

УДК 550.382

## ПРИМЕНЕНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ВОССТАНОВЛЕНИЯ ВЕКТОРА МАГНИТНОГО ПОЛЯ ПО ОДНОКОМПОНЕНТНЫМ ДАННЫМ

© 2025 г. Р. А. Рытов<sup>1</sup>, \*, В. Г. Петров<sup>1</sup>, \*\*

<sup>1</sup>Институт земного магнетизма, ионосферы и распространения радиоволн им. Н.В.Пушкина РАН (ИЗМИРАН),  
Москва, Троицк, Россия

\*e-mail: ruslan.rytov2017@ya.ru

\*\*e-mail: vgpetrov2018@mail.ru

Поступила в редакцию 12.04.2024 г.

После доработки 29.05.2024 г.

Принята к публикации 25.07.2024 г.

В данной работе с помощью искусственных нейронных сетей была решена задача о восстановлении векторного аномального магнитного поля по однокомпонентным данным. Для обучения искусственной нейронной сети была создана база данных компонент аномального магнитного поля  $B_x$ ,  $B_y$ ,  $B_z$  с помощью набора точечных магнитных диполей, залегающих под плоскостью измерения поля. На синтетическом примере была показана работа обученной нейронной сети в сравнении с известным численным алгоритмом восстановления векторного поля по данным одной компоненты. Далее, по данным вертикальной компоненты аномального геомагнитного поля с помощью искусственных нейронных сетей были восстановлены горизонтальные компоненты аномального геомагнитного поля на территории 58–85° E, 52°–74° N с шагом сетки 2 угловых минуты.

**Ключевые слова:** искусственные нейронные сети, аномальное магнитное поле, векторное магнитное поле, компьютерное моделирование.

**DOI:** 10.31857/S0016794025010109, **EDN:** ADKBHQ

### 1. ВВЕДЕНИЕ

Модели векторного аномального магнитного поля широко используются для задач геофизики, навигации и направленного бурения [Buchanan et al., 2013; Kaji et al., 2019]. Однако, количество модульных данных аномального поля превышает число векторных измерений. Поэтому, чтобы получить высокоточную модель векторного магнитного поля, с помощью специальных методов по данным известного однокомпонентного аномального магнитного поля рассчитывают векторное аномальное магнитное поле.

Примерами таких методов являются метод магнитного потенциала [Lourenco and Morrison, 1973; Колесова и Черкаева, 1987] и метод магнитных диполей [Montesinos et al., 2016; Kaftan, 2017]. В методе магнитного потенциала компоненты поля описываются двойными рядами Фурье, коэффициенты которых связаны через потенциал аномального магнитного поля. Однако

данний метод требует, чтобы магнитная аномалия полностью находилась в области измерений [Lourenco and Morrison, 1973; Колесова и Черкаева, 1987]. С помощью метода диполей искомое векторное поле рассчитывается, опираясь на известную компоненту аномального поля, с помощью набора фиктивных точечных диполей, положения которых подбираются методом проб и ошибок под плоскостью сканирования аномального поля. Однако время работы метода диполей быстро возрастает с увеличением числа диполей и точек измерения аномального магнитного поля.

Для быстрой обработки большого объема цифровых изображений эффективно применение искусственных нейронных сетей. Искусственные нейронные сети широко используются для приложений в компьютерном зрении и классификации изображений [Krizhevsky et al., 2012]. Нейронные сети, обученные на данных о физи-

ческих процессах, применялись для моделирования магнитных полей, а также для интерполяции и продления магнитных полей, измеренных на редкой сетке [Coskun et al., 2022; Pollock et al., 2021; Pollock et al., 2023]. В некоторых случаях обученная нейронная сеть показывает более высокую точность в сравнении с традиционными численными алгоритмами [Coskun et al., 2022; Pollock et al., 2021].

