

ИССЛЕДОВАНИЕ НЕОДНОЗНАЧНОСТИ ОБРАЩЕНИЯ ДИСПЕРСИОННЫХ КРИВЫХ ПОВЕРХНОСТНЫХ ВОЛН ПРИ ПОМОЩИ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

Александр Викторович Яблоков

Институт нефтегазовой геологии и геофизики им. А.А. Трофимука СО РАН, 630090, Россия, г. Новосибирск, проспект Академика Коптюга 3, научный сотрудник, e-mail: yablokovav@ipgg.sbras.ru; Институт горного дела им. Н.А. Чинакала СО РАН, 630091, Россия, г. Новосибирск, Красный проспект, 54, младший научный сотрудник; Новосибирский государственный университет, 630090, Россия, г. Новосибирск, ул. Пирогова, 2, младший научный сотрудник.

Александр Сергеевич Сердюков

Институт нефтегазовой геологии и геофизики им. А.А. Трофимука СО РАН, 630090, Россия, г. Новосибирск, проспект Академика Коптюга 3, к.ф.-м.н, старший научный сотрудник, e-mail: serdyukovas@ipgg.sbras.ru; Институт горного дела им. Н.А. Чинакала СО РАН, 630091, Россия, г. Новосибирск, Красный проспект, 54, младший научный сотрудник.

В работе обсуждаются результаты использования адаптированного алгоритма семплирования методом Монте-Карло для оценки области неоднозначности обращения синтетических дисперсионных кривых фазовых скоростей поверхностных волн с применением искусственных нейронных сетей. Обоснована целесообразность использования рассмотренного алгоритма для вычисления вероятностной оценки результатов решения обратной задачи в методе многоканального анализа поверхностных волн.

Ключевые слова: инверсия, искусственная нейронная сеть, неоднозначность решения обратной задачи сейсмоки

STUDY OF UNCERTAINTY OF THE INVERSION OF DISPERSION CURVES OF SURFACE WAVES USING ARTIFICIAL NEURAL NETWORKS

Alexandr V. Yablokov

Trofimuk Institute of Petroleum Geology and Geophysics SB RAS, 3, Akademika Koptyuga Ave., Novosibirsk, 630090, Russia, Researcher, e-mail: yablokovav@ipgg.sbras.ru; Chinakal Institute of Mining SB RAS, Russia 630090, Krasnyi propect 54, Junior Researcher. Novosibirsk State University, 630090, Russia, Novosibirsk, Pirogova st. 2, Junior Researcher

Aleksander S. Serdyukov

Trofimuk Institute of Petroleum Geology and Geophysics SB RAS, 3, Akademika Koptyuga Ave., Novosibirsk, 630090, Russia, PhD, Researcher, e-mail: serdyukovas@ipgg.sbras.ru; Institute of Mining SB RAS, Russia 630090, Krasnyi propect 54, Junior Researcher

The results of using an adapted sampling algorithm by the Monte Carlo method to estimate the ambiguity domain of the inversion of synthetic dispersion curves of the phase velocities of surface waves using artificial neural networks are discussed in the paper. The expediency of using the considered algorithm for calculating a probabilistic estimate of the results of the inverse problem solution in the method of multichannel analysis of surface waves has been confirmed.

Keywords: inversion, artificial neural network, uncertainty of the seismic inversion problem

Введение

В работе рассматривается метод многоканального анализа поверхностных волн (MASW) на предмет оценки области неоднозначности решения обратной задачи при помощи искусственных нейронных сетей (ИНС). Метод MASW активно применяется для изучения скоростного строения верхней части геологического разреза [1], а также входит в перечень обязательных инструментов сейсмического микрорайонирования в РФ [2]. Актуальны исследования методом MASW выполняемые в классе слоистых моделей, т.е. когда одновременно восстанавливаются скорости S-волны и мощности каждого слоя [3]. Для решения обратной задачи метода MASW в классе слоистых скоростных моделей используются методы глобального поиска [4, 5] и ИНС [6, 7]. Преимущества использования ИНС – более высокая скорость вычисления и отсутствие необходимости настройки параметров оптимизации, в отличие от методов глобальной оптимизации.

