

МЕТОДЫ И СРЕДСТВА ОБРАБОТКИ И ИНТЕРПРЕТАЦИИ КОСМИЧЕСКОЙ ИНФОРМАЦИИ

РАЗРАБОТКА МЕТОДИКИ АВТОМАТИЧЕСКОГО ВЫДЕЛЕНИЯ ЛИНЕАМЕНТОВ НА ОСНОВЕ НЕЙРОСЕТЕВОГО ПОДХОДА

© 2023 г. Г. А. Гришков^а, *, И. О. Нафигин^а, С. А. Устинов^а, В. А. Петров^а, В. А. Минаев^а

^аФедеральное государственное бюджетное учреждение науки Институт геологии рудных месторождений, петрографии, минералогии и геохимии Российской академии наук (ИГЕМ РАН), г. Москва, Россия

*E-mail: gorgulini@yandex.ru

Поступила в редакцию 04.04.2023 г.

Целью научной работы является изучение потенциала нейросетевых технологий в области извлечения линейных структур из цифровых моделей рельефа SRTM. Линейные структуры, также известные как линеаменты, играют важную роль при заверке известных разломов, выявлении разломно-трещинных структур, детализации каркаса разрывных нарушений, а также при разведке полезных ископаемых. Их точное и эффективное извлечение при решении обозначенных задач имеет принципиальное значение. Привлечение нейросетевых технологий дает ряд преимуществ перед последовательными алгоритмами, включая возможность поиска универсальных критериев для выделения линеаментов на основе обучающей выборки. В работе рассматривается комплексная инновационная методология, включающая несколько ключевых этапов. Первый этап является авторским методом подготовки данных, который помогает обеспечить качество обучающей выборки и минимизировать влияние шума. Второй этап заключается в разработке алгоритма векторизации результатов работы нейронной сети, позволяющего легко экспортировать результаты (линеаменты) в географическую информационную систему (ГИС). Третий этап обеспечивает метод минимизации шумовой составляющей обучающей выборки и оптимизации выбора синаптических весовых коэффициентов путем дообучения нейронной сети с использованием смоделированных данных, отражающих различные условия локализации линеаментов. Для верификации полученных результатов проведено пространственное сравнение линейных структур, извлеченных нейронной сетью, и линеаментов, выделенных оператором. Результаты этого сравнения демонстрируют высокий потенциал предложенного подхода и показывают, что использование нейросетевых технологий является актуальным и перспективным подходом для решения задачи извлечения линейных структур из цифровых моделей рельефа. Сделаны положительные выводы о целесообразности использования полученных результатов для их практического применения в области наук о Земле.

Ключевые слова: линеаменты, нейронные сети, цифровая модель рельефа, линейные структуры, неотектоника, геоинформационная система, разрывные нарушения, python, tensorflow, keras

DOI: 10.31857/S0205961423060040, **EDN:** DGOQRA

ВВЕДЕНИЕ

В последние годы число задач, для решения которых применяются нейронные сети, постоянно увеличивается. В основе нейросетевых технологий лежат не стандартные алгоритмические условия, как в большинстве программного обеспечения, а вероятностная модель, использующая регрессионный или классификационный подход для прогнозирования результата (Гришков и др., 2021). Кроме того, с развитием вычислительных методов (Dramschi, 2020) и совершенствованием технических параметров персональных компьютеров применение нейросетевых технологий стало доступно широкому кругу пользователей.

Нейронные сети применяются во многих областях науки, таких как медицина фармакология, геология и т.д. Одними из первых методы ней-

ронных сетей нашли применение в следующих областях геологических исследований: дистанционное зондирование (Lary et al., 2016), геоморфология (Valentine, Kalnins, 2016), гидрогеофизика (Shen, 2018), сейсмология (Kong et al., 2019), геодинамика (Wang et al., 2018), геохимия (Zuo et al., 2019). А также нейронные сети успешно применяются в области разведки полезных ископаемых (Gonbadi et al., 2015; Zhao et al., 2016; Zuo et al., 2018).

Наряду с перечисленными работами, наше исследование направлено на развитие методов применения нейросетевых технологий на разных стадиях геологоразведочных работ. Основной акцент сделан на разработку автоматического метода выделения линейных структур (линеаментов) по цифровым моделям рельефа (ЦМР).