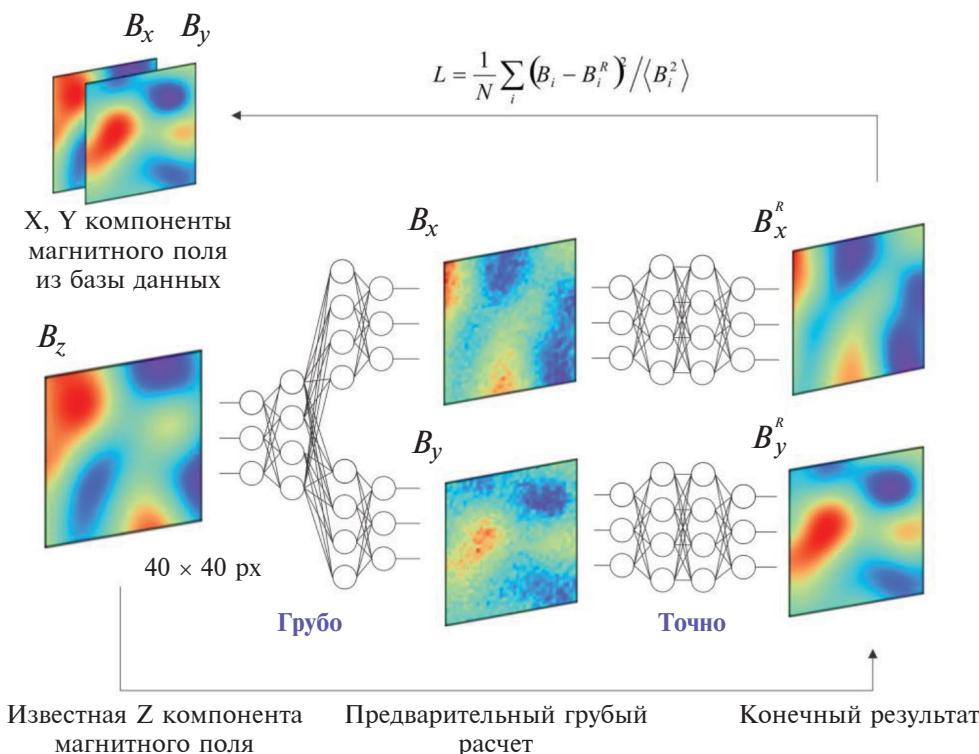
В данной работе предложен новый метод восстановления векторного магнитного поля с помощью искусственных нейронных сетей. Нейронная сеть принимает на вход данные вертикальной  $B_z$ -компоненты аномального поля размерностью  $40 \times 40$  пикселей, а затем восстанавливает компоненты в плоскости  $B_x$  и  $B_y$ . Для обучения разработанной нейронной сети была создана база данных, содержащая 50000 случайных аномальных магнитных полей, которые были получены с помощью суммарного поля точечных магнитных диполей. Было проведено сравнение разработанной нейронной сети с известным численным методом восстановления векторного поля [Lourenco and Morrison, 1973; Колесова и Черкаева, 1987]. Работа нейронной сети также была проверена с помощью данных вертикальной компоненты аномального поля, полученного

с помощью моделей IGRF-13 [Alken et al., 2021] и EMM2017 [Maus, 2010; The National Centers for Environmental Information, 2018] на территории  $58\text{--}85^\circ$  E,  $52\text{--}74^\circ$  N с шагом сетки 2 угловых минуты.

## 2. ОПИСАНИЕ МЕТОДА

### 2.1. Архитектура нейронной сети

Схема разработанной искусственной нейронной сети показана на рис. 1. Известное распределение вертикальной компоненты аномального поля  $B_z$  размерностью  $40 \times 40$  пикселей поступает на вход нейронной сети. Для предварительного грубого расчета используется плотная нейронная сеть, содержащая входной слой, внутренний слой и выходной слой размерностью  $40 \times 40$  нейронов. Далее результаты грубого расчета компонент аномального поля поступают на вход уточняющей нейронной сети. Уточнение происходит с помощью сверточной нейронной сети с входным слоем, выходным слоем и двумя внутренними слоями, содержащими  $40 \times 40$  нейронов. В разработанной модели использовалась линейная функция активации нейронов.



**Рис. 1.** Схематичное изображение архитектуры искусственной нейронной сети для восстановления  $B_x$ - и  $B_y$ -компонент аномального магнитного поля по известной вертикальной  $B_z$ -компоненте.

Нейронная сеть была реализована с помощью библиотеки *tensorflow* [Abadi et al., 2016]. Выбор библиотеки *tensorflow* обоснован высокой производительностью, гибкостью и удобством разработки нейронной сети. Для обучения нейронной сети использовался алгоритм стохастического градиентного спуска *Adam* [Kingma et al., 2014].

Для обучения нейронной сети и дальнейшей оценки точности восстановления магнитного поля необходимо задать функцию невязки. Существует множество известных функций невязки, некоторые из которых реализованы в пакете *tensorflow*, например, средний квадрат отклонения, средний модуль отклонения и т.д. Существуют и более совершенные функции, например, РЕ-функция [Barkhatov et al., 2017]. Выбор конкретной функции невязки для обучения нейронной сети зависит от типа входных данных и может подбираться экспериментально. В данной работе для простоты была выбрана функция среднеквадратичной ошибки вида

$$L = \frac{1}{N} \sum_i \frac{(B_i - B_i^R)^2}{\langle B^2 \rangle}, \quad (1)$$

где  $B_i$  – известное поле в точке  $i$ ,  $B_i^R$  – восстановленное поле в точке  $i$ ,  $\langle B^2 \rangle$  – средний квадрат известного аномального поля,  $N$  – общее число точек измерения.

Обучающая база данных состоит из 50000 случайных компонент аномального магнитного поля  $B_x, B_y, B_z$ , из неё 45000 компонент использовались для обучения искусственной нейронной сети, 5000 компонент использовались для валидации процесса обучения нейронной сети. В процессе обучения невязка достигла значений  $L < 4 \cdot 10^{-3}$ .

## 2.2. Прямое моделирование аномального поля

Для моделирования аномального магнитного поля использовались точечные диполи, так как магнитное поле намагниченного тела на расстояниях, превышающих его размеры, эквивалентно полю точечного диполя. Поле точечного магнитного диполя определяется известной формулой [Яновский, 1978]

$$\vec{B}(\vec{r}) = \frac{3\vec{r}(\vec{m}, \vec{r})}{|\vec{r}|^5} - \frac{\vec{m}}{|\vec{r}|^3}, \quad (2)$$

где  $\vec{r}$  – вектор из точки нахождения диполя в точку измерения,  $\vec{m}$  – магнитный момент диполя в декартовой системе координат. Аномальное магнитное поле моделируется с помощью случай-

ного распределения 1–400 точечных магнитных диполей. Компоненты аномального магнитного поля затем вычисляются в плоскости на некоторой высоте над точечными диполями и заносятся в базу данных. Численные значения компонент аномального поля нормируются таким образом, чтобы они лежали в диапазоне [-1, 1].