Обратная задача метода MASW, обращение дисперсионных кривых зависимостей фазовых и/или групповых скоростей поверхностной волны от частоты, некорректна и неоднозначна [8]. При восстановлении большого числа неизвестных параметров восстанавливаемой скоростной модели неоднозначность обратной задачи усиливается, и задача поиска истинного решения имеет вероятностный характер. Это приводит к необходимости оценки области неоднозначности решения обратной задачи.

Для корректной оценки области неоднозначности решения обратной задачи сейсмологии необходимо спроецировать на пространство скоростных моделей как шум в данных, так и ошибки, вводимые обратным оператором. За счёт высокой скорости вычислений инверсии с применением ИНС целесообразно использовать подходы на основе алгоритма Монте-Карло с Марковскими цепями [9]. Необходимо учитывать особенности ввода шума в данные при рассмотрении задачи обращения дисперсионных кривых поверхностных волн. В частности, некорректно использование Гауссовского распределения вероятности шума с постоянным стандартным отклонением. На практике, спектральное размывание максимумов энергии дисперсионных кривых, а, следовательно, и вероятность их ошибочного пикирования, усиливается с уменьшением частоты. Отметим также, что распределение вероятности шума в дисперсионной кривой поверхностной волны является непараметрическим (не Гауссовым), поскольку регулярные и случайные помехи вводят смещения в максимумы энергии целевой фундаментальной моды [10].

Авторам настоящего исследования неизвестны работы по оценке области неоднозначности алгоритма инверсии дисперсионных кривых поверхностных волн с использованием многослойной полносвязной ИНС. В настоящей работе приведены результаты применения алгоритма семплирования методом Монте-Карло [9] адаптированного к решению данной задачи.

Методы

Рассматриваемый алгоритм инверсии дисперсионных кривых фазовых скоростей поверхностных волн состоит из следующих основных этапов: 1 – осреднение дисперсионных кривых, полученных в процессе спектрального анализа; 2

– оценка диапазонов параметров скоростной модели; 3 – расчёт набора обучающих данных; 4 – обучение искусственной нейронной сети (ИНС) и сохранение весов; 5 – применение сохранённых весов ИНС для инверсии дисперсионных кривых. Алгоритм инверсии подробно изложен в статье [7].

Для формирования обучающей выборки в пределах оценённых диапазонов возможных решений равномерно выбираются значения скорости S-волны ($V_S = [V_{S,1}, V_{S,2}, \dots, V_{S,l}]$, где l – число слоёв восстанавливаемой модели) и мощности ($h = [h_1, h_2, \dots, h_{l-1}]$). Для каждой пары векторов V_S и h численно решается прямая задача и вычисляются значения дисперсионной кривой фазовой скорости ($V_{R, \text{расчётная}} = [V_{R,1}, V_{R,2}, \dots, V_{R,m}]$, где m – число отсчётов по частоте). $V_{R, \text{расчётная}}$ – формирует входной слой ИНС. Выходным слоем ИНС является конкатенация $V_S \cup h$. Оптимальным в смысле приемлемых точности инверсии и скорости обучения ИНС является $s = 250000$ примеров $V_S \cup h \in M$ (M имеет размерность $s \times (2l - 1)$, где l – число слоёв скоростной модели) и соответствующих им $V_{R, \text{расчётная}} \in D$ (D имеет размерность $s \times m$). В процессе итерационного обучения ИНС за счёт минимизации функционала $MAE(W \cdot [V_S \cup h] - V_{R, \text{расчётная}}) \rightarrow \min$, где MAE – средняя абсолютная ошибка (функционал невязки), подбираются веса ИНС (W). Подобранные W являются обратным оператором, который отображает пространство извлечённых фазовых скоростей в пространство параметров скоростной модели: $W \cdot D = M$. Алгоритм подбора гиперпараметров архитектуры ИНС выходит за рамки данной статьи.

