

ПРИМЕНЕНИЕ СВЁРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ВЫДЕЛЕНИЯ
ОСЕЙ ЛИНЕЙНЫХ АНОМАЛИЙ МАГНИТНОГО ПОЛЯА. Д. Шклярुक* , К. М. Кузнецов 

Московский государственный университет имени М. В. Ломоносова, г. Москва, Россия

* **Контакт:** Алексей Дмитриевич Шклярук, alexsh9898@yandex.ru

Статья посвящена применению свёрточных нейронных сетей (СНС) для автоматизированного выделения осей линейных аномалий магнитного поля. В ходе работы составлена оригинальная архитектура СНС на основе U-Net с использованием предобученных весов VGG-16, обучение которой выполнено на выборке из 500 модельных примеров. Рассматриваемый в работе подход может стать оптимальным инструментом при структурной интерпретации аномальных магнитных полей. В результате апробации предлагаемых СНС, на примере поля одного из участков Баренцева моря, выделены оси линейных аномалий, во многом совпадающие с положением осей, полученных ручной экспертной интерпретацией, что показывает высокую эффективность применения современных технологий искусственных нейронных сетей.

Ключевые слова: Свёрточные нейронные сети, магниторазведка, линейные аномалии магнитного поля, Баренцево море, дайки.

Цитирование: Шклярук, А. Д. и Кузнецов К. М. Применение свёрточных нейронных сетей для выделения осей линейных аномалий магнитного поля // Russian Journal of Earth Sciences. — 2025. — Т. 25. — ES4007. — DOI: 10.2205/2025es001003 — EDN: OZAKIC

Введение

На сегодняшний день для решения различных задач изучения глубинного строения Земли, Луны и других объектов в комплексе геолого-геофизических методов активно используются потенциальные поля (гравитационное и магнитное). Их качественный анализ позволяет составить схемы, в том числе связанные с тектоникой изучаемых областей. В такой анализ входят выделение линейных структур поля, классификация и кластеризация аномалий и иные процедуры.

В рамках данной работы рассмотрена задача выделения линейных аномалий магнитного поля, которые могут быть приурочены, например, к различным протяжённым магматическим комплексам (дайкам), разломным зонам, а также техногенным линейным объектам и др. В настоящее время ее решение во многих случаях сводится на первом этапе к поиску наиболее информативных трансформант с подходящими ядрами преобразования (например, высокочастотная фильтрация, вычисление полного горизонтального градиента и т.п.), и на втором этапе – ручная экспертная интерпретация. В данной работе рассмотрен метод по выделению линейных структур потенциальных полей, основанный на свёрточных нейронных сетях.

Основные понятия

Свёрточная нейронная сеть (СНС) – это тип многослойного персептрона (нейронной сети прямого распространения), часть слоёв которой сконструирована таким образом, что связь между ними описывается дискретной свёрткой [Хайкин, 2016; Venkatesan and Li, 2017]. На вход таких слоёв подаётся числовая матрица, с которой сворачивается ядро, определяемое весами нейронов. На выход представляется матрица числовых признаков, которая, в свою очередь, подаётся на вход следующего слоя (рис. 1).

<https://elibrary.ru/ozakic>

Получено: 24 ноября 2024 г.

Принято: 24 февраля 2025 г.

Опубликовано: 10 июля 2025 г.



© 2025. Коллектив авторов.




Рис. 1. Схема работы свёрточного слоя.

Матрица, получаемая в результате свёртки, обладает меньшим размером, т.к. центр ядра преобразования не может совпадать с положением крайних значений входной матрицы [Stankovic and Mandic, 2021]. Это видно из рис. 1, где невозможно переместить ядро выше или левее. В случае, если размерность выходной матрицы должна совпадать с размерностью входной применяется метод *padding* – искусственное добавление нулевых значений по краям входной матрицы. Если на выходе наоборот нужны матрицы меньшего размера, то применяется метод – *striding* – увеличение шага перемещения ядра свёртки [Stankovic and Mandic, 2021]. Такие методы могут быть представлены отдельными слоями нейронной сети.

Также в практике применения СНС применяются слои *объединения (пуллинга)*, представляющие собой сжатие матрицы путём сложения значений её соседних элементов (рис. 2а). Этот слой важен для извлечения доминирующих признаков. Объединение может быть основано на выборе максимального или среднего значения в блоке. Существует и обратная операция, увеличивающая размерность матрицы – *расширение (апсемплинг)* (рис. 2б) [Stankovic and Mandic, 2021].