Таблица 1. Параметры SRTM

Проекция	Географическая
Горизонтальная система координат	WGS84
Вертикальная система координат	EGM96 (Earth Gravitational Model 1996)
Вертикальные единицы измерения	Метры
Пространственное разрешение	1 угловая секунда для глобального охвата (30 метров)
Размер растра	30 м/п
Длина волны С-диапазона	5.6 см

Термин “линеамент” введен в литературу американским геологом У. Хоббсом в 1911 г. для обозначения вытянутых в одном направлении линейных элементов рельефа и геологических структур (Чернова и др., 2012). Линеаментный анализ часто проводится для заверки известных разломов, выявления разломно-трещинных структур и детализации каркаса разрывных нарушений. Данный анализ является одним из наиболее эффективных дистанционных методов изучения каркаса разрывных нарушений и глубинного строения территорий (Кац и др., 1986).

На текущий момент существует множество подходов к выделению линеаментов. Как правило, выделение производится на основе оптических (аэро- и космоснимков) и радарных данных, а также цифровых моделях местности и рельефа. В связи с разнородной физической основой исходных данных весьма затруднительно разработать универсальный подход к выделению линеаментов. Тем не менее, предпринимаются попытки по созданию таких алгоритмов, реализованных в следующих программных обеспечениях: “SimSGM” (Молчанов, Гордеев, 2021); “LEFA” (Шевырев, 2018); “ALINA” (Щепин и др., 2007); “LESSA” (Zlatopolsky, 1992). Тем не менее, все эти программные продукты реализованы на основе последовательных алгоритмов (математических функций) и имеют перечень входных параметров (переменных), что в свою очередь приводит к неоднозначности результатов выделения линейных объектов. Привлечение нейросетевых технологий может нивелировать эти недостатки и, следовательно, установить универсальные критерии выделения линеаментов.

В настоящее время существует множество разновидностей нейронных сетей: прямого распространения, рекуррентные, с долгой краткосрочной памятью и т.д. Выбор архитектуры нейронной сети всегда уникален и определяется типом поставленной задачи (регрессия, классификация, прогнозирование) и входными данными (цифровые сигналы, изображения и т.д.) (Логинов, Петров, 2019).

И ввиду того, что в рамках текущего исследования стоит задача применения нейросетевых

технологий для автоматического выделения линеаментов на основе цифровых моделей рельефа (ЦМР), то ее решение обеспечивается сверточными нейронными сетями (СНС). Это связано с тем, что СНС хорошо себя зарекомендовали при решении задач, связанных с обработкой изображений, т.е. матриц (LeCun et al., 2015).

Как правило, СНС основаны на фундаментальных концепциях работы нейронных сетей и направлены на извлечение наборов уникальных признаков изображения или конкретного объекта. Это достигается за счет параллельной обработки изображения в различных слоях сети с помощью чередования слоев свертки (обработка изображения локальными операциями с помощью фильтров) и сжатия (сжатие изображения, объединения значения фильтров), а также полносвязного слоя, формирующего итог из полученных значений.

ФАКТИЧЕСКИЙ МАТЕРИАЛ

В основу работы лег следующий фактический материал:

- цифровые модели рельефа (ЦМР);
- линеаменты, выделенные ручным способом в результате анализа ЦМР.

Данные ЦМР и линеаментов использовались при обучении нейронной сети в виде входных и ожидаемых параметров.

ЦМР — это особый вид трехмерных математических моделей, представляющий собой отображение рельефа как реальных, так и абстрактных геополей (поверхностей) (Тикуннов, 2008).

В качестве ЦМР использовались результаты радиолокационной топографической съемки — “Shuttle Radar Topography Mission” (SRTM) (рис. 1) с параметрами, представленными в табл. 1.

SRTM — международный исследовательский проект по созданию цифровой модели высот Земли с помощью радарной топографической съемки ее поверхности. SRTM запущена в феврале 2000 г. и охватила 80% земной поверхности. Изначально перед миссией SRTM ставились следующие задачи по обеспечению точности:




Рис. 1. Визуализация цифровой модели рельефа исследуемой территории на базе SRTM.

- линейная абсолютная ошибка по высоте менее 16 м;
- линейная относительная ошибка по высоте менее 10 м;
- круговая абсолютная ошибка в плане меньше, чем 20 м;
- круговая относительная ошибка в плане меньше, чем 15 м;
- относительная ошибка по высоте для данных X-band SRTM меньше 6 м.

Значения, полученные на практике, оказались в доверительном интервале 90% (табл. 2) (Fag et al., 2007).

Для подготовки исходных данных использовано геоинформационное программное обеспечение “QGIS”, которое свободно распространяется по лицензии “GPL2” (Брауде-Золотарев и др., 2008). Главным преимуществом данного ПО является наличие открытого исходного кода на языке программирования “Python”, что позволяет расширить его функционал за счет разработки или привлечения сторонних приложений.