## 2.3. Обучение нейронной сети

Обучение разработанной нейронной сети проводилось на персональном компьютере с процессором *Intel Core i7-9700* и видеокартой *NVIDIA GeForce GTX 950*. Для того чтобы 2 Gb свободной памяти видеокарты были задействованы, входные данные для обучения, общим размером чуть более 2 Gb, разбивались на равные части по 1 Gb. Далее обучение проводилось на каждой серии данных до момента, когда невязка на валидирующую выборку станет больше невязки обучающей выборки. Пример графика динамики функции невязки в процессе обучения в логарифмическом масштабе показан на рис. 2.

На рис. 2 показан процесс уменьшения значения функции невязки для обучающих данных и для валидирующих данных. Для того чтобы избежать переобучения нейронной сети, процесс обучения останавливался, если невязка валидирующей выборки начинала возрастать относительно невязки обучающей выборки [Ying, 2019]. Данный момент показан на рис. 2 стрелочкой, ему соответствует примерно 80 номер эпохи.

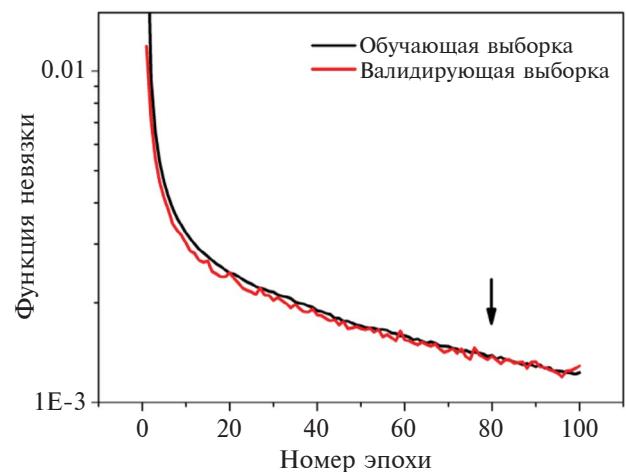


Рис. 2. Значение функции невязки для обучающей серии данных и валидирующей серии данных как функция номера эпохи в процессе обучения искусственной нейронной сети

### 3. СИНТЕТИЧЕСКИЙ ПРИМЕР

Обученная нейронная сеть была проверена с помощью тестовых аномальных магнитных полей, которые не входили в общую базу данных в процессе обучения. На рис. 3 для конкретного примера показан результат работы обученной нейронной сети в сравнении с численным алгоритмом восстановления горизонтальных компонент аномального магнитного поля, который подробно описан в работе [Lourenco and Morrison, 1973].

На рис. 3 $a$ , 3 $b$  показаны результаты восстановления горизонтальных компонент  $B_x$  и  $B_y$  аномального поля по данным вертикальной  $B_z$ -компоненты с помощью численного алгоритма. Рисунки 3 $c$ , 3 $d$  демонстрируют результаты работы обученной нейронной сети для тех же входных данных. Серии на рис. 3 показывают исходные компоненты  $B_x$  и  $B_y$ , восстановленные компоненты  $B_x^{\text{восст.}}$  и  $B_y^{\text{восст.}}$ , а также разность между исходными и восстановленными компонентами магнитного поля, полученными с помощью численного алгоритма и искусственной нейронной сети.

Рисунок 3 показывает, что в случае работы численного алгоритма невязка, рассчитанная по формуле (1), принимает значения  $L = 0.1067$  и  $L = 0.1606$  для компонент  $B_x$  и  $B_y$  соответственно. Для результатов работы нейронной сети ошибка принимает значения  $L = 0.0031$  и  $L = 0.0018$  для компонент  $B_x$  и  $B_y$  соответственно. Рисунок 3 $a$ , 3 $b$  показывают, что в случае работы численного алгоритма основной вклад

в ошибку вносят краевые эффекты, которые отсутствуют в результатах работы нейронной сети, как показывают рис. 3 $c$ , 3 $d$ . Краевые эффекты возникают, когда магнитная аномалия не входит целиком в изучаемую область [Lourenco and Morrison, 1973; Колесова и Черкаева, 1987].

Чтобы снизить общую невязку, краевые 10 px каждого изображения удаляются, а невязка вычисляется в области  $20 \times 20$  px, показанной на рис. 3. В данном случае для численного алгоритма невязка принимает значения  $L = 0.0082$  и  $L = 0.0112$  для компонент  $B_x$  и  $B_y$  соответственно, а в случае применения обученной нейронной сети невязка  $L = 4.2 \cdot 10^{-4}$  и  $L = 2.7 \cdot 10^{-4}$  для компонент  $B_x$  и  $B_y$  соответственно.

Далее было проведено сравнение средней невязки результатов работы численного алгоритма и обученной нейронной сети на 1000 случайных распределений аномального магнитного поля, которые не входили в базу данных при обучении нейронной сети. В выборку включались также случаи, когда магнитная аномалия не входит целиком в рассматриваемую область. Невязка рассчитывалась как для целого изображения  $40 \times 40$  px, так и для изображений без краевых пикселей,  $20 \times 20$  px. Результаты проведенного сравнения показаны в табл. 1.