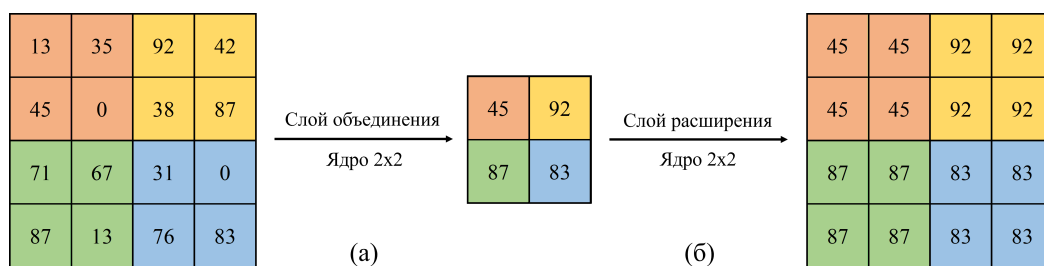


Рис. 2. Пример работы слоя объединения (а) и слоя расширения (б).

Создание обучающей выборки

Для выбора архитектуры свёрточной нейронной сети и определения весов её нейронов, получаемых в ходе обучения, необходимо подготовить обучающую выборку. В ходе данной работы она составлена из примеров, которые включают пары входных (магнитное поле) и выходных (положение линеаментов) матриц. Обучающая выборка может быть как собрана на основе размеченных реальных примеров данных, так и создана синтетическим путём. При этом важно, чтобы она была репрезентативной и включала достаточное количество примеров для эффективного обучения алгоритма.

Обучающая выборка может достигать нескольких сотен, а порой и тысяч отдельных примеров. Одной из сложностей при использовании машинного обучения для решения задач интерпретации потенциальных полей является затруднённый поиск и подготовка необходимого большого количества реальных проинтерпретированных (размеченных) данных. Поэтому в работе массив данных создан синтетическим путём. В дальнейшем для улучшения результатов планируется дополнительно использовать реальные примеры для обучения.

В качестве модели аномального магнитного поля ΔT линейно вытянутого источника рассмотрен эффект прямоугольной призмы, геометрические параметры которой близки к модели дайки [Булывчев и др., 2019]:

$$\Delta T = \sqrt{(T_{0X} + X)^2 + (T_{0Y} + Y)^2 + (T_{0Z} + Z)^2} - T_0,$$

где X, Y, Z – компоненты аномального магнитного поля, T_0 – нормальное магнитное поле, а T_{0X}, T_{0Y}, T_{0Z} – соответствующие его компоненты. В рамках данной работы рассмотрены только вертикально намагниченные прямоугольные призмы, компоненты магнитного эффекта которых можно записать [Plouff, 1976]:

$$X = J_z \ln(r + \eta_i) \begin{vmatrix} \xi_2 & \eta_2 \\ \xi_1 & \eta_1 \end{vmatrix} \begin{vmatrix} \zeta_2 \\ \zeta_1 \end{vmatrix};$$

$$Y = J_z \ln(r + \xi_i) \begin{vmatrix} \xi_2 & \eta_2 \\ \xi_1 & \eta_1 \end{vmatrix} \begin{vmatrix} \zeta_2 \\ \zeta_1 \end{vmatrix};$$

$$Z = -J_z \arctan\left(\frac{\xi_i \eta_i}{\zeta_i r}\right) \begin{vmatrix} \xi_2 & \eta_2 \\ \xi_1 & \eta_1 \end{vmatrix} \begin{vmatrix} \zeta_2 \\ \zeta_1 \end{vmatrix}.$$

где J_z – намагниченность призмы, ξ_i, η_i, ζ_i – координаты границ призмы по осям O_x, O_y и O_z соответственно в предположении, что точка расчёта расположена в начале системы координат, а r – расстояние от точки расчёта до угла призмы с координатами ξ_i, η_i, ζ_i .

Для расчёта формируется область размером 192×192 ячейки, что при масштабе, например, 1:10 000 соответствует области порядка 20×20 км. Важно отметить, что размер ячеек матрицы не является параметром, участвующим в обучении и работе нейронной сети. Количество ячеек выбрано исходя из архитектуры нейронной сети, используемой в работе, обусловленной скоростью обучения и возможностями персонального компьютера.

Алгоритм создания обучающей выборки состоит из следующих пунктов:

1. С помощью генератора случайных чисел задаются положение и геометрические параметры призмы, а именно ширина, длина, высота и угол поворота, а также намагниченность и параметры нормального поля. Пределы изменчивости параметров подобраны таким образом, чтобы вычисляемые аномалии магнитного поля были подобны реально зафиксированным;
2. Вычисляется магнитный эффект полученной призмы в точках матрицы размером 192×192 ячеек (рис. 3а);
3. Создаётся матрица, характеризующая положение линеаментов. В ней над источником задаётся значение 1, а остальные ячейки равны 0 (рис. 3б);
4. Создаётся матрица со значениями искусственной помехи (шума): для каждой ячейки вычисляется случайно значение из диапазона 10–50% от амплитуды рассчитанного поля. Поскольку синтетические модели должны характеризовать реально существующие поля, характеризующиеся гладкой формой, то полученная матрица сглаживается фильтром осреднения в скользящем окне размером 30×30 ячеек (рис. 3в);
5. Полученный магнитный эффект призмы и шума суммируются (рис. 3г).




