

DOI: 10.37614/2588-0039.2020.43.025

## ОБРАБОТКА ИОНОГРАММ ВЫСОКОШИРОТНЫХ СТАНЦИЙ ВЕРТИКАЛЬНОГО ЗОНДИРОВАНИЯ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ: ES И F2 СЛОИ

С.А. Долгачева, Л.Н. Макарова, А.В. Николаев

ФГБУ «Арктический и антарктический научно-исследовательский институт»,  
Санкт-Петербург, Россия

E-mails: [dolgachyova2010@yandex.ru](mailto:dolgachyova2010@yandex.ru), [lumak@aari.nw.ru](mailto:lumak@aari.nw.ru), [demosfen.spb@gmail.com](mailto:demosfen.spb@gmail.com)

**Аннотация.** В работе рассматривается использование искусственных нейронных сетей для автоматической обработки высокоширотных ионограмм вертикального зондирования. Нейросетевые модели обучались различать типы слоев Es и F2 и определять их параметры: критические частоты обыкновенной волны для Es и F2 слоев ( $f_oEs$  и  $f_oF2$ ), минимальные действующие высоты ( $hEs$ ,  $hF2$ ), наименьшую наблюдаемую частоту отражения от ионосферы ( $f_{min}$ ), экранирующую частоту слоя Es ( $fbEs$ ), высоту максимума слоя Es, наибольшую частоту отражения от области F ( $fxI$ ), предельную частоту рассеянной обыкновенной компоненты слоя F ( $foI$ ), высоту и частоту для коэффициента M3000 F2 слоя (M3000f F2 и M3000h F2). Эффективность моделей оценивалась с помощью тестовой выборки, содержащей 30000 ионограмм. Точность определения слоев Es и F2 наиболее эффективной модели составляет 91.1% и 91.9% соответственно. Средняя ошибка определения частот составляет от 0.27 до 0.66 МГц для разного типа частот; средняя ошибка определения высоты Es ~8.5 км, высоты F2 ~30 км.

### Введение

Объектом исследовательского интереса является высокоширотная ионосфера, состояние которой связано с солнечной активностью и процессами, протекающими в солнечном ветре и магнитосфере Земли. Сеть полярных станций Росгидромета, на которых работниками ФГБУ «АНИИ» были установлены комплексы вертикального зондирования ионосферы (ВЗИ) CADI (Canadian Advanced Digital Ionosonde), развернута вдоль активной области авроральной зоны и покрывает более пяти часовых поясов, что позволяет исследовать структуру и пространственно-временное распределение быстро протекающих ионосферных процессов. Однако обработка результатов ВЗИ на высокоширотных станциях носит более сложный характер, в отличие от станций на средних широтах, так как авроральная ионосфера характеризуется большой изменчивостью и разнообразием распределения электронной концентрации на разных высотах [1 - 5].

Наблюдения авроральной ионосферы [3, 5] показывают, что при разных уровнях магнитной активности на уровне E и F слоев возникают спорадические ионосферные образования, которые носят локальный характер. Связано это с тем, что, помимо воздействия ультрафиолетового излучения Солнца (EUV) на ионосферу Земли, в периоды магнитосферных бурь и суббурь усиливаются электрические поля, продольные токи, а также высыпания частиц плазменного слоя из ночной магнитосферы в авроральную зону. В результате, структура получаемых высокоширотных ионограмм усложняется, и их интерпретация наблюдателями затрудняется, а автоматическая обработка становится вовсе невозможной [1, 2].

Для решения научных задач, связанных с исследованием эволюции спорадических слоев высокоширотной ионосферы с высоким временным разрешением требуется обработка большого массива ионограмм, которая в настоящее время не может выполняться в полном объеме наблюдателями вручную. Так, например, в Арктической Зоне России ФГБУ «АНИИ» проводит сеансы вертикального зондирования ионосферы на 6 полярных станциях Росгидромета и одной среднеширотной станции ЭИС НИС «Горьковская» с 15-минутным временным интервалом. Объем данных, получаемый Полярным Геофизическим Центром (ПГЦ) отдела Геофизики в час составляет около 28 ионограмм, в сутки – около 672. При таком потоке данных с учетом их сложной структуры, наблюдатели выполняют обработку 25% всех ионограмм с временным разрешением 1 час. Остальная часть ионограмм (75%) не интерпретируется и хранится в базе данных ПГЦ в исходном виде. Обработка всего объема ионограмм требует вовлечения автоматических алгоритмов, способных фильтровать исходные данные, выделять типы ионосферных слоев и определять их параметры. В нашей работе исследовалась возможность применения метода глубокого обучения искусственных нейронных сетей для распознавания типов слоев Es и/или F2 и определения их основных параметров. Для обучения моделей использовались обработанные наблюдателями ионограммы, хранящиеся в базе данных

ПГЦ. Для максимального разнообразия обучающей выборки были отобраны ионограммы со всех станций для всех сезонов при различном уровне геомагнитной активности.