Для оценки области неоднозначности обращения дисперсионных кривых фазовых скоростей с помощью ИНС адаптируется и применяется алгоритм семплирования методом Монте-Карло, описанный в работе [9]. Так, для генерации шума, вводимого в дисперсионные кривые, используется Гауссово распределение с частотно-зависимым стандартным отклонением.

Результаты экспериментов

Детально рассмотрим алгоритм оценки области неоднозначности на примере инверсии синтетической дисперсионной кривой фазовой скорости, вычисленной для горизонтально-слоистой скоростной модели, упругие параметры которой приведены в табл. 1.

Таблица 1

Упругие параметры скоростной модели

Номер слоя	V_S (м/с)	h (м)	V_p (м/с)	ρ (кг/м ³)	Оценённые диапазоны возможных значений	
					V_S (м/с)	h (м)
1	300	2.5	624	1900	210-410	1.2-3.7
2	500	8	1040	1900	428-628	1.2-14.9
3	800	∞	1665	1900	671-871	∞

Для определения статистических характеристик распределения шума, вводимого в дисперсионную кривую фазовых скоростей необходимо рассмотреть волновые формы и V - f спектр рассматриваемой дисперсионной кривой. Волновые формы были вычислены на различном удалении от источника с использованием алгоритма, описанного в работе [11], и сгруппированы в сейсмограмму ОТВ, которая содержит только фундаментальную моду волны Релея (рис. 1а). V - f спектр (рис. 1б) был получен с использованием алгоритма, описанного в работе [12]. Извлечённая из V - f спектра дисперсионная кривая фазовой скорости ($V_{R, \text{извлечённая}} = [V_{R,1}, V_{R,2}, \dots, V_{R,m}]$, где m – число отсчётов по частоте) обозначена красными точками на рис. 1б.

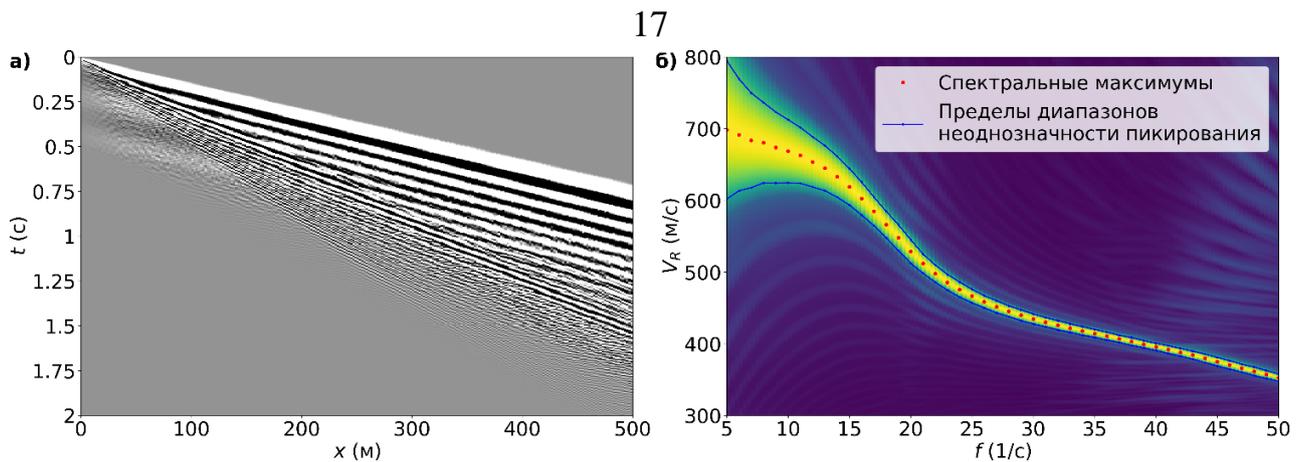


Рис. 1. Синтетические данные:

а) сейсмограмма, содержащая только фундаментальную моду волны Релея и б) её V - f спектр.