Результаты, приведенные в табл. 1, показывают, что искусственная нейронная сеть в среднем имеет лучшую точность в смысле функции невязки (1) в сравнении с известным численным алго-

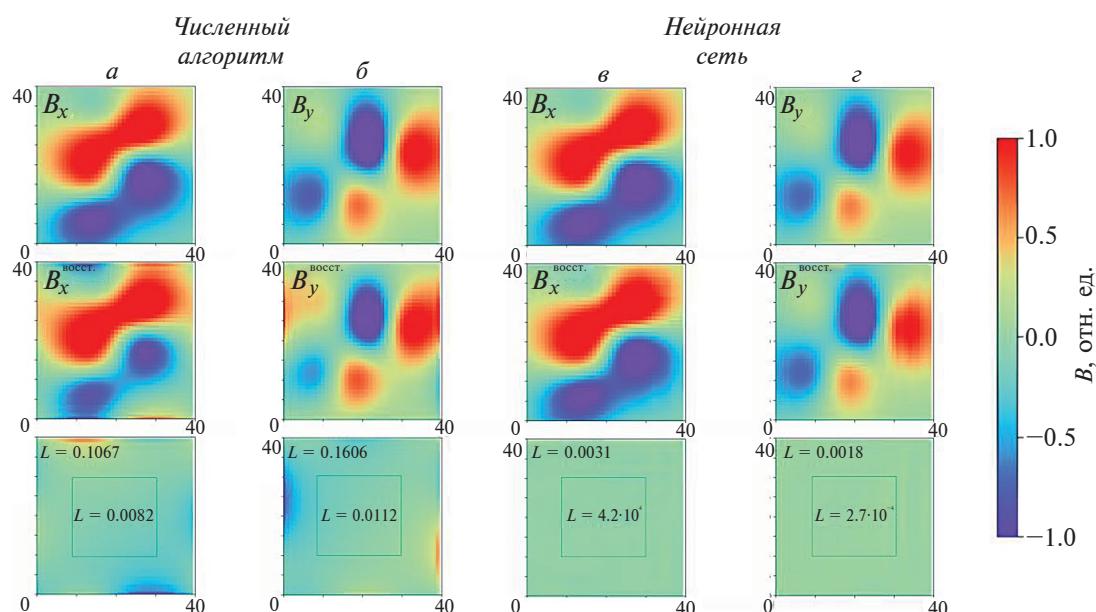


Рис. 3. Результаты восстановления горизонтальных компонент  $B_x$  и  $B_y$  ( $a$ – $b$ ) с помощью численного алгоритма и ( $c$ – $d$ ) с помощью обученной искусственной нейронной сети.

**Таблица 1.** Средняя невязка для восстановленных компонент аномального магнитного поля в плоскости с помощью численного алгоритма и обученной искусственной нейронной сети

Размер изображения на выходе	$B_x$ (числ. алгоритм)	$B_y$ (числ. алгоритм)	$B_x$ (нейрон. сеть)	$B_y$ (нейрон. сеть)
$40 \times 40$ px	$L = 0.1068$	$L = 0.1058$	$L = 0.0271$	$L = 0.0269$
$20 \times 20$ px	$L = 0.0125$	$L = 0.0125$	$L = 0.0069$	$L = 0.0071$

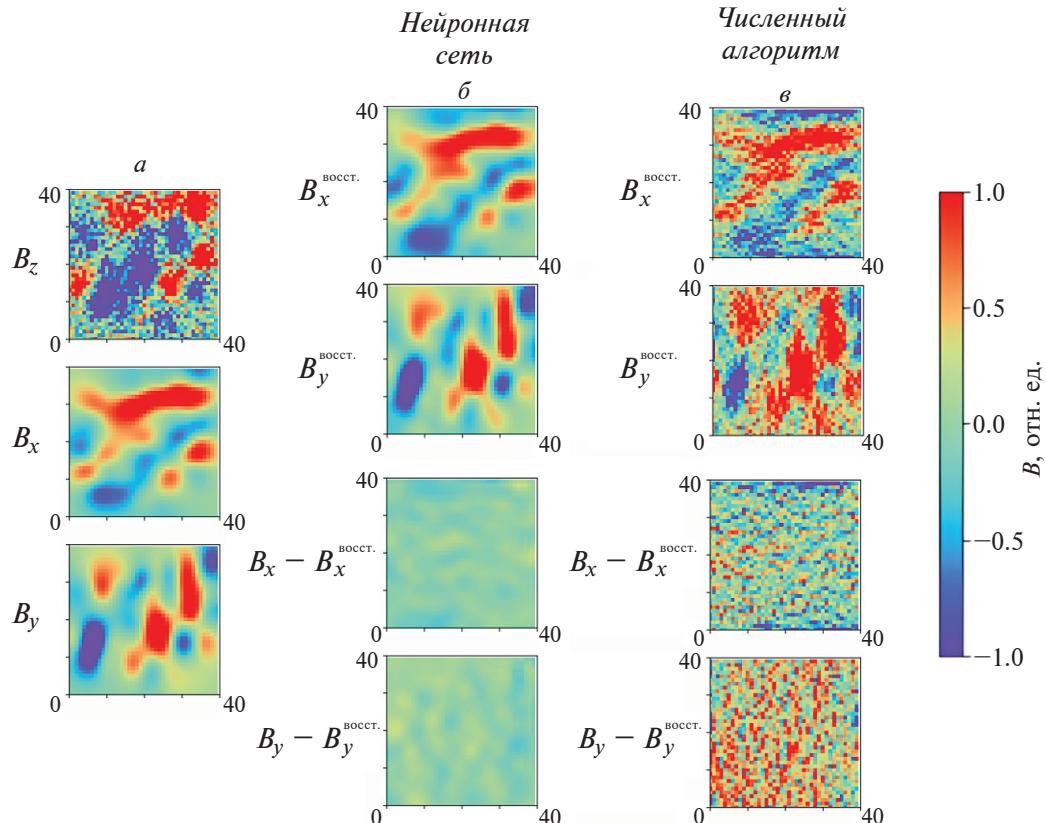
ритмом. Если также учесть влияние краевых эффектов и отбросить по 10 пикселей с каждого края изображения, то точность восстановления векторного поля возрастает существенно для обоих методов, но и в этом случае нейронная сеть показывает несколько лучшие результаты.

