

УДК 551.26:004:621.396.96
DOI 10.17513/use.38079

РАСПОЗНАВАНИЕ ВОЛНОВЫХ ОБРАЗОВ ТРЕЩИН МАССИВА ГОРНЫХ ПОРОД НА ОСНОВЕ НЕЙРОННЫХ СЕТЕЙ ПО ДАННЫМ ГЕОРАДИОЛОКАЦИИ

Соколов К.О., Шамаев С.Д.

Институт горного дела Севера им Н.В. Черского, Якутск, e-mail: sha.sd@inbox.ru

Трещины массива горных пород существенно влияют на физико-механические свойства горных пород, и их, в свою очередь, необходимо учитывать при планировании добычных работ и строительстве горнотехнических сооружений. Существуют различные методики выявления трещин массива горных пород по данным георадиолокации. Однако применение данных методик ограничивается производительностью операторов-геофизиков, так как данные георадиолокации преимущественно интерпретируются ими вручную. Для изучения трещиноватости мерзлых горных пород по данным георадиолокации возможно применение искусственных нейронных сетей (ИНС), которые позволяют проводить анализ георадиолокационных радарограмм с целью выявления разрывов и смещений осей синфазности георадиолокационных сигналов. Существенной проблемой при применении ИНС является подготовка данных для обучения (обучающей выборки). Создание обучающего набора данных возможно с помощью модели георадиолокационного разреза массива мерзлых горных пород с трещиной. Однако практика использования синтетических радарограмм на основе модели георадиолокационного разреза массива мерзлых горных пород с трещиной показала необходимость ее усовершенствования в плане увеличения количества слоев горных пород, возможности задания наклонных границ с учетом наличия син- и антиформ. В статье описаны этапы разработки модели нейронной сети, в том числе создание обучающего набора данных, выбор архитектуры, обучение и апробация модели нейронной сети. Апробация модели ИНС показала высокую эффективность модели ИНС. Тем не менее, в работе модели наблюдаются некоторые недостатки. Разработанная система позволит существенно сократить временные затраты на интерпретацию данных георадиолокации. Дальнейшие исследования будут связаны с повышением точности предсказания, обусловленным расширением обучающего набора данных и разработкой дополнительной модели ИНС.

Ключевые слова: трещины, массив горных пород, георадиолокация, распознавание образов, сверточные нейронные сети, автоэнкодер

Работа выполнена в рамках государственного задания Министерства науки и высшего образования Российской Федерации (тема № 0297-2021-0020, ЕГИСУ НИОКТР № 122011800086-1).

RECOGNITION OF WAVE PATTERNS OF ROCK MASSIF CRACKS BASED ON NEURAL NETWORKS FROM GPR DATA

Sokolov K.O., Shamaev S.D.

Mining Institute of the North SB RAS, Yakutsk, e-mail: sha.sd@inbox.ru

Cracks in the rock mass significantly affect the physical and mechanical properties of rocks, and they, in turn, must be taken into account in the planning of mining operations and construction of mining structures. There are various techniques for detecting cracks in the rock mass using GPR data. However, the application of these techniques is limited by the productivity of geophysical operators, as the GPR data are mainly interpreted by them manually. To study the fracturing of frozen rocks from GPR data, it is possible to use artificial neural networks (ANN), which will make it possible to analyze GPR radarograms in order to detect discontinuities and shifts of in-phase axes of GPR signals. A significant problem in the application of ANN is the preparation of data for training (training sample). It is possible to create a training data set using a model of GPR section of frozen rock massif with a fracture. However, the practice of using synthetic radarograms based on the model of GPR section of frozen rock massif with a crack has shown the need for its improvement in terms of increasing the number of rock layers, the possibility of setting inclined boundaries, taking into account the presence of syn- and antiforms. The article describes the stages of neural network model development, including the creation of a training data set, selection of architecture, training and testing of the neural network model. The validation of the ANN model showed high performance of the ANN model. Nevertheless, some drawbacks are observed in the performance of the model. The developed system will significantly reduce the time cost of GPR data interpretation. Further research will be related to improving the prediction accuracy associated with the expansion of the training data set and development of an additional ANN model.