В виду того, что спектральное размывание максимумов энергии уменьшается с увеличением частоты, стандартное отклонение (σ) шума, вводимого в значения фазовой скорости должно быть переменным по частоте, т.е. $\sigma_{\text{шума}} = \sigma_{\text{шума}}(f)$. Примем такие значения $V_{R, \text{извлечённая}}(f)$ за пределы неоднозначности пикирования (синяя кривая на рис. 1б), где амплитуда поверхностной волны уменьшилась в два раза относительно максимума на фиксированной частоте. Допустим, что распределение шума на каждой частоте симметрично относительно максимума, т.е. математическое ожидание $\mu_{\text{шума}}(f) = 0$. Тогда распределение шума определяется Гауссовым распределением на каждой частоте как $\mathcal{N}(0, \sigma_{\text{шума}}(f))$. Объем выборки $\mathcal{N}(0, \sigma_{\text{шума}}(f))$ обозначим u и примем $u = 10000$ отсчётов на каждой частоте.

В ходе применения алгоритма, описанного в [7], оцениваются диапазоны возможных значений V_S и h (столбцы 6-7 таблицы 1), рассчитывается набор тренировочных данных $V_S \cup h \in \mathbf{M}$ и соответствующие им дисперсионные кривые $V_{R, \text{рассчётная}} \in \mathbf{D}$, обучается ИНС и сохраняются веса (\mathbf{W}). \mathbf{W} применяются для общения всех кривых из \mathbf{D} : $\mathbf{W}[\mathbf{D}] = \bar{\mathbf{M}}$. Далее рассчитываются ошибки $\mathbf{E} = \mathbf{M} -$

\bar{M} . Вычисленные значения $\mu_{\text{ошибки}}$ и $\sigma_{\text{ошибки}}$ из E , соответствующих распределениям ошибки восстановления V_S и h , используются для определения распределения ошибок обратного оператора: $\mathcal{N}(\mu_{\text{ошибки}}, \sigma_{\text{ошибки}})$ (рис. 2). Объем выборки $\mathcal{N}(\mu_{\text{ошибки}}, \sigma_{\text{ошибки}})$ также примем равным u ($u = 10000$ отсчётов) для V_S и h в каждом слое. Значения $\mu_{\text{ошибки}}$ близки к нулю во всех случаях.

