеет коммерческое применение в сфере беспилотных летательных аппаратов, а также авиамодельного спорта. На отдельные её части имеется авторское свидетельство [1].



Рисунок 1 – Устройство сбора метеоданных



Программная часть, кроме прошивок самих устройств, включает в себя комплекс программного обеспечения для обучения и применения нейронной сети, на основе собранных устройством, описанным ранее, данных. Сама нейронная сеть реализована на языке C++.

Для решения поставленной задачи был выбран многослойный персептрон [2, 3]. Это обуславливается относительной простотой его реализации, а также небольшими вычислительными затратами при использовании обученной нейронной сети. Нейроны в сети имеют униполярную сигмоидальную функцию активации  $f(x) = \frac{1}{1+e^{-\beta x}}$ . Начальная инициализация весов происходит случайным образом в пределах  $[-\frac{1}{N}; \frac{1}{N}]$ , где N – количество выборок для обучения. В процессе обучения методом градиентного спуска минимизируется следующая функция потерь  $E(W) = \frac{1}{2} \sum_{j=1}^p \sum_{k=1}^M (y_k^{(j)} - d_k^{(j)})^2$ , где W – вектор весовых коэффициентов сети, p – количество выборок для обучения, M – количество нейронов в выходном слое,  $y_k^{(j)}$  выход k-го нейрона в выходном слое на j-той выборке,  $d_k^{(j)}$  – k-тое целевое значение на j-той выборке.

Сеть обучается с использованием алгоритма стохастического градиентного спуска. Для предотвращения остановки алгоритма в локальном минимуме целевой функции применяется так называемый момент инерции антиградиента, являющийся аналогом одноимённой физической характеристики объекта, который имеет массу [4]. Для каждого весового коэффициента он вычисляется как значение этого весового коэффициента в момент времени t помноженный на некую отрицательную константу, задаваемую исследователем и применяется для нахождения значения весового коэффициента t+1.

При константе равной нулю момент инерции не используется и алгоритм сводится к обычному стохастическому градиентному спуску. Для внутренних слоёв нейронной сети коррекция весов вычисляется на основе метода обратного распространения ошибки [3]. Условия окончания обучения: достижение заданного максимального количества эпох; достижение функцией потерь заданного значения; изменение функции за две последних эпохи обучения не превышает заданное значение. В течение одной эпохи весовые коэффициенты могут корректироваться как единожды, так многократно, для реализации так называемого закрепления обучающего эффекта. Этот параметр так же настраиваемый.

```
start at 2017.07.08_15-34-19
Static temperature [C]; dynamic temperature [C]; pressure [mm];wind [mps];
relative humidity [%]; battery [V]
26.53; 26.64; 739.01; 0.00; 43.60; 4.07
26.53; 26.66; 738.86; 0.00; 43.70; 4.07
26.56; 26.67; 738.91; 0.00; 43.83; 4.08
```

Рисунок 2 – Структура исходных данных

Исходные данные имеют структуру, показанную на рисунке 2. Каждая строка хранит ежесекундные показания с датчиков (температура, давление, влажность и т.д.). Полный набор данных представляет собой множество фай-



лов, записанных на интервале в 10 месяцев. Так как эти данные в естественном виде непригодны для обучения нейронной сети, необходимо выполнить их предобработку. Во-первых, параметры необходимо усреднить по периодам с равным интервалом. Во-вторых, в некоторые моменты времени система сбора была отключена и, как следствие, в данных образовались пропуски, которые необходимо устранить (например, заполнить средним значением). В-третьих, перед началом обучения все входные и выходные признаки необходимо отмасштабировать на интервал  $[0;1]$ .

В рамках данной работы был обучен многослойный персептрон, способный прогнозировать показания статической температуры на час вперёд. Для его обучения весь набор исходных данных был усреднён с интервалом в один час. Для входного кортежа данных было использовано 4 признака: статическая температура, давление и влажность за время  $t_0$ ,  $t_0-1$ ,  $t_0-2$ ,  $t_0-4$ ,  $t_0-6$ ,  $t_0-24$  и час суток на момент  $t_0$ . В качестве выходного значения был принят один параметр статической температуры за время  $t_0+1$ . Всего на вход было подано 19 признаков, один ожидался на выходе. Обученная сеть состоит из 4-х скрытых слоёв по 200, 100, 50 и 25 нейронов соответственно, количество которых подобрано опытным путём. Коэффициент момента инерции был выставлен в 0, количество повторов обучения на одном кортеже было равно 1.

Результат прогнозирования температуры обученного многослойного персептрона показан на рисунке 3. График соответствует интервалу от 7 марта 2018 года до 21 марта 2018 года. Эти данные не участвовали в обучении.

В ходе исследовательской работы был обучен многослойный персептрон способный давать краткосрочный прогноз температуры с высокой точностью (среднее абсолютное отклонение  $\approx 1$  C°). Результаты планируется внедрить на реализованные портативные устройства.




Рисунок 3 – Результат прогнозирования нейронной сетью

### Литература

1. Свидетельство об официальной регистрации программы для ЭВМ №2017663122. Программа прошивки микроконтроллера в устройстве для системы сбора, обработки, накопления и ретрансляции метеоданных. / А.В. Сурков, Реестр программ для ЭВМ. – 1 с.





2. Осовский С. Нейронные сети для обработки информации / Пер. с пол. И.Д. Рудинского. – М.: Финансы и статистика, 2002. – 344 с.: ил.
3. Хайкин С. Нейронные сети: полный курс, 2-е издание. – Издательский дом Вильямс, 2008.
4. Nesterov Y. et al. Gradient methods for minimizing composite objective function. – 2007.

Н.К.А. Табет<sup>1</sup>, В.С. Фетисов<sup>2</sup>

## ИНТЕЛЛЕКТУАЛИЗАЦИЯ ИЗМЕРЕНИЙ ТОЛЩИНЫ ПАРАФИНОВЫХ ОТЛОЖЕНИЙ В НЕФТЕПРОВОДАХ

(<sup>1</sup> Аденский университет, Республика Йемен

<sup>2</sup> Уфимский государственный авиационный технический университет)

Парафиновые отложения в нефтепроводах представляют собой серьезную проблему для всех нефтетранспортных компаний. Ежегодно тратятся огромные средства на очистку внутренних поверхностей трубопроводов от этих вредных отложений. Если вовремя не производить такую очистку, то просвет сечения нефтепровода может сильно сузиться, сильно затрудняя транспортировку нефти, или перекрыться вовсе (рис.1).

Для удаления парафина из труб применяют различные способы: механические (очистка с помощью специальных самоходных снарядов, перемещающихся внутри трубы и удаляющих парафиновые наросты скребками, щетками или поршнями - в англоязычной литературе этот метод именуется *pigging* [1]); тепловые (с помощью нагрева трубопровода по длине или прокачки горячей жидкости и растапливания тем самым парафинового отложения); химические (с применением различных растворителей, закачиваемых в трубу) [2].



Рис. 1. Образцы срезов нефтепроводов с парафиновыми отложениями