Рис. 3. Пример модели из обучающей выборки: (а) – магнитный эффект линейно вытянутой призмы; (б) – положение линеаэнта, используемое для обучения СНС; (в) – случайный шум; (г) – итоговая модель для обучения СНС.

Для эффективного обучения нейронной сети необходимо привести входные данные (аномальное магнитное поле) к размерности выходных (матрица, характеризующая положение линеаэнта) – выполнить нормализацию. Это особенно важно при работе с большими объёмами данных, где каждый элемент может иметь различный диапазон значений. Полученная матрица магнитного поля нормализуется и приводится к диапазону от 0 до 1.

В результате каждый пример из обучающей выборки включает в себя две матрицы: магнитное поле и положение линейной структуры. Для приближения синтетических данных к реальным одна модель включает случайное количество от 1 до 10 линейных объектов, случайным образом расположенных на карте.

Для обучения нейронной сети создан массив из 500 наборов полей и положения линеаэнтов.

Создание модели нейронной сети и её обучение

Для решения задачи необходимо выбрать оптимальную архитектуру СНС, включающую в себя различные компоненты, такие как свёрточные слои, слои пулинга и иные скрытые слои, таким образом, чтобы наиболее эффективно обрабатывать входные данные и переходить от конкретных особенностей входной матрицы к более абстрактным деталям. Кроме того, каждый слой нейронной сети может включать различные функции активации нейронов [Хайкин, 2016].

Задачу выделения линейных структур в поле можно отнести к задаче сегментации изображения [Shapiro and Stockman, 2000]. В настоящее время в различных сферах для решения подобных задач применяется готовая архитектура свёрточной нейронной сети – U-Net. Она названа в честь буквы «U», которую напоминает её структура (рис. 4).

Эта архитектура имеет две части: кодирующую, которая уменьшает размер изображения, и декодирующую, которая увеличивает его обратно [Ronneberger et al., 2015].

Кодирующая часть состоит из нескольких свёрточных слоёв, которые последовательно уменьшают пространственное разрешение модели, одновременно увеличивая число каналов (глубину) карты признаков. Это позволяет создавать более информативные признаки аномального магнитного поля. Декодирующая часть также состоит из нескольких свёрточных слоёв, которые увеличивают размер изображения и постепенно уменьшают количество признаков, приводя их к 1-му результативному [Ronneberger et al., 2015].

В архитектуре СНС U-Net веса в кодирующей и декодирующей частях связаны, что позволяет сохранять детали входных данных несмотря на множество слоёв, уменьшающих их размерность [Ronneberger et al., 2015].

До обучения СНС первоначальные веса задаются случайным образом. Для улучшения обучения нейронной сети возможно использовать предобученные веса модели глубокого обучения, эффективно решающие задачи сегментации объектов на изображениях. В языке программирования Python существует множество моделей СНС, обученных сегментировать изображения: VGG [Simonyan and Zisserman, 2014] (рис. 5), ResNet [He et al., 2016], Inception [Szegedy et al., 2015], EfficientNet [Tan and Le, 2019] и др. Все они обучены на выборке, состоящей из более чем 14 миллионов изображений, представленным в базе данных ImageNet [Deng et al., 2009]. Данные сети обучены для сегментации изображений, не связанных с геолого-геофизическими задачами, поэтому использовать веса без дообучения в нашей задаче невозможно.




Рис. 4. Схема свёрточной нейронной сети архитектуры U-Net [Ronneberger et al., 2015].

Вышеперечисленные модели различаются между собой количеством слоёв свёртки и пулинга, но принцип действия у них схож. Для задачи выделения линейных аномалий опытным путём выбрана сеть VGG-16 (рис. 5), которая состоит из 16 настраиваемых слоёв: 13 слоёв свёртки и 3 полносвязанных слоёв. Также в данной сети присутствует 5 слоёв пулинга, которые уменьшают изображение вдвое. Можно выделить несколько преимуществ в использовании предобученных весов VGG-16 [Simonyan and Zisserman, 2014]:

1. Ранние слои VGG-16 (первые свёртки) обучены распознавать универсальные паттерны: границы, текстуры, линии. Эти признаки полезны даже для неродственных задач (например, линейных магнитных аномалий);

2. Предобученные веса служат хорошей начальной точкой, сокращая время обучения. Модель не начинает «с нуля», а сразу фокусируется на адаптации к поставленной задаче;
3. Использование предобученных весов снижает риск переобучения, особенно если данных мало.