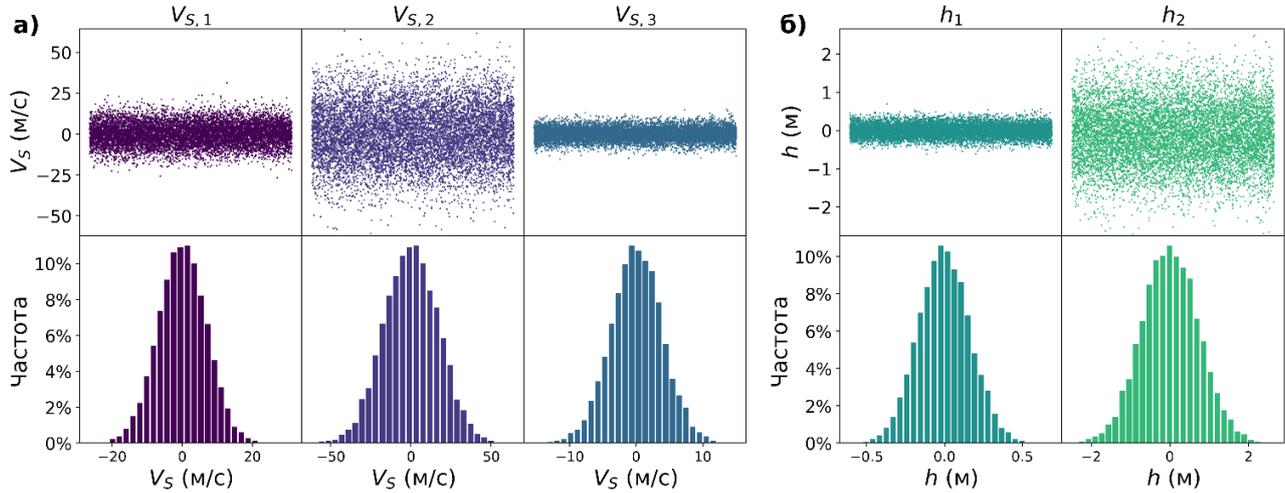


Рис. 2. Гистограммы распределений Гауссовского шума, полученного по статистическим характеристикам распределений ошибок восстановления набора обучающих данных:

а) скорости S-волны и б) мощности каждого слоя

Согласно алгоритму [9], W применяются для обращения $V_{R, \text{извлечённая}}(f)$: $W[V_{R, \text{извлечённая}}(f)] = \bar{m}$ и рассчитывается прямая задача $F[\bar{m}] = V_{R, \text{восстановленная}}(f)$. Далее для всех $n(f) \in \mathcal{N}(0, \sigma_{\text{шума}}(f))$ вводится шум в $D_n = V_{R, \text{восстановленная}}(f) + n(f)$. D_n имеет размерность $t \times u$. Выполняется инверсия: $W[D_n] = \bar{M}_n$. Далее для всех $n \in \mathcal{N}(\mu_{\text{ошибки}}, \sigma_{\text{ошибки}})$ вводятся ошибки обратного оператора в $\bar{M}_n^{\text{искомое}} = \bar{M}_n + n$. $\bar{M}_n^{\text{искомое}}$ имеет размерность $(2l - 1) \times u$. $\bar{M}_n^{\text{искомое}}$ является распределением восстановленных значений V_S и h путём обращения $V_{R, \text{извлечённая}}(f)$ с учётом ввода случайного шума в $V_{R, \text{извлечённая}}(f)$ и ввода ошибок обратного оператора в V_S и h . По значениям $\bar{M}_n^{\text{искомое}}$ рассчитывается прямая задача $F[\bar{M}_n^{\text{искомое}}] = D_n^{\text{искомое}}$. Распределения восстановленных параметров из $\bar{M}_n^{\text{искомое}}$ и истинная скоростная модель (красная кривая) изображены на рис. 3а в виде одномерных скоростных моделей. Цветовой палитрой отображена невязка между $V_{R, \text{извлечённая}}(f)$ и $D_n^{\text{искомое}}$ (меньшие значения более яркие). $D_n^{\text{искомое}}$ и $V_{R, \text{извлечённая}}(f)$ (красная кривая) изображены на рис. 3б.

По относительной разнице между истинным решением и минимальным $\bar{M}_n^{\text{искомое}}$, истинным решением и максимальным $\bar{M}_n^{\text{искомое}}$ определяется область неоднозначности восстановления параметров скоростной модели: $V_{S,1} = [-46\%; 40\%]$, $V_{S,2} = [-23\%; 44\%]$, $V_{S,3} = [-7\%; 11\%]$, $h_1 = [-59\%; 35\%]$, $h_2 = [-29\%; 63\%]$.

Время применения сохранённых весов ИНС $t_W = 0.3$ с для обращения всех 10000 примеров, время подбора весов ИНС $t_{\text{обучения}} = 630$ с.

