

ПРОГНОЗИРОВАНИЕ ЛЕСНЫХ ПОЖАРОВ ПО МЕТЕОДАНЫМ С АНАЛИЗОМ СПУТНИКОВЫХ СНИМКОВ

К.В. Вик

Томский политехнический университет

E-mail: kvv11@tpu.ru

Введение

В России одной из актуальных тем является прогнозирование и детектирование лесных пожаров, поскольку лесной фонд занимает 70% территории страны. В момент на 29 июля 2019 года Сибирский окружной информационный центр сообщал, что площадь лесных пожаров в Сибири составляла 1 млн 603 тыс. га, было зафиксировано 232 очага. Наиболее сложная обстановка отмечалась в Иркутской области (137 пожаров) и Красноярском крае (94). Всего, по данным Федерального агентства лесного хозяйства (Рослесхоза), в России на 29 июля горело около 2,3 млн га леса.

По данным Рослесхоза площадь земельного фонда составляет: 1млрд 146 млн га. В России ежегодно фиксируется от 9тыс. до 35 тыс. лесных пожаров, площадь сгораемых территорий составляет: от 500 тыс. до 3,5 млн га. Поэтому, тема прогнозирования и детектирования лесных пожаров актуальна.

Задача

1. Изучение методов прогнозирования лесных пожаров по метеоданным;
2. Поиск обучающей выборки для прогнозирования лесных пожаров, для последующего обучения используемого алгоритма;
3. Подготовка обучающей выборки по спутниковым снимкам;
4. Реализация алгоритма;
5. Сравнение с аналогами.

Ход работы

В ходе прогнозирования лесных пожаров с метеорологическими данными использовались:

1. Обучающий набор данных «forest fires» [1];
2. Алгоритм обратного распространения [2];
3. Подготовка обучающей выборки по спутниковым снимкам;
4. Вычисление индекса гари.

Реализация

Для обучения нейронной сети был выбран обучающий набор данных «forest fires». Этот образец содержит базу данных, из 516 примеров. Данный пример распределен между собой на 12 входных параметров и 1 выходной параметр. База данных состоит из следующих параметров:

1. X – пространственная координата оси X на карте парка Монтесиньо: от 1 до 9;

2. Y – пространственная координата оси Y на карте парка Монтесиньо: от 2 до 9;
3. Month – месяц;
4. Day – день;
5. FFMC – Готовность почвы к возгоранию;
6. DMC – Код влажности;
7. DC – Код засухи;
8. ISI – Индекс начального распространения пожара;
9. Temp – Температура окружающей среды;
10. RH – Относительная температура окружающей среды;
11. Wind – Ветер;
12. Rain – Дождь;
13. Area – Площадь выгоревшей территории;

Для обучения нейронной сети использовался алгоритм обратного распространения. Данный алгоритм используется для минимизации отклонения реальных значений выходных сигналов нейронной сети от требуемых. В качестве функции ошибки ИНС будем рассматривать следующую величину: в основе идеи алгоритма лежит использование выходной ошибки нейронной сети:

$$E(w) = \frac{1}{2} \sum_i E_i = \frac{1}{2} \sum_{i,k} (f_{i,k} - y_{i,k}^T)^2 \quad (1)$$

где $f_{i,k}$ – значение выходного сигнала -го выходного нейрона сети при подаче на её входы i -го набора обучающих данных, $y_{i,k}^T$ – требуемое значение выходного сигнала k -го выходного нейрона для i -го набора данных для обучения. Суммирование ведется по всем нейронам выходного слоя и по всем наборам данных из обучающей выборки. Обучение ИНС направлено на минимизацию функции $E(w)$.

Минимизация методом градиентного спуска обеспечивает подстройку весовых коэффициентов следующим образом:

$$\Delta w_{ij}^{(q)} = \eta \frac{\delta E}{\delta w_{ij}}, \quad (2)$$

где $\Delta w_{ij}^{(q)}$ – величина изменения веса связи, соединяющей i -й нейрон $(q-1)$ слоя с j -м нейроном слоя q ; η – коэффициент скорости обучения,

$0 < \eta < 1$. Таким образом, вес связи изменяется пропорционально её вкладу в значение ошибки нейрона, для которого эта связь является входной, т.к. частная производная по весу $\frac{\delta E}{\delta w_{ij}}$ показывает зависимость скорости изменения функции ошибки E от изменения этого веса.