Для построения собственной СНС типа U-Net с предобученными весами сети VGG-16 случайные веса декодера (левая часть на рисунке 4) сети U-Net заменены на предобученные веса сети VGG-16. На следующем этапе СНС дообучалась на подготовленной выборке, описанной выше (рис. 3) [Шклярчук и Кузнецов, 2024].

Для оценки точности обучения выполнено разделение подготовленной выборки на обучающую и тестовую в соотношении 80:20 соответственно.

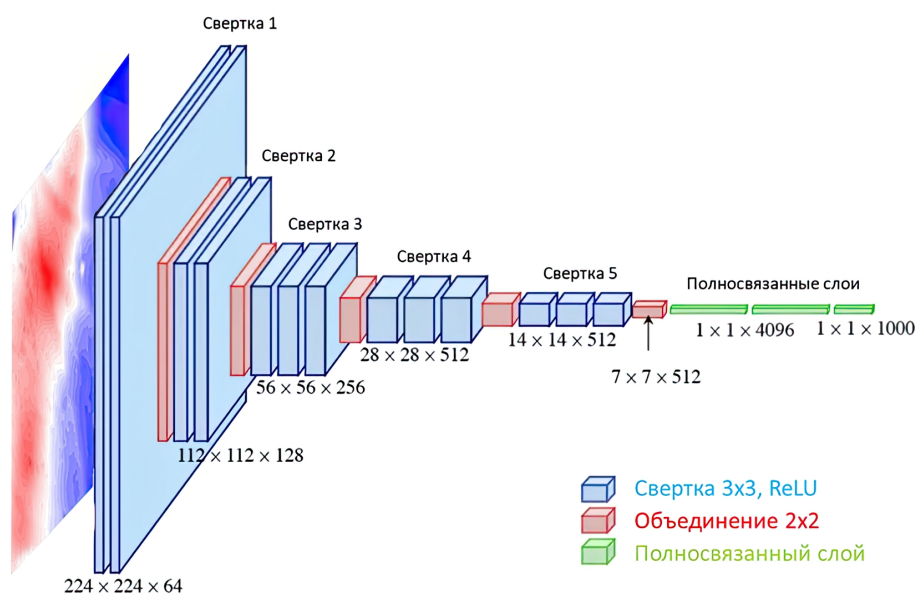


Рис. 5. Сверточная нейронная сеть VGG16 (по [Simonyan and Zisserman, 2014] с дополнениями).

При обучении нейронной сети необходимо задать гиперпараметры [Хайкин, 2016]:

1. Оптимизатор, который будет использоваться для минимизации функции потерь. Некоторые из популярных оптимизаторов: Adam, SGD (Stochastic Gradient Descent), RMSProp и другие;
2. Скорость обучения, которая определяет, насколько существенно будут корректироваться веса нейронной сети с учётом функции потерь при её обучении;
3. Метрика для оценки качества модели нейронной сети во время обучения. Это может быть, например, средняя квадратическая ошибка (MSE), кросс-энтропия (Cross-entropy), среднее расхождение (Accuracy) и др.;
4. Количество эпох, то есть количество циклов обучения на всем наборе данных;
5. Размер батча, который определяет, сколько моделей из выборки для обучения будет обработано за одну эпоху обучения.

Во время обучения нейронной сети важно отслеживать изменение ошибок, чтобы определить, когда модель достигает оптимального уровня производительности.

Для решения задачи выделения линейных аномалий потенциальных полей были выбраны следующие параметры обучения: оптимизатор – Adam, скорость обучения – 0,0001, метрика оценки качества – Accuracy + Cross Entropy, количество эпох – 50, размер батча (количество карт для одной эпохи) – 25. На синтетических примерах по метрике Accuracy получено значение – 0,996, по MSE – 0,003.

Апробация обученной СНС на модельном примере

Для оценки точности работы нейронной сети создана валидационная выборка из модельных примеров, которые не входили ни в обучающую, ни в тестовую выборки. Она состоит из 100 примеров, на которых количество линейных аномалий на одной карте варьировалось от 6 до 10. На синтетических примерах с большим количеством линеаментов (от 6 до 10) свёрточная нейронная сеть работает с точностью более 0,9 по метрике Ассигасу (рис. 6). Основные ошибки возникают на пересечениях линеаментов и на краях моделей аномального магнитного поля.