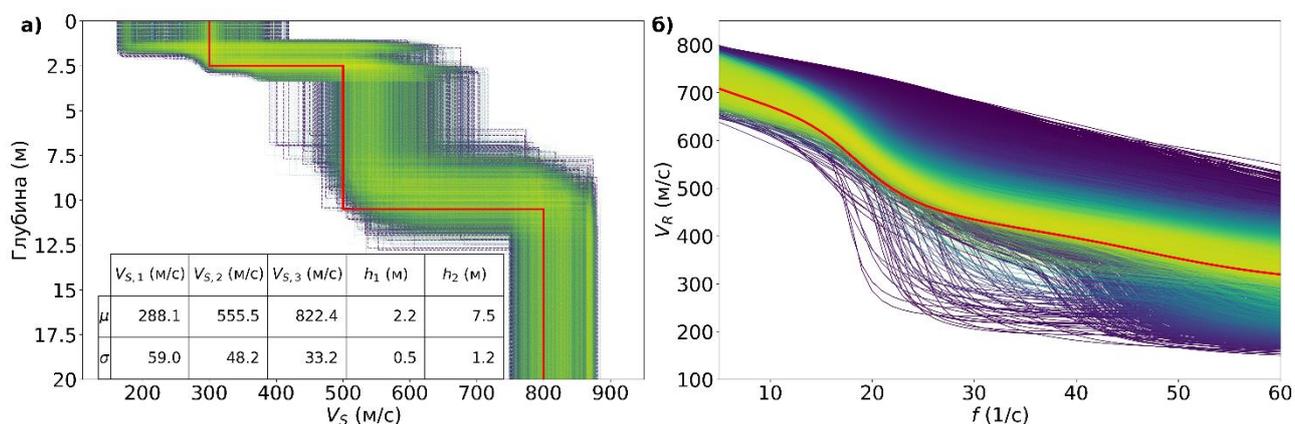


Рис. 3. Результирующие распределения восстановленных а) скоростных моделей и б) рассчитанных по ним дисперсионных кривых. Красным цветом нанесена истинная скоростная модель и извлечённая дисперсионная кривая

Обсуждение результатов

Дальнейшие пути исследования сосредоточены на подборе и анализе непараметрических распределений шума, статистические характеристики которых могут быть связаны не только с частотно зависимым спектральным размыванием, но с закономерностями перетекания энергии на V - f спектре при наличии регулярных и случайных помех в сейсмических данных.

Перспективны поиски направлений повышения точности обучения и применения ИНС для инверсии, в частности рассмотрение одновременной инверсии дисперсионных кривых фазовой и групповой скорости, использование мод высшего порядка или всего спектрального изображения.

Заключение

В работе приведены результаты оценки области неоднозначности обращения дисперсионных кривых поверхностных волн с применением ИНС с использованием адаптированного к решению данной задачи алгоритма семплирования методом Монте-Карло. Основным преимуществом использования ИНС для инверсии дисперсионных кривых является высокая скорость вычисления при аппроксимации на большом объёме данных, следовательно, целесообразно использовать описанную в работе процедуру оценки неоднозначности решения при обработке реальных данных для вычисления вероятностной оценки результатов.