Опустим преобразования формулы (2) и представим сразу конечный результат (3).

Изменение веса связи определяется следующим образом:

$$\Delta w_{ij}^{(q)} = -\eta \delta_j x_i, \quad (3)$$

где δ_j – значение ошибки j -го нейрона в слое q , x_i – значение i -го входного сигнала для j -го нейрона слоя q . Данная формула применима и для настройки смещений нейронов, только вместо x_i необходимо подставить «1».

Результаты

Нейронная сеть была обучена с помощью алгоритма обратного распространения ошибки с применением библиотеки Keras [3].

Во всех скрытых слоях нейронной сети используется функция активации TANH [4].

Нейронные сети были протестированы на примере «forest fires». Данные полученные оказались такими:

loss = 0.0108 – среднеквадратичная ошибка, ошибка обучающей выборки - error_train = 0.1105 и тестовая ошибка - error_test = 0.0563, output_y = 0.0657 (148.414 га.).

На основании полученных данных можно сделать вывод, что алгоритм обратного распространения, работает и вычисляет площадь пожара из полученных данных с метеостанций.

Подготовка обучающей выборки

Для того чтобы анализировать спутниковые снимки и обнаруживать места гари, необходимо:

1. Создать базу данных спутниковых снимков с местами выгоревших территорий;
2. Создать маски гари и посчитать площадь выгоревшей территории.
- 3.

Спутниковые снимки были взяты с сайта glovis.usgs [5]. Ниже представлена сама программа (смотреть рис. 1). Для обработки снимков использовалась программа ArcGis. [6]




Рис. 1. Программа glovis.usgs.gov/app

Вычисление индекса гарей

Чтобы вычислить индекс гари воспользуемся уравнением для количественного определения выгоревших территорий. Это нормализованный индекс гарей (Normalized Burn Ratio – NBR). В нем для определения серьезности гари математически сравниваются ближний инфракрасный и коротковолновый инфракрасный 2 каналы (соответственно, каналы 5 и 7). Затем мы сравним NBR на снимках 2014 и 2015 гг., чтобы вычислить

изменения NBR, показывающие только территории, которые выгорели между датами, когда были сделаны эти два снимка. Оцифруем выгоревшие области и после смодем определить площадь гари в ArcGIS Online.

Площадь гари Thompson составила около 12 400 акров.




Рис. 2. Полигонное выделение гари Thompson

Сравнение с аналогами

В настоящее время созданы и успешно используются дистанционные системы космического, мониторинга состояния лесов.

Такие системы позволяют в режиме реального времени получать информацию о пожарной обстановке в лесах на всей территории РФ. Однако глубина обработки этой информации не всегда достаточна, в частности, не реализованы функции прогнозирования динамических параметров лесных пожаров.

AeroNet Lab – Лаборатория организованная для разработки и применения алгоритмов машинного обучения для интеллектуального анализа данных наблюдения Земли [7]

Исследование выполнено при финансовой поддержке РФФИ в рамках научного проекта № 18-08-00977 А и в рамках Программы повышения конкурентоспособности ТПУ.

Заключение

В данной работе было реализовано и проверено прогнозирование сгоревшей площади от лесных пожаров. На основании полученных результатов можно сделать вывод, что нейронная сеть обучилась, но недостаточно, для корректного прогнозирования площади выгорания.

Также, была выбрана обучающая выборка для реализации прогнозирования при использовании библиотеки Keras.

Список использованных источников

1. <https://archive.ics.uci.edu/ml/datasets/forest+fires>
2. <https://neurohive.io/ru/osnovy-data-science/obratnoe-rasprostranenie/>
3. <https://keras.io/>
4. <https://neurohive.io/ru/osnovy-data-science/activation-functions/>
5. <https://glovis.usgs.gov/app>
6. <http://www.arcgis.com/home/webmap/viewer.html?useExisting=1>
7. <https://aeronetlab.space>