### 3.1. Влияние шума

Далее работа искусственной нейронной сети была проверена на зашумленных данных. Результаты проверки показаны на рис. 4.

Для моделирования белого шума случайное число в диапазоне [-0.5, 0.5] было добавлено к значению каждого пикселя вертикальной компоненты  $B_z$ , как показывает рис. 4a. Здесь также показаны истинные компоненты в плоскости,  $B_x$  и  $B_y$ . По заданной зашумленной компоненте  $B_z$  были восстановлены компоненты в плоскости  $B_x$  и  $B_y$  с помощью искусственной нейронной сети, рис. 4б, и с помощью численного алгоритма, рис. 4в.

Разница между истинными компонентами и восстановленными показана на рис. 4б для искусственной нейронной сети и на рис. 4в для чис-



**Рис. 4.** Результаты восстановления горизонтальных компонент  $B_x$  и  $B_y$  (a) по зашумленным данным компоненты  $B_z$ , (б) с помощью обученной искусственной нейронной сети и (в) с помощью численного алгоритма.

**Таблица 2.** Средняя невязка для восстановленных компонент аномального магнитного поля в плоскости по зашумленным данным с помощью численного алгоритма и обученной искусственной нейронной сети

Размер изображения на выходе	$B_x$ (числ. алгоритм)	$B_y$ (числ. алгоритм)	$B_x$ (нейрон. сеть)	$B_y$ (нейрон. сеть)
$40 \times 40$ px	$L = 0.7493$	$L = 0.8122$	$L = 0.0733$	$L = 0.0680$
$20 \times 20$ px	$L = 0.1496$	$L = 0.1895$	$L = 0.0122$	$L = 0.0126$

ленного алгоритма. В случае нейронной сети невязка принимает значения  $L = 0.0578$  для  $B_x$ -компоненты и  $L = 0.0464$  для  $B_y$ -компоненты. Для численного алгоритма невязка принимает значения  $L = 0.4613$  для  $B_x$ -компоненты и  $L = 0.6579$  для  $B_y$ -компоненты.

Далее, как и в предыдущей секции, было проведено сравнение средней невязки результатов работы численного алгоритма и обученной нейронной сети на 1000 случайных зашумленных распределений вертикальной компоненты аномального магнитного поля. Невязка так же рассчитывалась как для целого изображения  $40 \times 40$  px, так и для изображений без краевых пикселей,  $20 \times 20$  px. Результаты такого сравнения показаны в табл. 2.

Результаты, приведенные в табл. 2, показывают, что искусственная нейронная сеть в среднем показывает лучшую устойчивость к шумам во входных данных. Так, в случае численного алгоритма, средняя невязка для  $B_x$ - и  $B_y$ -компонент аномального поля составляет  $L = 0.7493$  и  $L = 0.8122$  соответственно. Для искусственной нейронной сети, средняя невязка для  $B_x$ - и  $B_y$ -компонент аномального поля составляет  $L = 0.0733$  и  $L = 0.0680$  соответственно. Если же отбросить краевые пиксели, то для численного алгоритма невязка принимает значения  $L = 0.1496$  и  $L = 0.1895$  для компонент  $B_x$  и  $B_y$  соответственно, а для искусственной нейронной сети невязка принимает значения  $L = 0.0122$  и  $L = 0.0126$  для компонент  $B_x$  и  $B_y$  соответственно.

#### 4. РАССЧЕТ КОМПОНЕНТ АНОМАЛЬНОГО ГЕОМАГНИТНОГО ПОЛЯ ПО ДАННЫМ ВЕРТИКАЛЬНОЙ КОМПОНЕНТЫ

Искусственная нейронная сеть была протестирована на большом объеме данных аномального геомагнитного поля. С помощью моделей IGRF-13 и EMM2017 на высоте 4 км были получены данные вертикальной компоненты аномального поля над областью  $58\text{--}85^\circ$  E,  $52\text{--}74^\circ$  N с шагом сетки 2 угловых минуты, как показано на рис. 5.