Благодарности

Исследование выполнено при финансовой поддержке РНФ в рамках научного проекта № 20-77-10023.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. 1. Park C. B., Miller R. D., Xia J. Multichannel analysis of surface waves // *Geophysics*. – 1999. – V. 64. – №. 3. – P. 800-808.
2. 2. СП 283. 1325800.2016. Объекты строительные повышенной ответственности. Правила сейсмического микрорайонирования.
3. 3. Multichannel analysis of surface waves to map bedrock / R.D. Miller [et al.] // *The Leading Edge*. – 1999. – V. 18. – №. 12. – P. 1392-1396.
4. 4. Cox B. R., Teague D. P. Layering ratios: a systematic approach to the inversion of surface wave data in the absence of a priori information // *Geophysical Journal International*. – 2016. – V. 207. – №. 1. – P. 422-438.
5. 5. Grey wolf optimizer for parameter estimation in surface waves / X. Song [et al.] // *Soil Dynamics and Earthquake Engineering*. – 2015. – V. 75. – P. 147-157.
6. 6. Çaylak Ç., Kaftan İ. Determination of near-surface structures from multi-channel surface wave data using multi-layer perceptron neural network (MLPNN) algorithm // *Acta Geophysica*. – 2014. – V. 62. – №. 6. – P. 1310-1327.
7. 7. Yablokov A., Serdyukov A. Inversion of Surface Waves Dispersion Curves Using Artificial Neural Network // 82nd EAGE Annual Conference & Exhibition. – European Association of Geoscientists & Engineers, 2020. – V. 2020. – №. 1. – P. 1-5.
8. 8. Foti S., Lai C.G., Rix G.J., Strobbia C. Surface wave methods for near-surface site characterization / Boca Raton, 2014. – 482 p.
9. 9. Aleardi M., Salusti A. Elastic pre-stack inversion through Discrete Cosine Transform reparameterization and Convolutional Neural Networks // *Geophysics*, 2021. – V. 86. – №. 1. – P. 1JF-V89.
10. 10. Hayashi K., Suzuki H. CMP cross-correlation analysis of multi-channel surface-wave data // *Exploration Geophysics*. – 2004. – V. 35. – №. 1. – P. 7-13.
11. 11. Gaždová R., Vilhelm J. DISECA—A Matlab code for dispersive waveform calculations // *Computers and Geotechnics*. – 2011. – V. 38. – №. 4. – P. 526-531.
12. 12. Serdyukov A.S., Yablokov A.V., Duchkov A.A., Azarov A.A., Baranov V.D. Slant f-k transform of multichannel seismic surface wave data // *Geophysics*. – 2019. – T. 84. – №. 1. – C. A19-A24.

REFERENCES

1. Park C. B., Miller R. D., Xia J. Multichannel analysis of surface waves // *Geophysics*. – 1999. – V. 64. – №. 3. – P. 800-808.
2. SP 283. 1325800.2016. Ob"ekty stroitel'nye povyshennoj otvetstvennosti. Pravila sejsmicheskogo mikrorajonirovaniya.
3. Multichannel analysis of surface waves to map bedrock / R.D. Miller [et al.] // *The Leading Edge*. – 1999. – V. 18. – №. 12. – P. 1392-1396.
4. Cox B. R., Teague D. P. Layering ratios: a systematic approach to the inversion of surface wave data in the absence of a priori information // *Geophysical Journal International*. – 2016. – V. 207. – №. 1. – P. 422-438.
5. Grey wolf optimizer for parameter estimation in surface waves / X. Song [et al.] // *Soil Dynamics and Earthquake Engineering*. – 2015. – V. 75. – P. 147-157.

6. Çaylak Ç., Kaftan İ. Determination of near-surface structures from multi-channel surface wave data using multi-layer perceptron neural network (MLPNN) algorithm // *Acta Geophysica*. – 2014. – V. 62. – №. 6. – P. 1310-1327.
7. Yablokov A., Serdyukov A. Inversion of Surface Waves Dispersion Curves Using Artificial Neural Network // 82nd EAGE Annual Conference & Exhibition. – European Association of Geoscientists & Engineers, 2020. – V. 2020. – №. 1. – P. 1-5.
8. Foti S., Lai C.G., Rix G.J., Strobbia C. Surface wave methods for near-surface site characterization / Boca Raton, 2014. – 482 p.
9. Aleardi M., Salusti A. Elastic pre-stack inversion through Discrete Cosine Transform reparameterization and Convolutional Neural Networks // *Geophysics*, 2021. – V. 86. – №. 1. – P. 1JF-V89.
10. Hayashi K., Suzuki H. CMP cross-correlation analysis of multi-channel surface-wave data // *Exploration Geophysics*. – 2004. – V. 35. – №. 1. – P. 7-13.
11. Gaždová R., Vilhelm J. DISECA—A Matlab code for dispersive waveform calculations // *Computers and Geotechnics*. – 2011. – V. 38. – №. 4. – P. 526-531.
12. Serdyukov A.S., Yablokov A.V., Duchkov A.A., Azarov A.A., Baranov V.D. Slant f-k transform of multichannel seismic surface wave data // *Geophysics*. – 2019. – T. 84. – № 1. – S. A19-A24.

© A. B. Яблоков, А. С. Сердюков, 2021