Keywords: cracks, rock massif, ground-penetrating radar, pattern recognition, convolutional neural networks, autoencoder

The work was carried out within the framework of the state task of the Ministry of Science and Higher Education of the Russian Federation (subject No. 0297-2021-0020, Unified State Accounting Information System research, development and technological work for civil purposes No. 122011800086-1).

Трещины массива горных пород представляют собой поверхности разрыва сплошности в горных породах без признака смещения [1]. Они существенно влияют на физико-механические свойства горных пород, и их, в свою очередь, необходимо

учитывать при планировании добычных работ и строительстве горнотехнических сооружений [2]. В условиях криолитозоны трещины массива горных пород успешно изучаются с помощью метода георадиолокации [3]. Существуют различные методики выявления трещин массива горных пород по данным георадиолокации [4–6]. Однако применение данных методик ограничивается производительностью операторов-геофизиков, так как данные георадиолокации преимущественно интерпретируются ими вручную. Например, после георадиолокационного исследования на участке АО «Алмазы Анабара» было получено 37 радарограмм по 40000 трасс и 512 точек в каждой, что в общей сумме дает 757 млн значений в матрице.

Для повышения скорости интерпретации данных геофизических измерений возможно использование современных методов анализа цифровых данных, позволяющих не только более качественно обработать геофизические данные по сравнению с традиционными методами, но и провести обработку большого объема данных в короткие сроки. Для изучения трещиноватости мерзлых горных пород по данным георадиолокации возможно применение искусственных нейронных сетей (ИНС) [7], которые позволят проводить анализ георадиолокационных радарограмм с целью выявления разрывов и смещений осей синфазности георадиолокационных сигналов. В последнее время ИНС успешно используются при обработке георадиолокационных данных [8–11].

Целью данного исследования является разработка системы распознавания волновых образов трещин массива горных пород по данным георадиолокационных измерений на основе применения методов искусственного интеллекта.

Существенной проблемой при применении ИНС является подготовка данных для обучения (обучающей выборки). Для подготовки подобных наборов геофизической информации исследователи используют различное программное обеспечение. Например, для генерации синтетических радарограмм в работах [12–14] применялась программа grfMax. Такой подход позволяет автоматизировать формирование обучающей выборки и сгенерировать различные варианты синтетических радарограмм для полноценного обучения нейронной сети. Но, так как принцип работы grfMax основан на решении прямой задачи распростра-

нения высокочастотных электромагнитных волн, то данный подход весьма затратный по времени и требует последующей обработки синтетических радарограмм, в частности для разметки в обучающей выборке искомого объектов.

Решение вышеуказанных проблем возможно с помощью модели георадиолокационного разреза массива мерзлых горных пород с трещиной [15]. Разработанное на основе этой модели программное обеспечение в течение 5–10 минут способно сгенерировать до 20 000 обучающих образов с уже нанесенной разметкой для определения положения трещины. Подобная скорость генерации не является избыточной, поскольку параметры обучающих образов напрямую зависят от параметров методики, по которой проведены георадиолокационные измерения. В работе [16] для поиска трещин в асфальтовом покрытии, т.е. при жестко заданных параметрах измерений и исследуемой среде, потребовалось более 5000 обучающих образов. Однако практика использования синтетических радарограмм на основе модели георадиолокационного разреза массива мерзлых горных пород с трещиной показала необходимость ее усовершенствования в плане увеличения количества слоев горных пород, возможности задания наклонных границ с учетом наличия син- и антиформ.