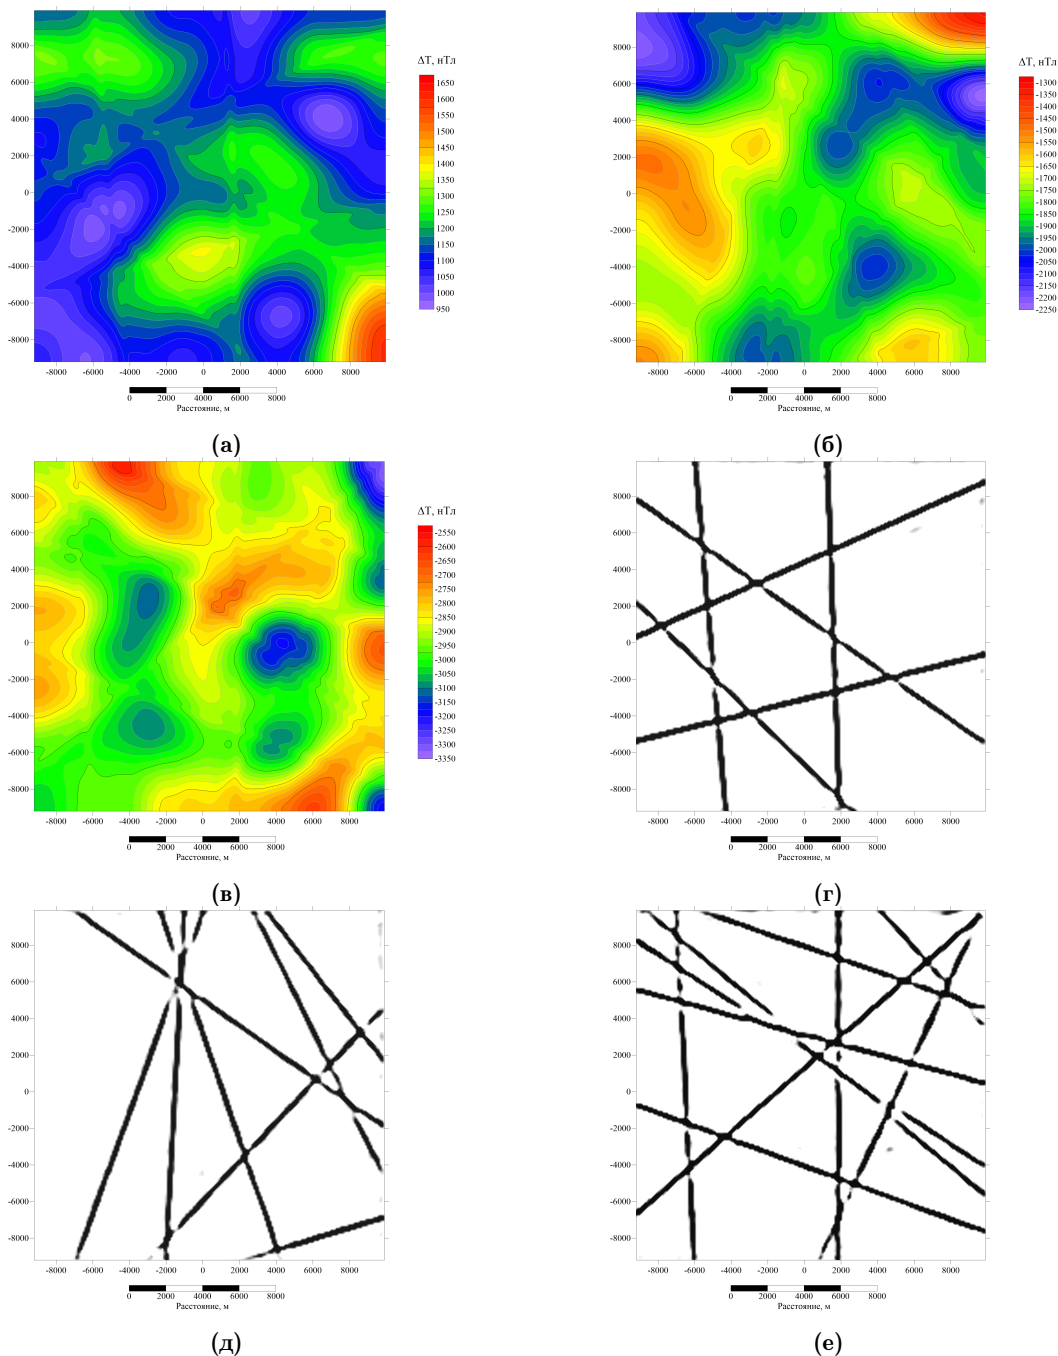


Рис. 6. Результат работы СНС на синтетических примерах: (а), (б), (в) – модельные примеры с линейными аномалиями; (г), (д), (е) – выделенные линеаменты с помощью СНС.