Разработка нейронной сети также проводилась на базе языка программирования “Python”. Выбор данного языка основан на доступности широкого спектра библиотек, таких как “Tensorflow”, “Keras”, “Numpy”, а также возможности дальнейшей интеграции разработанного ПО в систему “QGIS”. “Tensorflow” и “Keras” являются мощными инструментами для работы с нейронными сетями, что упрощает и ускоряет их разработку (Гафаров, Галимянов, 2018). Библиотека

“Numpy” обеспечивает мощный и аддитивный синтаксис для доступа, организации и управления данными в векторных, матричных и многомерных форматах (Григорьева и др., 2017).

ПОДГОТОВКА ИСХОДНЫХ ДАННЫХ

В связи с тем, что в процессе обучения нейронной сети загружается фиксированное количество входных и ожидаемых параметров в виде массивов, эти данные должны быть нормированы и подготовлены в табличном виде.

Для выделения линеаментов ручным способом в ПО “QGIS” создан ГИС-проект, включающий в себя объединенную мозаику из доступных для скачивания участков SRTM (рис. 2).

В качестве критериев, маркирующих “линеаменты”, выступали отрицательные линейные формы рельефа, отраженные интенсивными участками градиентного перехода. В связи с тем, что количество входных и ожидаемых параметров в ходе обучения нейронной сети фиксировано, ЦМР и схема линеаментов намеренно разделены на отдельные фрагменты и преобразованы в мат-

Таблица 2. Значения фактических ошибок для территории Евразии

Абсолютная ошибка в плане (метры)	8.8
Абсолютная ошибка по высоте (метры)	6.2
Относительная ошибка по высоте (метры)	8.7
Ошибка по высоте для данных X-band (метры)	2.6




Рис. 2. Линеаменты выделенные ручным способом.

рицу высот и матрицу достоверности выделения линеамента, соответственно (рис. 3).

Разделение ЦМР и схемы линеаментов на отдельные фрагменты необходимо в связи с их неограниченным размером, что привело бы к невозможности обучения нейронной сети. Такой подход позволил зафиксировать размер выделяемых линеаментов и участков ЦМР.

Матрица высот служит входным параметром при обучении нейронной сети и является частью ЦМР. Значения высотных отметок нормализованы в диапазоне от 0 до 1.

Матрица достоверности выделения линеаментов указывает на наличие линеамента в ячейке значением 1, а его отсутствие значением 0. При обучении нейронной сети эта матрица является ожидаемым параметром.

РАЗРАБОТКА АРХИТЕКТУРЫ НЕЙРОННОЙ СЕТИ

В связи с тем, что входные и ожидаемые данные являются растровыми, для решения поставленной задачи выбрана сверточная нейронная сеть (СНС), показывающая хороший результат в работе с графическими изображениями (LeCun et al., 2015).

Выбор архитектуры нейронной сети проводился аналитически (рис. 4). Первая модель имела следующие параметры: входной и выходной слой размером 28×28 пикселей; слои свертки; скрытый слой с 128 нейронами; функция актива-

ции — “ReLu” (Соснин, Суслова, 2019). Результатом ее работы является облако точек, где указывается вероятность наличия линеамента в каждом пикселе.

Первая обученная нейронная сеть слабо реагировала на изменение входных параметров, что приводило к неудовлетворительному результату (рис. 5). Для решения данной проблемы проведено увеличение размеров окна входных и ожидаемых данных до 32×32 , 36×36 и 40×40 пикселей.

В ходе анализа полученных результатов сделан вывод о том, что нейронная сеть с размером окна 40×40 пикселей наилучшим образом реагирует на входные параметры (рис. 6).

Как можно заметить на рис. 7, результат работы нейронной сети не всегда совпадает с искомым линеаментом. Это связано с тем, что линеаменты, выделенные вручную, картируются очень приблизительно, а нейронная сеть оперирует исходными данными и реагирует на их незначительные флуктуации. Следовательно, результаты работы нейронной сети можно рассматривать как искомый линеамент, но с вычисленной и внесенной поправкой (т.е. среднеквадратическим отклонением). Полученный результат является ключевым критерием использования нейронных сетей для решения поставленной задачи.

В ходе исследования установлено, что увеличение скрытых слоев свыше 5 и нейронов свыше 3200 слабо влияет на достоверность результатов, но при этом значительно уменьшает производительность. Следовательно, нейронная сеть с 5-ю

скрытыми слоями, в каждом из которых по 3200 нейронов, и размером входных и выходных окон 40×40 пикселей наилучшим образом подходит для текущего исследования (рис. 7).

РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

Для преобразования результатов работы нейронной сети в векторную форму, пригодную для работы в геоинформационном пространстве, поставлены и решены следующие задачи:

- формирование объекта из набора облаков точек методом, предложенным Сузуки и Абе (Suzuki, Abe, 1985);
- свертка площадного объекта в линейный с использованием алгоритма скелетизации Зонга-Суня (Баранов, Фаворская, 2011);
- векторизация и аппроксимация растровых данных алгоритмом Дугласа–Пеккера (Рябов, 2017);
- запись относительных координат начальных и конечных узлов сегментов линейного объекта;
- вычисление смещения и назначение географических координат векторным объектам.

На результаты векторизации значительно влияет шумовая компонента, что приводит к искажениям положения при идентификации линейных объектов. Решением данной проблемы является моделирование наборов идеальных данных и дообучение на них нейронной сети, так как качество подготовленной обучающей выборки невозможно оценить эмпирически, а только визуально, т.е. невозможно однозначно математически описать модель поведения всех линейных объектов. Другими словами, необходимо дополнить нейронную сеть идеально смоделированными данными.

Моделирование условий выделения линейных объектов производилось на основе разработанной авторской методики, состоящей из 4 этапов:

- подготовка различных вариаций линейных объектов, учитывающих ориентировки, длину, положение в окне;
- создание различных вариантов склонов (пологий, крутой и т.д.) и задание высотных отметок;
- моделирование и добавление Гауссовского шума (Barbu, 2013);
- сглаживание и генерация растрового изображения.

Смоделированные данные можно представить в виде растрового изображения, значения пикселей которого соответствуют высотным отметкам. В отличие от естественных, смоделированные данные имеют менее плавные переходы между высотами и более выраженную линейную структуру (рис. 8).

Нейронная сеть, обученная на смоделированных данных, демонстрирует линейный тренд распределения точечных данных, в сравнении с ре-




Рис. 3. Блок-схема подготовки входных и ожидаемых данных перед обучением нейронной сети.

зультатом нейронной сети, обученной на естественных данных. Тем не менее, ответ нейронной сети, обученной на естественных данных, коррелирует с ожидаемым “идеальным” результатом (рис. 9).

Так как в природе идеальные данные не встречаются, можно с уверенностью предположить, что шумовая компонента естественных данных будет вносить значительные погрешности в результат. Обучение идеализированной нейронной




Рис. 4. Архитектура разработанной нейронной сети: 1 – входное изображение; 2 – нейроны сверточного слоя; 3 – нейроны слоя уменьшения размерности; 4 – функция переформатирования данных из двумерного массива в одномерный; 5 – выходное изображение; 6 – нейроны скрытого слоя; 7 – слои.

сети производилось исключительно с целью проверки ее работоспособности.

На рис. 10 представлен результат работы выделения линеаментов ручным способом (рис. 10, а) и результат выделения линеаментов в ходе работы нейронной сети после ее дообучения (рис. 10, б).

Выделенные нейронной сетью линеаменты по большей части отражают линеаменты, которые были выделены вручную. Хорошо согласуются как протяженные, так и мелкие структуры. Наличие линеаментов в тех местах, где интерпретация оператором не была проведена, обуславливается чувствительностью к незначительным перепадам высот, которые крайне затруднительно определить человеческому глазу. Также по результатам работы нейронной сети можно наблюдать широкое распространение закольцованных структур, что возможно отражает блоковое строение рельефа или эрозионной сети.

ЗАКЛЮЧЕНИЕ

Проведенная работа позволяет сделать следующие выводы.

Впервые решена задача по выделению линеаментов с применением нейросетевых моделей.

Установлено, что обучение нейросетевых моделей на естественных и смоделированных данных оптимизирует подбор параметров, которые

влияют на результаты интерпретации нейронной сети.

Создана нейросетевая модель, обеспечивающая автоматическое выделение линеаментов человекоподобным образом.

Разработана методика автоматической векторизации результатов работы нейронной сети, их географической привязки и экспорта в ГИС.

В дальнейшем планируется обеспечить работу приложения с другими типами ЦМР и увеличить количество вариаций анализируемых морфологических элементов (кольцевые структуры, хребты, впадины, крутые и пологие склоны, протяженные структуры свыше 10 км и т.д.).