Материал и методы исследования

В модели (1) формируется матрица GPR, в которой каждому столбцу соответствует георадиолокационная трасса с номером T , а в каждой ячейке (d) столбца хранится амплитудное значение сигнала. Ось синфазности георадиолокационных сигналов представляется в виде $U_s(T, d)$ при d , имеющем постоянное значение, для некоторого диапазона значений T (рис. 1). Для описания разрыва оси синфазности использована инвертированная функция прямоугольного импульса $1 - \Pi(T - T_{cm}, W_{cm})$, где T_{cm} – номер трассы, с которой начинается разрыв, W_{cm} – ширина разрыва, представляющая собой количество трасс, в которых функция $U_s(T, d)$ зануляется. Таким образом, приходим к следующему выражению: $U_s(T, d) * (1 - \Pi(T - T_{cm}, W_{cm}))$. Для ввода в модель возможности описания взбросов или сбросов используем функцию Хэвисайда $\theta(T - T_{cm}) * d_{cm}$, где d_{cm} – количество отсчетов, на которое смещается ось синфазности.

$$GPR = \sum_{T=0}^K \sum_{d=0}^N U_s (d - \theta(T - T_{cm}) * d_{cm}) * (1 - \Pi(T - T_{cm}, W_{cm})) + n(T), \quad (1)$$

где K – количество трасс, N – количество отсчетов в трассе, U_s – форма сигнала, θ – функция Хэвисайда, Π – функция прямоугольного импульса, $n(T)$ – помехи.

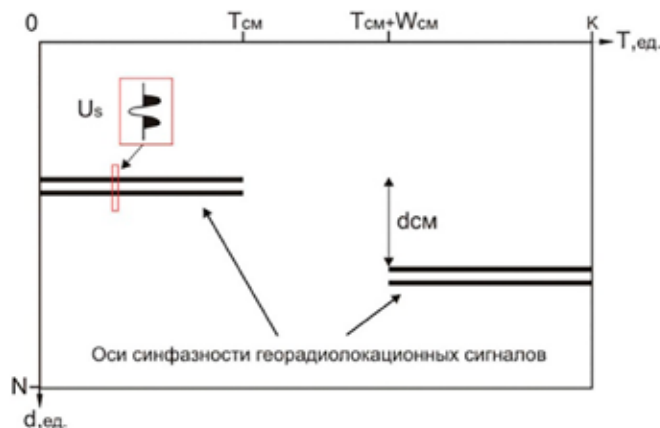


Рис. 1. Схема расположения основных элементов модели радарограммы

Для указания количества границ введем константу M , при этом индивидуальные параметры каждой границы (глубина залегания, изогнутость) задаются соответствующими переменными с индексами s . Для учета наклонных границ при вычислении $U_s(T, d)$ введем дополнительное слагаемое kT , увеличивающее время регистрации сигнала при $k > 0$, т.е. граница «уходит» вниз, при $k < 0$, соответственно, вверх. При $k = 0$ граница остается горизонтальной. В данном варианте формулы параметр наклона k будет единым для всех границ. Возможность моделирования осей синфазно-

сти георадиолокационных сигналов в виде син- и антиформ представлена в виде слагаемого $AI * \sin(sai * T)$. Параметр sai по своей сути задает частоту синусоиды, позволяя моделировать как мелкие колебания, характерные для небольших локальных объектов, так и крупные фрагменты син- и антиформ различной амплитуды AI . При $sai = 0$ влияние данного слагаемого нивелируется. Модель многослойного георадиолокационного разреза массива мерзлых горных пород с трещиной, учитывающая вышеуказанные особенности, представляется в виде:

$$GPR = \sum_{S=1}^M \sum_{T=0}^K \sum_{d=0}^N U_s (d + kT - \theta(T - T_{cm}) * d_{cm}, AI * \sin(sai * T) * GG_s) * (1 - \Pi(T - T_{cm}, W_{cm})) + n(T), \quad (2)$$

где M – количество границ, GG_s – положение по глубине s -й границы, k – параметр наклона оси синфазности сигналов, AI – амплитуда изгиба границы, sai – параметр изогнутости.

Апробация численных расчетов модели по формуле (2) была реализована в Matlab для четырехслойного разреза. В качестве формы сигнала U_s использована вторая производная функции Гаусса, для границ варьировались следующие значения параметров: k , AI , sai . Результаты моделирования представлены на рисунке 2.