Данные главного геомагнитного поля, создаваемого токами в ядре Земли, были получены из модели IGRF-13. Данные полного геомагнитного поля были получены из модели EMM2017. Модель EMM2017 позволяет получить с точностью до 51 км как главное магнитное поле, так и поле магнитных аномалий, которые создаются породами в земной коре [The National Centers for Environmental Information, 2018]. Для получения именно аномального магнитного поля, рассчитывалась разность между данными модели полного поля EMM2017 и главного поля IGRF-13. Расчет проводился с использованием следующих параметров: 2020 год, высота 4 км над уровнем моря, долгота  $58\text{--}85^\circ$  E с шагом 0.03 градуса, широта  $52\text{--}74^\circ$  N с шагом 0.03 градуса. Результаты восстановления компонент аномального магнитного поля в плоскости показаны на рис. 6.

Аномальное поле на географической сетке координат было преобразовано в километровую равномерную сетку с расстоянием между соседними точками в 2 км, всего  $1386 \times 1286$  точек. Для обработки изображения с помощью искусственной нейронной сети полученная карта вертикальной компоненты разбивалась случайным образом на 50000 пересекающихся участков с размерами  $40 \times 40$  пикселей.

Затем каждый участок обрабатывался с помощью нейронной сети, а для уменьшения влияния краевых эффектов 10 краевых пикселей каждого изображения удалялись. Наконец, из маленьких участков  $20 \times 20$  пикселей, которые содержат данные о восстановленных компонентах  $B_x$  и  $B_y$  аномального магнитного поля, формировались карты аномального магнитного поля исходного размера.

Расчет проводился на персональном компьютере, время обработки 50000 изображений  $40 \times 40$  пикселей с помощью искусственной нейронной сети не превышает 1 мин при выполнении расчета на CPU. Преобразования карт из географических координат в километровые и обратно проводились с помощью алгоритмов ин-

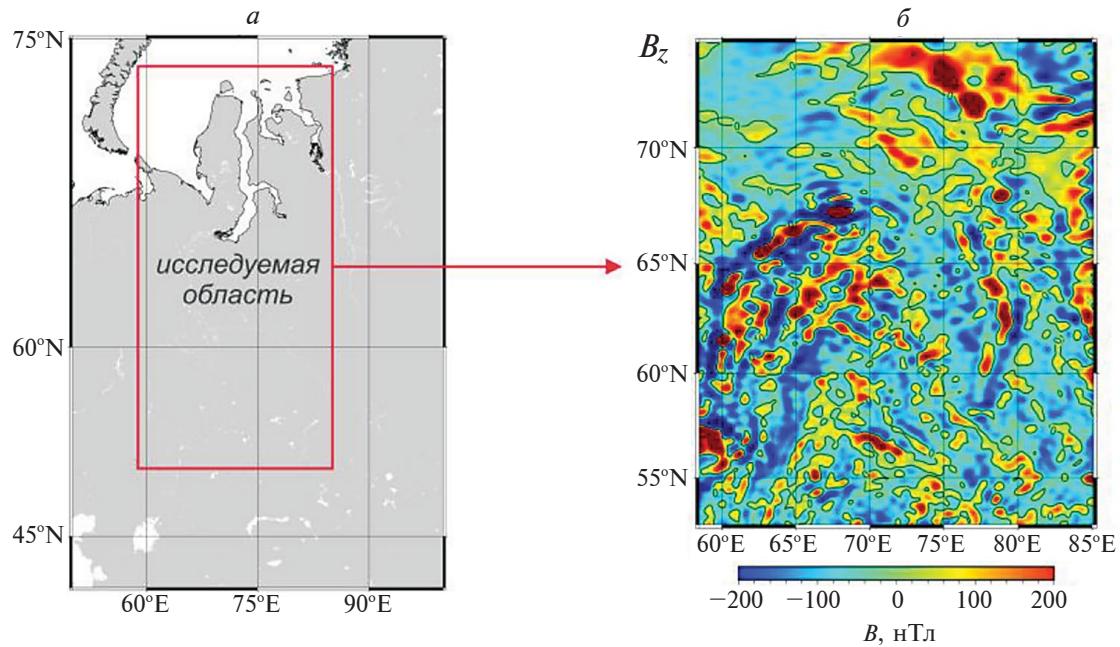


Рис. 5. Исследуемая область, в которой (а) выбиралось аномальное магнитное поле и (б) распределение вертикальной компоненты  $B_z$  над исследуемой областью.