В связи с тем, что на данный момент отсутствуют опубликованные научные работы по выделению линеаментов с применением нейросетевых моделей, результаты, изложенные в данной статье, представляют значительный вклад в область разработки подходов к выделению линеаментов.

ИСТОЧНИК ФИНАНСИРОВАНИЯ

Работа выполнена в рамках государственного задания ИГЕМ РАН.




Рис. 5. Результат работы нейронной сети с параметрами: входное и выходное изображения размером 28×28 пикселей, сверточные слои размером 32 и 64, соответственно, окно свертки размером 3×3 , слои уменьшения размерности в 2 раза после каждого сверточного слоя, один скрытый слой с 128 нейронами.




Рис. 6. Результат работы нейронной сети с параметрами: входное и выходное изображения размером 40×40 пикселей, сверточные слои размером 32 и 64, соответственно, окно свертки размером 3×3 , слои уменьшения размерности в 2 раза после каждого сверточного слоя, один скрытый слой с 128 нейронами.








			Входное изображение
			Искомый линеамент
			Результат работы нейронной сети

Рис. 7. Результат работы нейронной сети с параметрами: входное и выходное изображения размером 40×40 пикселей, сверточные слои размером 32 и 64, соответственно, окно свертки размером 3×3 , слои уменьшения размерности в 2 раза после каждого сверточного слоя, пять скрытых слоев с 3200 нейронами.






Примеры				Тип
				Смоделированные изображения
				Фрагменты из ЦМР

Рис. 8. Сравнение входных данных.

Результат обучения на смоделированных данных		Результат обучения на выделенных линеаментах		
				Смоделированное изображение
				Исходный линеамент
				Результат работы нейронной сети

Рис. 9. Результаты работы нейронных сетей, обученных на разных данных.




Рис. 10. Линеаменты, показанные красным цветом: *a*) выделенные ручным способом; *б*) выделенные нейронной сетью.