Апробация обученной СНС на примере поля участка Баренцева моря

В качестве примера для отработки алгоритма полученной СНС использовано аномальное магнитное поле участка Баренцева моря. В регионе широко распространена сеть даек различного простирания, проявленных в магнитном поле в виде линейных аномалий [Лыгин и др., 2023]. В качестве примера рассмотрен небольшой участок (50 × 50 км) высокоточной детальной гидромагнитной съёмки, в периметре которого в аномальном магнитном поле отчётливо проявляются крупные дайки (рис. 7). Предварительно, для использования обученной СНС, размерность модели аномального магнитного поля разрежалась до размера 192 × 192 ячейки. Стоит отметить, что рассматриваемый алгоритм применим к картам любого размера. Чтобы применить СНС для данных иного размера необходимо выполнить две процедуры: 1) увеличение размера матрицы данных до размеров кратных 192 путём добавления ячеек с нулевыми значениями и 2) разделение всей области данных на патчи размером 192 × 192 ячейки.




Рис. 7. Аномальное магнитное поле участка детальных гидромагнитных работ Баренцева моря.

Свёрточная нейронная сеть, обученная на синтетических моделях, применена к аномальному магнитному полю с целью выделения линейных магнитных аномалий, связанных с эффектом от даек (рис. 7). На рис. 8 представлено сравнение результатов применения СНС (чёрный цвет) и результатов комплексной интерпретации, описанной в работе [Черников и др., 2020] (жёлтый цвет). Стоит отметить, что несмотря на то, что в примерах из обучающей выборки максимальное количество линеаментов – 10, полученная СНС способна выделять неограниченное количество линейных элементов. Связано это в первую очередь с тем, что сеть не учитывает семантику «объектов», а лишь активирует соответствующие пиксели, похожие на обученные паттерны.

Результат выделенных аномалий с помощью СНС визуально коррелирует с результатом комплексной интерпретацией. Однако при этом в результатах работы сети есть области, не выделенные экспертом. Также встречаются области, которые не связаны в единый массив, хотя и составляют цепочку. Для подтверждения выделенных линеаментов рассчитана высокочастотная составляющая аномального магнитного поля (Фильтр высоких частот (ФВЧ) – 5 км) (рис. 9). Видно, что линеаменты, невыделенные с помощью комплексной интерпретации [Черников и др., 2020], но выделенные с помощью СНС, относятся к положительным линейным высокочастотным магнитным аномалиям. Дополнительно выделенные линеаменты требуют подтверждения с помощью других геофизических методов, например сейсморазведки или данных бурения.

Важно отметить, что применение свёрточной нейронной сети является инструментом и требует дальнейшей экспертной интерпретации.




Рис. 8. Оси линейных аномалий магнитного поля, приуроченных к дайковому комплексу, полученные по результатам использования СНС (чёрный цвет) и по результатам комплексной интерпретации [Черников и др., 2020] (жёлтый цвет).

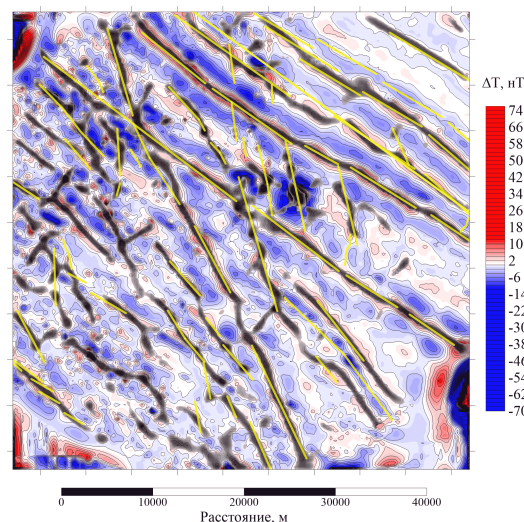


Рис. 9. Высокочастотная составляющая аномального магнитного поля (ФВЧ – 5 км) с нанесёнными осями линейных аномалий магнитного поля, приуроченных к дайковому комплексу, полученные по результатам использования СНС (чёрный цвет) и по результатам комплексной интерпретации [Черников и др., 2020] (жёлтый цвет).

Выводы

Применение свёрточных нейронных сетей является актуальной и важной задачей в контексте современных исследований в области геофизики. Вот несколько аспектов, по которым эта тема актуальна:

1. *Оптимизация ресурсов:* Автоматическое выделение аномалий с использованием СНС может существенно снизить необходимость вручную обрабатывать и анализировать большие объёмы данных. Это позволяет исследователям сосредотачиваться на более сложных аспектах исследования, а также оптимизировать использование вычислительных ресурсов.
2. *Улучшение точности выделения аномалий:* СНС обладают способностью извлекать сложные пространственные и временные зависимости из данных. Это способствует более точному и эффективному выделению линейных аномалий в геофизических полях, что может привести к более надёжным результатам интерпретации.