На основе сгенерированных синтетических радарограмм была сформирована обучающая выборка для модели ИНС. Выборка состояла из 50000 пар синтетических радарограмм, представляющих собой изображение размером 32×32 пикселя с нанесенной разметкой положения трещины в виде зеленых пикселей (рис. 3б) и без нанесенной разметки (рис. 3а). Радарограммы без разметки используются в качестве входных данных, радарограммы с разметкой применяются в качестве целевых данных для вычисления функции потерь модели. После генерации контрастность синтетических радарограмм повышается до максимума для выделения границ слоев.

рограмм, представляющих собой изображение размером 32×32 пикселя с нанесенной разметкой положения трещины в виде зеленых пикселей (рис. 3б) и без нанесенной разметки (рис. 3а). Радарограммы без разметки используются в качестве входных данных, радарограммы с разметкой применяются в качестве целевых данных для вычисления функции потерь модели. После генерации контрастность синтетических радарограмм повышается до максимума для выделения границ слоев.




Рис. 2. Результаты моделирования по формуле (2) с параметрами:
 а) $k = 0,3$; $AI = 0,1$; $sai = 0,015$; б) $k = 0$; $AI = 0,1$; $sai = 0,015$; в) $k = 0,3$; $AI = 0$; $sai = 0$

Архитектуры нейронной сети

№ архитектуры	1 сегмент	2 сегмент	3 сегмент	4 сегмент	5 сегмент	Косинусное сходство
	Количество нейронов					
1	512	256	32	8	2	0.81
2	256	128	32	2	-	0.89
3	64	32	24	8	-	0.91
4	64	32	16	-	-	0.96
5	32	24	8	-	-	0.98
6	16	8	-	-	-	0.81




Рис. 3. Пример результата моделирования радарограммы: а) без нанесенной разметки положения трещины; б) с нанесенной разметкой положения трещины

В настоящее время разработано множество различных типов ИНС. В предыдущем исследовании [17] была выбрана ИНС типа сверточный автоэнкодер. Сверточный автоэнкодер – это тип ИНС, который использует сверточные слои вместо полносвязных. Он состоит из двух основных частей: энкодера и декодера. Энкодер принимает входные данные и пропускает их через сверточные слои, сокращая размерность данных. Результат этого процесса – «латентное», или «скрытое», представление входных данных, которое охватывает наиболее важные аспек-

ты входных данных. Декодер затем принимает этот латентный код и преобразует его обратно в оригинальное пространство входных данных [18].

В нашем исследовании энкодер и декодер состоят из трех сегментов, каждый из которых оснащен сверточным слоем с параметрами ядра 3×3 и шагом 1, слоем активации ReLU, а также слоем MaxPooling, сокращающим размерность, или UpSampling, повышающим размерность. Данная архитектура была выбрана эмпирически из множества архитектур и достигает 98% точности по метрике – косинусное сходство. Остальные варианты с большим или меньшим количеством сегментов или нейронов не смогли достичь той же точности по причине переобучения либо, наоборот, по причине недообученности. Таким образом, была выбрана архитектура ИНС под 5 номером, так как она обладает наиболее подходящим количеством сегментов и нейронов (таблица).

Принцип работы выбранной архитектуры заключается в том, что энкодер сжимает входное изображение до размеров 8×8 пикселей, после чего декодер преобразует его обратно к исходной размерности 32×32 пикселя, уже с выделенными положениями трещин.

Обучение модели производилось с использованием оптимизатора Adam с коэффициентом скорости обучения 0.001 и функции потерь в виде бинарной кросс-энтропии. Для регулирования сети применялся dropout 0.2 после каждого сверточного слоя. Сгенерированный набор данных был разбит на 3 подгруппы: 40000 экземпляров были выделены для обучения модели, 9000 экземпляров – для вычисления ошибки и 1000 экземпляров – для валидации. Примеры результатов, полученных с помощью обученной модели автоэнкодера, представлены на рисунке 4.