СПИСОК ЛИТЕРАТУРЫ

- Баранов Р.П., Фаворская М.Н. Алгоритмы скелетизации объектов на изображении // Актуальные проблемы авиации и космонавтики. 2011. Т. 1. № 7. С. 349–349.
- Брауде-Золотарев М., Гребнев Г., Протасов П., Ралько А., Сербина Е. Свободное программное обеспечение в организации: сборник материалов. 3-е изд. М.: “Интернет-Полиграфия” INFO-FOSS.RU. 2008. 124 с.
- Гафаров Ф.М., Галимянов А.Ф. Искусственные нейронные сети и приложения: учебное пособие. Казань: Издательство Казанского университета. 2018. 121 с.
- Григорьева Е.Г., Клячин В.А., Клячин А.А. Универсальный программный комплекс для решения многомерных вариационных задач // Математическая физика и компьютерное моделирование. 2017. № 2(39). С. 39–55.
- Гришков Г.А., Устинов С.А., Нафигин И.О., Петров В.А. Нейронные сети и возможности их применения для анализа пространственных геологических данных // Материалы XV Международной научно-практической конференции. В 7-ми томах. Т. 4. Развитие новых идей и тенденций в науках о Земле: инновационные технологии геологической разведки горного и нефтегазового дела, бурение скважин, математическое моделирование и разведочная геофизика. М.: Российский государственный геологоразведочный университет им. С. Орджоникидзе, 2021. С. 33–36.
- Кац Я.Г., Полетаев А.И., Румянцев Э.Ф. Основы линейной тектоники. М.: Недра. 1986. 140 с.
- Логинов Г.Н., Петров А.М. Автоматическое выделение геоэлектрических границ по данным бокового короткого зондирования с помощью глубокой сверточной нейронной сети // Геология и геофизика. 2019. Т. 60. № 11. С. 1650–1657.
- Молчанов А.Б., Гордеев Н.А. Автоматизация метода реконструкции неотектонических напряжений Л.А. Сим с применением алгоритмов компьютерного зрения // Труды Ферсмановской научной сессии ГИ КНЦ РАН. 2021. № 18. С. 301–304.
<https://doi.org/10.31241/FNS.2021.18.056>
- Рябов А.А., Алгоритм Рамера-Дугласа-Пекера Методы и средства обработки и хранения информации: Межвузовский сборник научных трудов. М.: “Курс”, 2017. С. 40–43.
- Соснин А.С., Суслова И.А. Функции активации нейросети: сигмоида, линейная, ступенчатая, ReLu, THAN // НАУКА. ИНФОРМАТИЗАЦИЯ. ТЕХНОЛОГИИ. ОБРАЗОВАНИЕ. Материалы XII международной научно-практической конференции. Екб.: Российский государственный профессионально-педагогический университет, 2019. С. 237–246.
- Тикунов В.С. Геоинформатика: учебное пособие для студентов. М.: МГУ. 2008. 361 с.
- Чернова И.Ю., Нугманов И.И., Кадыров Р.И. Автоматизированный линейный анализ: учебно-методическое пособие. Казань: Казанский (Приволжский) федеральный университет. 2012. 38 с.
- Шевырев С.Л. Программа LEFA: автоматизированный структурный анализ космической основы в среде MATLAB // Успехи современного естествознания. 2018. № 10. С. 138–143.
- Щепин М.В., Евдокимов С.В., Головченко С.В. Выявление кольцевых структур по результатам обработки изображений космических снимков // Исслед. Земли из космоса. 2007. № 4. С. 74–87.
- Barbu T. Variational Image Denoising Approach with Diffusion Porous Media Flow // Abstract and Applied Analysis. 2013. P. 1–8.
<https://doi.org/10.1155/2013/856876>
- Dramsch J. 70 years of machine learning in geoscience in review // Advances in Geophysics. 2020. V. 61. P. 1–55.
- Farr T.G., Rosen P.A., Caro E., Crippen R., Duren R., Hensley S., Kobrick M., Paller M., Rodriguez E., Roth L., Seal D., Shaffer S., Shimada J., Umland J., Werner M., Oskin M., Burbank D., Alsdorf, D. The Shuttle Radar Topography Mission // Reviews of Geophysics. 2007. V. 45. № 2. P. 1–33.
- Gonbadi A.B., Tabatabaei S.H., Carranza E.J.M. Supervised geochemical anomaly detection by pattern recognition // J. Geochemical Exploration. 2015. V. 157. P. 81–91.
- Kong Q., Trugman D.T., Ross Z.E., Bianco M.J., Meade B.J., Gerstoft P. Machine learning in seismology: Turning data into insights // Seismological Research Letters. 2019. V. 90. № 1. P. 3–14.
- Lary D.J., Alavi A.H., Gandomi A.H., Walker A.L. Machine learning in geosciences and remote sensing // Geoscience Frontiers. 2016. V. 7. № 1. P. 3–10.
<https://doi.org/10.1016/j.gsf.2015.07.003>
- LeCun Y., Bengio Y., Hinton G. Deep learning // Nature. 2015. V. 521. № 7553. P. 436–444.
- Shen C. A transdisciplinary review of deep learning research and its relevance for water resources scientists // Water Resources Research. 2018. V. 54. № 11. P. 8558–8593.
- Suzuki S., Abe K. Topological Structural Analysis of Digitized Binary Images by Border Following // CVGIP. 1985. V. 30. № 1. P. 32–46.
- Valentine A.P., Kalnins L.M. An introduction to learning algorithms and potential applications in geomorphometry and earth surface dynamics // Earth Surface Dynamics. 2016. V. 4. P. 445–460.
- Wang Z., Di H., Shafiq M.A., Alaudah Y., AlRegib G. Successful leveraging of image processing and machine learning in seismic structural interpretation: A review // The Leading Edge. 2018. V. 37. № 6. P. 451–461.
- Zhao J., Chen S., Zuo R. Identifying geochemical anomalies associated with Au–Cu mineralization using multifractal and artificial neural network models in the Ningqiang district, Shaanxi, China // J. Geochemical Exploration. 2016. V. 164. P. 54–64.
- Zlatopolsky A.A. Program LESSA (Lineament Extraction and Stripe Statistical Analysis) automated linear image features analysis – experimental results // Computers & Geoscience. 1992. V. 18. № 9. P. 1121–1126.
- Zuo R., Xiong Y., Wang J., Carranza E. J. M. Deep learning and its application in geochemical mapping // Earth-Science Reviews. 2019. V. 192. P. 1–14.
- Zuo R.G., Xiong Y.H. Big data analytics of identifying geochemical anomalies supported by machine learning methods // Nat Resour Res. 2018. V. 27. № 1. P. 5–13.