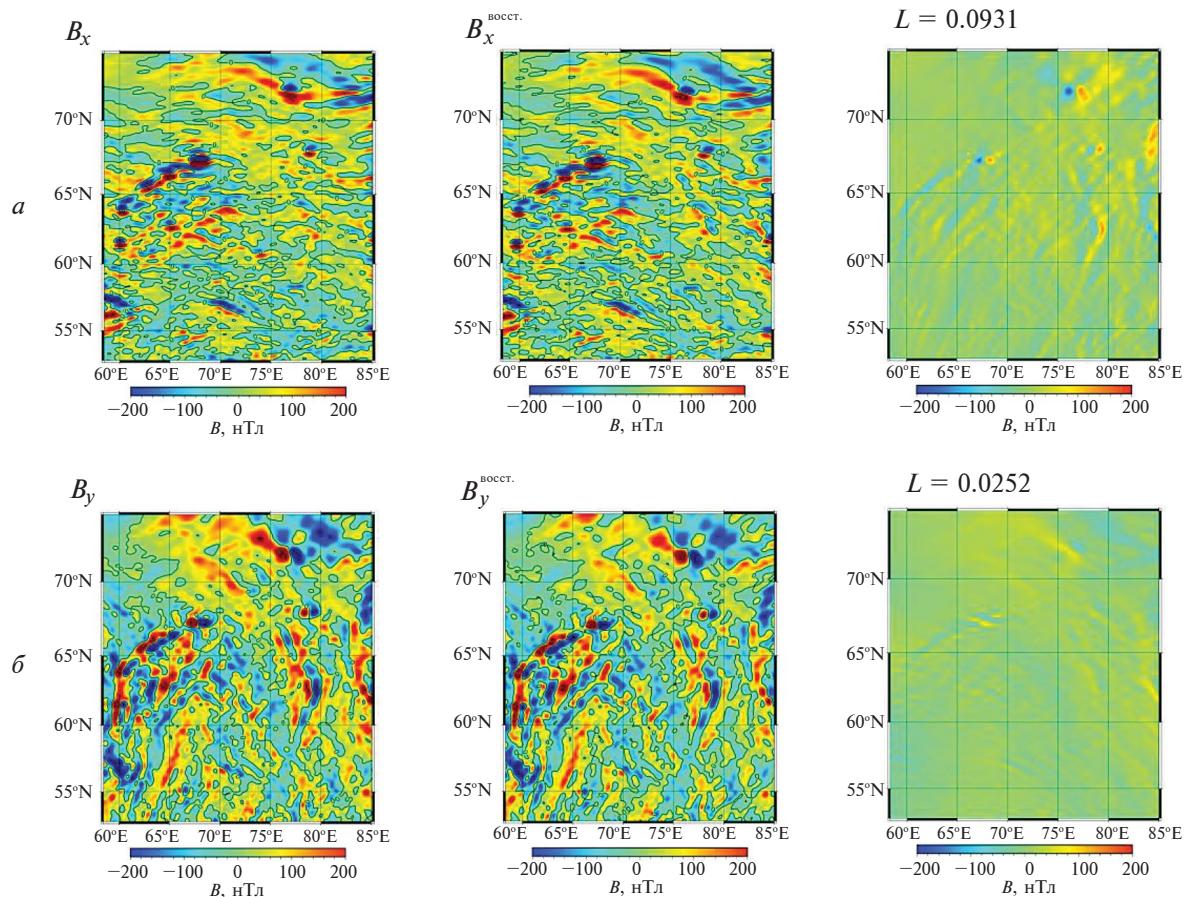


Рис. 6. Исходное аномальное магнитное поле, восстановленное аномальное магнитное поле с помощью обученной искусственной нейронной сети и разница между исходными и восстановленными компонентами (а)  $B_x$  и (б)  $B_y$ .

терполяции, реализованных в открытой библиотеке `scipy` [Virtanen et. al., 2020].

Серии на рис. 6а, 6б показывают истинные компоненты поля  $B_x$  и  $B_y$ , полученные из модели ЕММ, восстановленные компоненты  $B_x^{\text{восст.}}$  и  $B_y^{\text{восст.}}$  с помощью искусственной нейронной сети, а также разницу между истинными и восстановленными компонентами аномального магнитного поля. Так, для компоненты  $B_x$  функция невязки принимает значение  $L = 0.0931$ , для компоненты  $B_y$  функция невязки принимает значение  $L = 0.0252$ .

В области наиболее высокой интенсивности магнитных аномалий,  $|B_x| = 1642$  нТл,  $|B_y| = 1853$  нТл, погрешность принимает значения 170 нТл и 98 нТл соответственно. В области высоких широт погрешность для компоненты  $B_x$  наиболее велика, как показывает рис. 6а. Это может быть связано с большой протяженностью самих аномалий в данной области, около 400 px как показывает рис. 5б, в сравнении с протяженностью входного изображения нейронной сети, 40 px.

## 5. ЗАКЛЮЧЕНИЕ

В данной работе была разработана модель искусственной нейронной сети для восстановления векторного аномального магнитного поля по данным вертикальной компоненты поля. Нейронная сеть содержит в себе плотный входной слой для предварительного грубого расчета, результаты которого далее уточняются с помощью сверточной нейронной сети. Разработанная нейронная сеть была обучена на данных, созданных с помощью случайного распределения фиктивных точечных магнитных диполей, с помощью которых моделировалось аномальное магнитное поле над поверхностью земли.

Нейронная сеть показала в среднем лучшие результаты при сравнении с известной численной схемой восстановления компонент магнитного поля в плоскости. Обученная нейронная сеть восстанавливает компоненты поля с меньшими краевыми ошибками для случаев, когда магнитная аномалия не входит целиком в искомую область. Также нейронная сеть показала устойчивость к шуму во входных данных.

Результаты восстановления векторного поля на основе данных моделей IGRF и ЕММ показали высокую производительность работы нейронной сети с большим объемом входных данных. На данный момент ведется работа по дальнейшему тестированию и совершенствованию модели нейронной сети.

## ФИНАНСИРОВАНИЕ РАБОТЫ

Исследование проводилось в рамках государственного задания института.