Рис. 4. Пример результата работы модели ИНС:
а) фрагмент радарограммы до обработки;
б) фрагмент радарограммы после обработки

Результаты исследования и их обсуждение

Апробация работы модели ИНС проведена на данных георадиолокационного исследования массива мерзлых горных пород криолитозоны. Результат обработки представлен на рисунке 5, на котором в интервале от 80 до 300 наносекунд можно наблюдать значительное количество смещений и разрывов осей синфазности георадиолокационных сигналов. В промежутках от 0 до 80 наносекунд и от 300 до 325 наносекунд находятся непрерывные оси синфазности. Стоит отметить, что именно в областях с большим числом смещений и разрывов осей синфазности модель нейронной сети идентифицировала положения трещин, в то время как на участках с непрерывными осями синфазности положения трещин не были обнаружены. В области, выделенной пунктирной линией, заметны малоамплитудные сигналы, которые соизмеримы с уровнем шума. Это усложняет процесс распознавания положений трещин.

Следует отметить, что «горбы», возникающие на осях синфазности из-за дискретизации сигнала и прерывания тонкой

линии (от 0 до 15 м на 240 нс), модель ИНС не определяет как трещины. Это стало возможным благодаря операциям уменьшения размерности, которые обнуляют данные явления, что подтверждает правильный выбор архитектуры нейронной сети.

Тем не менее, в работе модели наблюдаются некоторые недостатки. В частности, модель ИНС ошибочно выделяет пустоты в осях синфазности как трещины, расположенные на 140-м метре и 80 нс или на 130-м метре и 200 нс. Причина этого заключается в том, что модель ИНС принимает пустоты за разрывы осей синфазности. Еще одна ошибка находится на 30-м метре и 210 нс, где модель ИНС идентифицировала деформацию оси синфазности, образованную вследствие помех, как трещину. Кроме того, модель ИНС не всегда способна различить конец оси синфазности и трещину, что наблюдается на 70-м метре и 190 нс или 100-м метре и 350 нс. Решение этой проблемы может заключаться в расширении обучающего набора соответствующими данными. Однако такие случаи встречаются довольно редко и не оказывают существенного влияния на результат интерпретации данных.

Также следует упомянуть, что для удобства интерпретации трещины, представляющие собой отдельную систему, необходимо выделять как некоторую ограниченную область, например в интервале от 135 до 150 м и от 70 до 120 нс. Для решения данной проблемы можно использовать дополнительную модель ИНС, находящую области трещиноватости на основе уже найденных трещин.




Рис. 5. Пример результата работы модели ИНС

Заключение

Разработана система распознавания волновых образов трещин массива горных пород по данным георадиолокационных измерений на основе применения методов искусственного интеллекта. Для создания обучающего набора данных использовалась модель георадиолокационного разреза массива мерзлых горных пород с трещиной [15], которая была усовершенствована для задания нескольких границ слоев и наклонных границ. На основе разработанной модели был создан обучающий набор, состоящий из 100000 синтетических радарограмм. Выбранный сверточный автоэнкодер был оптимизирован по количеству слоев и нейронов. После обучения была проведена апробация разработанной модели ИНС на данных георадиолокационного исследования массива мерзлых горных пород криолитозоны. Апробация модели ИНС показала высокую эффективность модели ИНС. Тем не менее, в работе модели наблюдаются некоторые недостатки.

Разработанная система позволит существенно сократить временные затраты на интерпретацию данных георадиолокации. Дальнейшие исследования будут связаны с повышением точности предсказания, обусловленным расширением обучающего набора данных и разработкой дополнительной модели ИНС.