### **Обучение моделей и результаты**

Искусственные нейронные сети [7] основаны на наборе связанных единиц, называемых искусственными нейронами, организованными в слои разных типов. Слой реализован как матрица весов, на которую умножается вектор входных данных, и затем прибавляется вектор свободных членов. К конечному результату выполняемых операций применяется нелинейная функция активации. Количество слоев зависит от сложности задачи и определяется экспериментально или на основе успешного решения похожих задач. Обучение нейронной сети – это итеративный процесс минимизации ошибки работы сети, в течение которого корректируются веса методом обратного распространения ошибки до тех пор, пока ошибка на выходе сети не будет ниже заданного порога, а метрики оценки качества работы не уложатся в выбранные пределы. Функция ошибки и метрики качества выбираются исходя из задачи. Например, для задачи классификации одной из метрик качества является точность определения класса (класс Es, класс F2).

Обработка ионограммы относится к задаче распознавания изображений, одной из классических задач компьютерного зрения, состоящей из двух ключевых этапов – выделения признаков из данных и классификации (или регрессии) на их основе. Задача классификации и регрессии может решаться с помощью линейных слоев (одномерного вектора весов). Для выделения признаков из изображения используются свёрточные слои, которые представляют собой трехмерную матрицу (набор двумерных фильтров - матриц весов). Каждый фрагмент изображения умножается на фильтр поэлементно, а результат умножения суммируется и записывается в аналогичную позицию получаемой матрицы признаков изображения (например, прямые под разными углами). Размеры фильтра малы (3x3 или 5x5 пикселя), с его помощью учитывается связь между пикселями внутри малой области. После операции свёртки и применения нелинейной функции активации происходит уменьшение пространственного размера матрицы признаков с помощью операции субдискретизации, которая заключается в объединении ближайших элементов матрицы (находится максимум или арифметическое среднее). Благодаря этому последующий свёрточный слой учитывает более глобальные взаимосвязи.

Для получения модели нужного качества, необходимо подобрать архитектуру сети и метод ее обучения. В настоящее время для решения разных задач классификации и регрессии широко применяется метод переноса обучения (transfer learning) [9]. Этот метод заключается в использовании уже обученной на большом количестве данных нейронной сети (например, ResNet [8], обученной командой Microsoft Research на нескольких миллионах изображений в открытом доступе) или сети, обученной собственным набором данных (например, изображениями ионограмм). В качестве последнего слоя классификации (или регрессии) выбранной нейросети создается новый слой, который обучается под решаемую задачу, при этом необходимость полного цикла обучения модели отпадает. Если полученная таким образом нейросеть плохо выделяет признаки (в нашем случае это определение слоёв Es и F), её можно дополнительно обучить. В данной работе был использован как метод полного обучения нейросети, так и метод transfer learning с использованием обученной на ионограммах модели автокодировщика – нейронной сети, получающей на выходе отклик, наиболее близкий к входным данным.

Первым этапом задачи автоматизации обработки ионограмм было определение типов ионосферных слоёв на ионограмме. Для определения первоначальной архитектуры моделей были выбраны ионограммы с наличием только одного ионосферного слоя. После анализа базы данных ПГЦ оказалось, что ионограммы со слоем E и слоем F1 недостаточно для обучения нейросети, поэтому были отобраны случайные 30000 ионограмм с наличием Es и F2 слоёв. Из них 20000 ионограмм составили обучающую выборку и 10000 – тестовую, для оценки точности модели. Две модели бинарной классификации с двумя слоями свертки и тремя линейными слоями, прошедшие полный цикл обучения, определили на ионограммах 90% всех слоёв Es и 87% всех слоёв F2. Далее, в обучающую и тестовую выборку были добавлены ионограммы с наличием всех ионосферных слоев. После обучения эффективность распознавания на тестовой выборке в 20000 ионограмм достигло 91.1% для Es слоя и 91.9% для слоя F2. Примеры автоматического определения слоёв представлены на рисунке 1.