## СПИСОК ЛИТЕРАТУРЫ

- Колесова В.И. Аналитические методы магнитной картографии. Москва: Наука, 1985.
- Колесова В.И., Черкаева Е.А. Вычисление компонент векторного аномального геомагнитного поля по модульным данным. Препринт № 46 (735). М.: ИЗМИРАН, 1987.
- Яновский Б.М. Земной магнетизм. Ленинград : Изд-во ЛГУ, 591 с. 1978.
- Abadi M. et al. Tensorflow: Large-scale machine learning on heterogeneous distributed systems //arXiv preprint arXiv:1603.04467. <https://doi.org/10.48550/arXiv.1603.04467>. 2016.
- Alken P., Thébault E., Beggan C.D., et al. International Geomagnetic Reference Field: the thirteenth generation // Earth, Planets and Space. V. 73. № 1. P. 1–25. <https://doi.org/10.1186/s40623-020-01288-x>. 2021.
- Barkhatov N.A., Vorobjev V.G., Revunov S.E., et al. Effect of solar dynamics parameters on the formation of substorm activity // Geomagn. Aeron. V. 57. P. 251–256. <https://doi.org/10.1134/S0016793217030021>. 2017.
- Buchanan A., Finn C.A., Love J.J., et al. Geomagnetic referencing—the real-time compass for directional drillers // Oilfield Review. V. 25. № 3. P. 32–47. 2013.
- Coskun U.H., Sel B., Plaster B. Magnetic field mapping of inaccessible regions using physics-informed neural networks //Scientific Reports. V. 12. № 1. P. 12858–12867. <https://doi.org/10.1038/s41598-022-15777-4>. 2022.
- Kaftan İ. Interpretation of magnetic anomalies using a genetic algorithm // Acta Geophysica. V. 65. № 4. P. 627–634. <https://doi.org/10.1007/s11600-017-0060-7>. 2017.
- Kaji C.V., Hoover RC., Ragi S. Underwater Navigation using Geomagnetic Field Variations / 2019 IEEE Intern. Conference on Electro Information Technology (EIT). <https://doi.org/10.1109/eit.2019.8834192>. 2019.
- Kingma D.P., Ba J. Adam: A method for stochastic optimization //arXiv preprint arXiv:1412.6980. 2014.
- Krizhevsky A., Sutskever I., Hinton G.E. Imagenet classification with deep convolutional neural networks // Advances in neural information processing systems. V. 25. P. 1097–1105. 2012.
- Lourenco J.S., Morrison H.F. Vector magnetic anomalies derived from measurements of a single component of the field // Geophysics. V. 38, № 2. P. 359–368. doi:10.1190/1.1440346. 1973.
- Maus S. An ellipsoidal harmonic representation of Earth's lithospheric magnetic field to degree and order 720, Geochem. Geophys. Geosyst., 11, Q06015, <https://doi.org/10.1029/2010GC003026>. 2010.
- Montesinos F.G., Blanco-Montenegro I., Arnoso J. Three-dimensional inverse modelling of magnetic anomaly

- sources based on a genetic algorithm // Physics of the Earth and Planetary Interiors. V. 253. P. 74–87. <https://doi.org/10.1016/j.pepi.2016.02.004>. 2016.
- Pollok S., Bjørk R., Jørgensen P.S. Inverse design of magnetic fields using deep learning // IEEE Transactions on Magnetics. V. 57. №. 7. P. 1–4. <https://doi.org/10.1109/TMAG.2021.3082431>. 2021.
  - Pollok S. et al. Magnetic field prediction using generative adversarial networks // Journal of Magnetism and Magnetic Materials. V. 571. P. 170556–170565. <https://doi.org/10.1016/j.jmmm.2023.170556>. 2023.
  - Virtanen P. et al. SciPy 1.0: fundamental algorithms for scientific computing in Python // Nature methods. V. 17. №. 3. P. 261–272. <https://doi.org/10.1038/s41592-019-0686-2>. 2020.
  - Ying X. An overview of overfitting and its solutions // Journal of physics: Conference series. — IOP Publishing. V. 1168. P. 022022–022029. <https://doi.org/10.1088/1742-6596/1168/2/022022>. 2019.
  - The National Centers for Environmental Information. (2018). [Online]. Available: <https://www.ngdc.noaa.gov/geomag/geomag.shtml>

## Application of Artificial Neural Networks for Reconstruction of Vector Magnetic Field from Single-Component Data

R. A. Rytov<sup>1,\*</sup>, V. G. Petrov<sup>1,\*\*</sup>

<sup>1</sup>Pushkov Institute of Terrestrial Magnetism, Ionosphere and Radio Wave Propagation, Russian Academy of Sciences, IZMIRAN, 142190, Troitsk, Moscow, Russia

\*e-mail: ruslan.rytov2017@ya.ru

\*\*e-mail: vgpetrov2018@mail.ru

In this work the problem of reconstructing the vector anomalous magnetic field from single-component data was solved by means of artificial neural networks. For training an artificial neural network a database of anomalous magnetic field components  $B_x$ ,  $B_y$ ,  $B_z$  was created using a set of point magnetic dipoles lying under the field measurement plane. Using a synthetic example, the work of a trained neural network was shown in comparison with a well-known numerical algorithm for restoring a vector field from data of one component. Further, according to the data of the vertical component of the anomalous geomagnetic field the horizontal components of the anomalous geomagnetic field were restored using artificial neural networks in the territory of  $58 - 85^\circ$  E,  $52 - 74^\circ$  N with a grid step of 2 arc minutes.

*Keywords:* artificial neural networks, anomalous magnetic field, vector magnetic field, computer modeling