Development of a Technique for Automatic Lineament Allocation Based on a Neural Network Approach

G. A. Grishkov¹, I. O. Nafigin¹, S. A. Ustinov¹, V. A. Petrov¹, and V. A. Minaev¹

¹*Federal State Budgetary Institution of Science Institute of Geology of Ore Deposits, Petrography, Mineralogy and Geochemistry of the Russian Academy of Sciences (IGEM RAS), Moscow, Russia*

The purpose of the scientific work is to study the potential of neural network technologies in the field of extracting linear structures from digital terrain models SRTM. Linear structures, also known as lineaments, play an important role in the verification of known faults, the identification of fault-fracture structures, the detailing of the framework of discontinuous faults, as well as in the exploration of minerals. Their accurate and effective extraction in solving the designated tasks is of fundamental importance. The use of neural network technologies provides a number of advantages over sequential algorithms, including the ability to search for universal criteria for selecting lineaments based on a training sample. The paper considers a comprehensive innovative methodology that includes several key stages. The first stage is the author's method of data preparation, which helps to ensure the quality of the training sample and minimize the impact of noise. The second stage is to develop an algorithm for vectorizing the results of the neural network, which allows you to easily export the results (lineaments) to a geographic information system (GIS). The third stage provides a method for minimizing the noise component of the training sample and optimizing the selection of synaptic weighting coefficients by retraining the neural network using simulated data reflecting various localization conditions of the lineaments. To verify the results obtained, a spatial comparison of linear structures extracted by a neural network and lineaments isolated by the operator was carried out. The results of this comparison demonstrate the high potential of the proposed approach and show that the use of neural network technologies is an actual and promising approach to solving the problem of extracting linear structures from digital terrain models. Positive conclusions are made about the expediency of using the results obtained for their practical application in the field of Earth sciences.

Keywords: lineaments, neural networks, digital relief model, linear structures, neotectonics, geoinformation system, discontinuous violations, python, tensorflow, keras

REFERENCES

- Baranov R.P., Favorskaya M.N. Algorithms of skeletonization of objects in the image // Aktual'nye problemy aviatsii i kosmonavтики, 2011. V. 1. № 7. P. 349–349. (In Russian).
- Braude-Zolotarev M., Grebnev G., Protasov P., Raiko A., Serbina E. Svobodnoe programnoye obespechenie v organizatsii: sbornik materialov (Free software in the organization: a collection of materials), 3-e izd, Moscow: "Internet-Poligrafiya" INFO-FOSS.RU. 2008. 124 p. (In Russian).
- Gafarov F.M., Galimyanov A.F. Iskusstvennyye neyronnyye seti i prilozheniya: uchebnoye posobie (Artificial neural networks and applications: a textbook), Kazan': Izdatel'stvo Kazanskogo universiteta. 2018. 121 p. (in Russian).
- Grigor'eva E.G., Klyachin V.A., Klyachin A.A. Universal software package for solving multidimensional variational problems // Matematicheskaya fizika i komp'yuternoe modelirovanie, 2017. № 2(39). P. 39–55. (In Russian).
- Grishkov G.A., Ustinov S.A., Nafigin I.O., Petrov V.A. Neural networks and the possibilities of their application for the analysis of spatial geological data // Materialy XV Mezh-dunarodnoj nauchno-prakticheskoy konferentsii. V 7-mi tomah. Tom. 4. Razvitie novykh idey i tendentsiy v naukah o Zemle: innovatsionny'e tekhnologii geologicheskoy razvedki gornogo i neftegazovogo dela, burovanie skvazhin, matematicheskoe modelirovanie i razvedochnaya geofizika, Moscow: Rossijskij gosudarstvennyj geologorazvedochnyj universitet im. S. Ordzhonikidze. 2021. P. 33–36. (In Russian).
- Kacz Ya.G., Poletaev A.I., Rumyancheva E.F. Osnovy lineamentnoy tektoniki (Fundamentals of lineament tectonics), Moscow: Nedra. 1986. 140 p. (in Russian).
- Loginov G.N., Petrov A.M. Automatic selection of geoelectric boundaries based on lateral logging data using a deep convolutional neural network // Geologiya i geofizika. 2019. T. 60. № 11. P. 1650–1657. (In Russian).
- Molchanov A.B., Gordeev N.A. Automation of the method of reconstruction of neotectonic stresses L.A. Sim using computer vision algorithms // Trudy Fersmanovskoy nauchnoj sessii GI KNCz RAN. 2021. № 18. P. 301–304. (in Russian). <https://doi.org/10.31241/FNS.2021.18.056>
- Ryabov A.A. Ramer-Douglas-Peaker algorithm // Metody i sredstva obrabotki i xraneniya informatsii: Mezhvuzovskij sbornik nauchny'x trudov, Moscow: "Kurs". 2017. P. 40–43. (In Russian).
- Sosnin A.S., Suslova I.A. Neural network activation functions: sigmoid, linear, stepwise, ReLU, THAN // NAUKA. INFORMATIZACIYA. TEXNOLOGII. OBRAZOVANIE. Materialy XII mezh-dunarodnoj nauchno-prakticheskoy konferentsii, Ekaterinburg: Rossijskij gosudarstvennyj professional'no-pedagogicheskij universitet. 2019. P. 237–246. (In Russian).
- Tikunov V.S. Geoinformatika: uchebnoye posobie dlya studentov (Geoinformatics: a textbook for students), Moscow: MGU. 2008. 361 p. (in Russian).
- Chernova I.Yu., Nugmanov I.I., Kadyrov R.I. Avtomatizirovannyj lineamentnyj analiz: uchebno-metodicheskoe posobie (Automated lineament analysis: an educational and methodical manual), Kazan': Kazanskij (Privolzhskij) federal'nyj universitet. 2012. 38 p. (in Russian).
- Shevyryov S.L. LEFA program: automated structural analysis of the cosmic basis in the MAT-