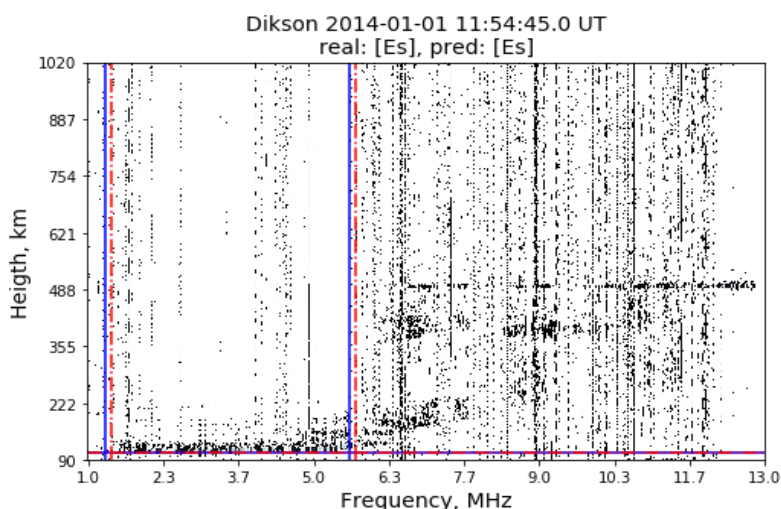
Следующим шагом было определение основных параметров ионосферных слоёв – минимальных действующих высот и критических частот обыкновенной волны. Для решения этой задачи был использован метод transfer learning с автокодировщиком и новая модель, с такой же архитектурой, как и в модели классификации. В результате обучения все модели показали примерно одинаковую эффективность: 1МГц средняя ошибка определения критической частоты Es слоя и 0.39 МГц средняя ошибка определения критической частоты F2 слоя. Для минимальной действующей высоты Es слоя средняя ошибка составила ~10.3 км, для F2 ~30 км. Пример работы наиболее эффективной модели на основе автокодировщика представлен на рисунке 1.

Далее, обучающий и тестовый набор были расширены ионограммами, сбалансированными таким образом, чтобы были равномерно представлены критические частоты Es и F2, а так же типы Es слоя. В итоге,

обучающая выборка составила 100000 ионограмм, а тестовая – 30000 ионограмм с высоким разнообразием. На этих данных были обучены усложненные регрессионные модели. Помимо критических частот и действующих высот было добавлено определение минимальной наблюдаемой частоты отражения от ионосферы ( $f_{min}$ ), экранирующей частоты слоя Es ( $f_{bEs}$ ), высоты максимума слоя Es $g$ , наибольшей частоты отражения от области F ( $f_{xI}$ ), предельной частоты рассеянной обыкновенной компоненты слоя F ( $f_{oI}$ ) и высоты и частоты для коэффициента M3000 F2 слоя (M3000f F2 и M3000h F2). На данном этапе средняя ошибка определения высоты слоя в наиболее эффективной модели составляет 8.25 км для Es и 8.5 км для высоты максимума слоя Es $g$ . Средняя ошибка определения высоты F2 слоя и высоты M3000 F2 слоя выше 10 км, однако, многообразие методов обучения и архитектур моделей позволяет подобрать в дальнейшем вариант для достижения необходимой точности.

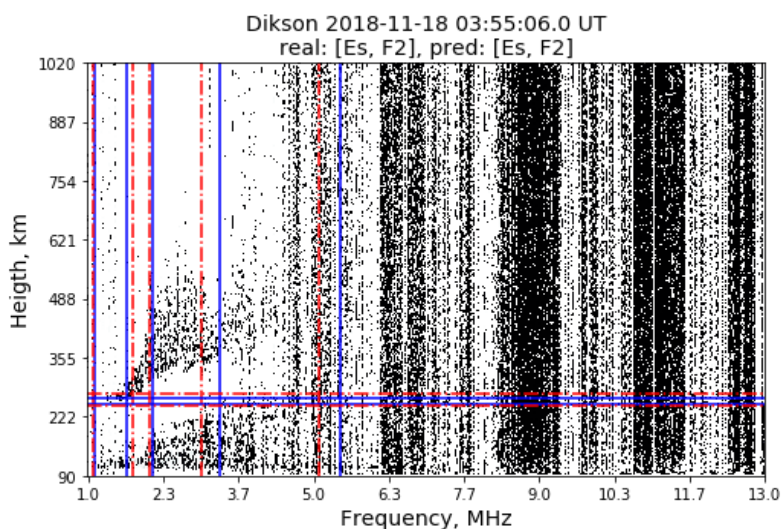
Средняя ошибка определения минимальной частоты составляет  $\sim 0.32$  МГц, для критической частоты Es слоя  $\sim 0.66$  МГц, для частоты проникновения  $\sim 0.47$  МГц, для критической частоты F2 слоя  $\sim 0.4$  МГц. Ошибка предельной частоты рассеянной o-компоненты слоя F  $\sim 0.27$  МГц, предельной частоты отражения от слоя F  $\sim 0.45$  МГц и  $\sim 0.4$  МГц для частоты M3000. Пример работы модели представлен на рисунке 1.