3. *Применение в различных областях геофизики*: технологии обработки данных, основанные на свёрточных нейронных сетях, могут быть успешно применены в различных областях геофизики. Это делает данную тему универсальной и перспективной для различных направлений исследований.
4. *Развитие методов обработки данных*: внедрение свёрточных нейронных сетей в геофизические исследования способствует развитию методов обработки и анализа данных в целом. Это может привести к новым подходам к решению проблем и задач, связанных с геофизическими измерениями и наблюдениями.

В ходе исследования построен и протестирован на модельных и реальных данных алгоритм на основе свёрточной нейронной сети для решения задачи выделения линейных аномалий магнитного поля. Приведённые примеры для Баренцева моря, позволяют предположить, что алгоритм выделения линейных аномалий магнитного поля может являться инструментом качественной интерпретации. Данный метод может послужить основой для разработки и совершенствования новых подходов к решению разнообразных задач в области геофизических исследований.

Благодарности. Исследования выполнены при финансовой поддержке Междисциплинарных научно-образовательных школ Московского университета в рамках Соглашения № 23-Ш01-13.

Список литературы

- Булгычев А. А., Лыгин И. В., Соколова Т. Б. и др. Прямая задача гравиразведки и магниторазведки (конспект лекций). — Москва : Университетская книга, 2019. — 176 с.
- Лыгин И. В., Арутюнян Д. А., Соколова Т. Б. и др. Картирование магматических комплексов по данным гидромагнитных съемок Баренцевоморского региона // Физика Земли. — 2023. — № 4. — С. 96–114. — <https://doi.org/10.31857/s0002333723040075>.
- Хайкин С. Нейронные сети: полный курс, 2-е издание. — Издательский дом «Вильямс», 2016. — 1104 с.
- Черников К. С., Горбачев С. В., Голованов Д. Ю. и др. Геологическая и экономическая эффективность применения гравиразведки и магниторазведки на разных стадиях геолого-разведочных работ // Геология нефти и газа. — 2020. — № 2. — С. 107–120. — <https://doi.org/10.31087/0016-7894-2020-2-107-120>.
- Шклярук А. Д. и Кузнецов К. М. Программа для выделения осей линейных аномалий магнитных и гравитационных полей на основе сверточных нейронных сетей RU 2024685140. — Федеральная служба по интеллектуальной собственности РФ, 2024.
- Deng J., Dong W., Socher R., et al. ImageNet: A large-scale hierarchical image database // 2009 IEEE Conference on Computer Vision and Pattern Recognition. — IEEE, 2009. — <https://doi.org/10.1109/cvpr.2009.5206848>.
- He K., Zhang X., Ren S., et al. Identity Mappings in Deep Residual Networks. — arXiv, 2016. — <https://doi.org/10.48550/ARXIV.1603.05027>.
- Plouff D. Gravity and Magnetic fields of polygonal prisms and application to magnetic terrain corrections // Geophysics. — 1976. — Vol. 41, no. 4. — P. 727–741. — <https://doi.org/10.1190/1.1440645>.
- Ronneberger O., Fischer P. and Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation // Medical Image Computing and Computer-Assisted Intervention - MICCAI 2015. — Springer International Publishing, 2015. — P. 234–241. — https://doi.org/10.1007/978-3-319-24574-4_28.
- Shapiro L. G. and Stockman G. C. Computer Vision. — Prentice-Hall, 2000. — 375 p.
- Simonyan K. and Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition. — arXiv, 2014. — <https://doi.org/10.48550/ARXIV.1409.1556>.
- Stankovic L. and Mandic D. Convolutional Neural Networks Demystified: A Matched Filtering Perspective Based Tutorial. — arXiv, 2021. — <https://doi.org/10.48550/ARXIV.2108.11663>.
- Szegedy C., Vanhoucke V., Ioffe S., et al. Rethinking the Inception Architecture for Computer Vision. — arXiv, 2015. — <https://doi.org/10.48550/ARXIV.1512.00567>.
- Tan M. and Le Q. V. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. — arXiv, 2019. — <https://doi.org/10.48550/ARXIV.1905.11946>.
- Venkatesan R. and Li B. Convolutional Neural Networks in Visual Computing: A Concise Guide. — CRC Press, 2017. — 186 p. — <https://doi.org/10.4324/9781315154282>.