- LAB environment // *Uspehi sovremennogo estestvoznaniya*. 2018. № 10. P. 138–143 (in Russian).
- Shhepin M.V., Evdokimov S.V., Golovchenko S.V.* Identification of ring structures based on the results of image processing of satellite images // *Issledovanie Zemli iz kosmosa*. 2007. № 4. P. 74–87. (in Russian).
- Barbu T.* Variational Image Denoising Approach with Diffusion Porous Media Flow // *Abstract and Applied Analysis*. 2013. P. 1–8.
<https://doi.org/10.1155/2013/856876>
- Dramsch J.* 70 years of machine learning in geoscience in review // *Advances in Geophysics*. 2020. V. 61. P. 1–55.
- Farr T.G., Rosen P.A., Caro E., Crippen R., Duren R., Hensley S., Kobrick M., Paller M., Rodriguez E., Roth L., Seal D., Shaffer S., Shimada J., Umland J., Werner M., Oskin M., Burbank D., Alsdorf, D.* The Shuttle Radar Topography Mission // *Reviews of Geophysics*. 2007. V. 45. № 2. P. 1–33.
- Gonbadi A.B., Tabatabaei S.H., Carranza E.J.M.* Supervised geochemical anomaly detection by pattern recognition // *J. Geochemical Exploration*. 2015. V. 157. P. 81–91.
- Kong Q., Trugman D.T., Ross Z.E., Bianco M.J., Meade B.J., Gerstoft P.* Machine learning in seismology: Turning data into insights // *Seismological Research Letters*. 2019. V. 90. № 1. P. 3–14.
- Lary D.J., Alavi A.H., Gandomi A.H., Walker A.L.* Machine learning in geosciences and remote sensing // *Geoscience Frontiers*. 2016. V. 7. № 1. P. 3–10.
<https://doi.org/10.1016/j.gsf.2015.07.003>.
- LeCun Y., Bengio, Y., Hinton G.* Deep learning // *Nature*. 2015. V. 521. № 7553. P. 436–444.
- Shen C.* A transdisciplinary review of deep learning research and its relevance for water resources scientists // *Water Resources Research*. 2018. V. 54. № 11. P. 8558–8593.
- Suzuki S., Abe K.* Topological Structural Analysis of Digitized Binary Images by Border Following // *CVGIP*. 1985. V. 30. № 1. P. 32–46.
- Valentine A.P., Kalnins L.M.* An introduction to learning algorithms and potential applications in geomorphometry and earth surface dynamics // *Earth Surface Dynamics*. 2016. V. 4. P. 445–460.
- Wang Z., Di H., Shafiq M. A., Alaudah Y., AlRegib G.* Successful leveraging of image processing and machine learning in seismic structural interpretation: A review // *The Leading Edge*. 2018. V. 37. № 6. P. 451–461.
- Zhao J., Chen S., Zuo R.* Identifying geochemical anomalies associated with Au–Cu mineralization using multifractal and artificial neural network models in the Ningqiang district, Shaanxi, China // *J. Geochemical Exploration*. 2016. V. 164. P. 54–64.
- Zlatopolsky A.A.* Program LESSA (Lineament Extraction and Stripe Statistical Analysis) automated linear image features analysis – experimental results // *Computers & Geoscience*. 1992. V. 18. № 9. P. 1121–1126.
- Zuo R., Xiong Y., Wang J., Carranza E. J. M.* Deep learning and its application in geochemical mapping // *Earth-Science Reviews*. 2019. V. 192. P. 1–14.
- Zuo R.G., Xiong Y.H.* Big data analytics of identifying geochemical anomalies supported by machine learning methods // *Nat Resour Res*. 2018. V. 27. № 1. P. 5–13.