а)



	real	pred
$f_{min}$ , MHz	1.30	1.42
$f_o Es$ , MHz	5.64	5.09
$h Es$ , km	107	108

б)



	real	pred
$f_{min}$ , MHz	1.13	1.09
$f_o Es$ , MHz	5.47	5.09
$h Es$ , km	106	111
$f_o F2$ , MHz	2.14	2.08
$h F2$ , km	251	250
$f_{xi}$ , MHz	3.34	3.02
M 3000 f, MHz	1.68	1.80
M 3000 h, km	267	276

**Рисунок 1.** Определение типа слоя (Es и F2) и его параметров ( $f_{min}$ ,  $f_o Es$ ,  $h Es$ ,  $f_o F2$ ,  $h F2$ ,  $f_{xi}$ , M3000 f и h) на примере обработки ионограмм со станции Диксон за 01.01.2014 (а) и 18.11.2018 (б). Результат интерпретации наблюдателем обозначен как «real» (синяя линия), нейросетью как «pred» (красная линия).

## Заключение

Использование искусственных нейронных сетей для интерпретации сложных высокоширотных ионограмм имеет большой потенциал в решении задачи улучшения качества их обработки. Существующие на данный момент алгоритмы имеют значительно меньшую эффективность, например, точность автоматической обработки, применяемой дигизондом Рейниша (DPS-4) в летний период не превышает 70%, а в зимний 50% [2]. В данной работе приведены результаты обработки 30000 ионограмм, содержащие Es и F2 слои, которые показали, что наиболее эффективные нейросетевые модели способны определить Es и F2 слой с точностью 91.1% и 91.9% соответственно. Средняя ошибка определения критических частот слоёв лежит в допустимых пределах, однако, точность определения высот слоев, как и определения их частот, требует дальнейшего обучения моделей. Также стоит отметить, что улучшение качества автоматической обработки ионограмм мало зависит от выбора уже обученных моделей по принципу transfer learning или моделей, прошедших полный цикл обучения. Однако выбор набора параметров, методов обучения нейронной сети и качество обучающей выборки играют ключевую роль в решении задачи точной интерпретации исходных данных.

## Литература

1. *Выставной В.М., Макарова Л.Н., Широков А.В., Егорова Л.В.* Исследования высокоширотной ионосферы методом вертикального зондирования с использованием современного цифрового ионозонда cad1. Гелиогеофизические исследования, № 4, 2013, С. 1–10.
2. *Выставной В.М., Егорова Л.В., Макарова Л.Н., Широков А.В.* Измерения параметров высокоширотной ионосферы методом вертикального зондирования с помощью современного цифрового ионозонда. Мир Измерений, № 10, 2014, С. 49–55.
3. *Макарова Л.Н., Широков А.В., Николаева В.Д.* Динамика аврорального слоя во время слабых и сильных возмущений в магнитосфере. Геомагнетизм и аэрономия, том 54, № 6, 2014, С. 763-766.
4. *Дашкевич Ж.В., Иванов В.Е., Сергиенко Т.И., Козелов Б.В.* Физико-химическая модель авроральной ионосферы. Космические исследования, №2, 2017, С. 12-24.
5. *Трошичев О.А., Беспозванная А.С., Макарова Л.Н. и др.* Ионосферно-магнитные возмущения в высоких широтах. Л.: Гидрометеиздат, 1986, 255 с.
6. Руководство URSI по интерпретации и обработке ионограмм. Пер. с англ. / Междунар. науч. радиосоюз, Сов. нац. ком. М.: Наука, 1978, 342 с.
7. *Николенко С., Кадурин А., Архангельская Е.* Глубокое обучение. СПб.: Питер, 2018, 480 с.
8. *Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun.* Deep Residual Learning for Image Recognition. arXiv:1512.03385, 2015.
9. *Pan S.J., Yang Q.* A survey on transfer learning. IEEE Transactions on Knowledge and Data Engineering, V. 22(10), 2010, P. 1345–1359.