THE APPLICATION OF CONVOLUTIONAL NEURAL NETWORKS FOR EXTRACTION OF MAGNETIC ANOMALY FIELD LINEAMENTS

A. D. Shklyaruk*  and K. M. Kuznetsov 

Lomonosov Moscow State University, Moscow, Russia

**Correspondence to: Alexey Shklyaruk, alexsh9898@yandex.ru

The article focuses on the application of convolutional neural networks (CNNs) for automated extraction of magnetic anomaly field lineaments. In the course of the work, an original CNN U-Net based architecture with pre-trained VGG-16 weights was developed, and its training was conducted on a sample of 500 model examples. The approach presented in this work can be an optimal tool for structural interpretation of magnetic anomaly fields. As a result of testing the proposed CNNs for magnetic field of the Barents Sea local area, the axes of the linear anomalies were identified, largely coinciding with the position of the axes obtained by manual expert interpretation. These fact demonstrates the high efficiency of applying modern artificial neural network technologies.

Keywords: Convolutional Neural Networks, magnetometry, linear anomalies of the magnetic field, Barents Sea, dykes

Received: November 24, 2024

Accepted: February 24, 2025

Published: July 10, 2025



© 2025. The Authors.

Citation: Shklyaruk, A. D. and Kuznetsov K. M. (2025), The Application of Convolutional Neural Networks for Extraction of Magnetic Anomaly Field Lineaments, *Russian Journal of Earth Sciences*, 25, ES4007, <https://doi.org/10.2205/2025ES001003>, EDN: OZAKIC

References

- Bulychev A. A., Lygin I. V., Sokolova T. B., et al. Direct problem of gravity and magnetic exploration (lecture notes. — Moscow : Universitetskaya kniga, 2019. — 176 p. — (In Russian).
- Chernikov K. S., Gorbachev S. V., Golovanov D. Yu., et al. Geological and Economic Efficiency of the Use of Gravity and Magnetic Exploration at Different Stages of Geological Exploration // *Russian Oil and Gas Geology*. — 2020. — No. 2. — P. 107–120. — <https://doi.org/10.31087/0016-7894-2020-2-107-120>. — (In Russian).
- Deng J., Dong W., Socher R., et al. ImageNet: A large-scale hierarchical image database // 2009 IEEE Conference on Computer Vision and Pattern Recognition. — IEEE, 2009. — <https://doi.org/10.1109/cvpr.2009.5206848>.
- Haykin S. *Neural networks: A comprehensive foundation*. — Prentice Hall, 1999. — 1104 p.
- He K., Zhang X., Ren S., et al. Identity Mappings in Deep Residual Networks. — arXiv, 2016. — <https://doi.org/10.48550/ARXIV.1603.05027>.
- Lygin I. V., Arutyunyan D. A., Sokolova T. B., et al. Mapping of Magmatic Complexes Based on Hydromagnetic Surveys in the Barents Sea Region // *Izvestiya, Physics of the Solid Earth*. — 2023. — Vol. 59, no. 4. — P. 586–603. — <https://doi.org/10.1134/s1069351323040079>.
- Plouff D. Gravity and Magnetic fields of polygonal prisms and application to magnetic terrain corrections // *Geophysics*. — 1976. — Vol. 41, no. 4. — P. 727–741. — <https://doi.org/10.1190/1.1440645>.
- Ronneberger O., Fischer P. and Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation // *Medical Image Computing and Computer-Assisted Intervention - MICCAI 2015*. — Springer International Publishing, 2015. — P. 234–241. — https://doi.org/10.1007/978-3-319-24574-4_28.
- Shapiro L. G. and Stockman G. C. *Computer Vision*. — Prentice-Hall, 2000. — 375 p.
- Shklyaruk A. D. and Kuznetsov K. M. Program for identifying axes of linear anomalies of magnetic and gravitational fields based on convolutional neural networks RU 2024685140. — Federal Service for Intellectual Property of the Russian Federation, 2024. — (In Russian).
- Simonyan K. and Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition. — arXiv, 2014. — <https://doi.org/10.48550/ARXIV.1409.1556>.
- Stankovic L. and Mandic D. Convolutional Neural Networks Demystified: A Matched Filtering Perspective Based Tutorial. — arXiv, 2021. — <https://doi.org/10.48550/ARXIV.2108.11663>.

- Szegedy C., Vanhoucke V., Ioffe S., et al. Rethinking the Inception Architecture for Computer Vision. — arXiv, 2015. — <https://doi.org/10.48550/ARXIV.1512.00567>.
- Tan M. and Le Q. V. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. — arXiv, 2019. — <https://doi.org/10.48550/ARXIV.1905.11946>.
- Venkatesan R. and Li B. Convolutional Neural Networks in Visual Computing: A Concise Guide. — CRC Press, 2017. — 186 p. — <https://doi.org/10.4324/9781315154282>.