Список литературы

1. Кирмасов А.Б. Основы структурного анализа. М.: Научный мир, 2011. 368 с.
2. Рац М.В., Чернышев С.Н. Трещиноватость и свойства трещиноватых горных пород М.: Недра, 1970. 164 с.
3. Соколов К.О. Интерпретация данных георадиолокации для определения зон повышенной трещиноватости массива мерзлых горных пород // Успехи современного естествознания. 2019. № 12. С. 150-155.
4. Arosio D. Rock fracture characterization with GPR by means of deterministic deconvolution // Journal of Applied Geophysics. 2016. Vol. 126. P. 27-34. DOI: 10.1016/j.jappgeo.2016.01.006.
5. Elkarmoty M., Tinti F., Kasmaeeyazdi S., Giannino F., Bondua S., Bruno R. Implementation of a fracture modeling strategy based on georadar survey in a large area of limestone quarry bench // Geosciences. 2018. Vol. 8, Is. 12. P. 481-496. DOI: 10.3390/geosciences8120481.
6. Conti I.M.M., de Castro D.L., Bezerra F.H.R., Cazarin C.L. Porosity estimation and geometric characterization of fractured and karstified carbonate rocks using GPR data in the salitre formation // Pure and Applied Geophysics. 2019. Vol. 176, Is. 1. P. 1673-1689. DOI: 10.1007/s00024-018-2032-5.
7. Шамаев С.Д. Применение методов искусственного интеллекта при обработке и интерпретации данных геофизических методов // Известия Уральского государственного горного университета. 2022. № 1. С. 86-101.
8. Silvia L., Federico L., Paolo B., Maurizio L., Stefano T. Landmine Detection from GPR Data Using Convolutional Neural Networks // 25-th European Signal Processing Conference (Kos, Greece, 28 August – 2 September 2017). Piscataway: Institute of Electrical and Electronics Engineers, 2017. P. 508-512.
9. Xiang Z., Rashidi A., Ou G. An Improved Convolutional Neural Network System for Automatically Detecting Rebar in GPR Data // ASCE International Conference on Computing in Civil Engineering (Atlanta, Georgia, 17-19 June 2019). United States: American Society of Civil Engineers, 2019. P. 422-429.
10. Tao L., Yi S., Chunlin H. Inversion of Ground Penetrating Radar Data Based on Neural Networks // Remote Sensing. 2018. Vol. 10, Is. 5. P. 730-740. DOI: 10.3390/rs10050730.
11. Xie L., Zhao Q., Huo J., Cheng G. A Ground Penetrating Radar Data Reconstruction Method Based on Generation Networks // 2020 IEEE Radar Conference (Florence, Italy, 21-25 September 2020). Piscataway: Institute of Electrical and Electronics Engineers, 2020. P. 1-4.
12. Sun H.-H., Lee Y.H., Li C., Ow L.F., Yusuf M.L.M., Yucel A.C. The Orientation Estimation of Elongated Underground Objects via Multipolarization Aggregation and Selection Neural Network // IEEE Geoscience and Remote Sensing Letters. 2022. Vol. 19. P. 1-5. DOI: 10.1109/LGRS.2021.3072923.
13. Yamaguchi T., Mizutani T., Nagayama T. Mapping Subsurface Utility Pipes by 3-D Convolutional Neural Network and Kirchhoff Migration Using GPR Images // IEEE Transactions on Geoscience and Remote Sensing. 2021. Vol. 59, Is. 12. P. 6525-6536. DOI: 10.1109/TGRS.2020.3030079.
14. Rajiv K., Basaveswara R.B., Ramesh C.G., Ganapathi R.N.V. Exploration of pipelines from the use of GPR data by neural network // International Journal of Recent Technology and Engineering. 2019. Vol. 8, Is. 2S11. P. 3711-3715. DOI: 10.35940/ijrte.B1470.0982S1119.
15. Sokolov K.O., Dyagileva R.A., Popkov P.A. Development of a Model of a GPR Section of a Frozen Rock Mass with a Crack // Engineering and Mining Geophysics. (26 April 2021). Netherlands: European Association of Geoscientists & Engineers. 2021. P. 1-5.
16. Zheng T., Jie G., Haitao Z. Recognition, location, measurement, and 3D reconstruction of concealed cracks using convolutional neural networks // Construction and Building Materials. 2017. Vol. 146. P. 775-787. DOI: 10.1016/j.conbuildmat.2017.04.097.
17. Шамаев С.Д. Разработка системы распознавания волновых образов трещин массива рных пород на основе нейронных сетей // Аммосов-2022 (г. Якутск, 22 апреля 2022 г.). Якутск: Северо-Восточный федеральный университет имени М.К. Аммосова, 2022. С. 86-101.
18. Xiao-Jiao Mao, Chunhua Shen, Yu-Bin Yang. Image restoration using convolutional auto-encoders with symmetric skip connections // 30th Conference on Neural Information Processing Systems (Barcelona, 5-10 December 2016). United States: Neural Information Processing Systems, 2016. P. 2810-2818.