

УДК 622.22; <https://doi.org/10.37878/2708-0080/2023-2.05>

<https://orcid.org/0000-0002-5994-8184>

<https://orcid.org/0000-0001-5442-4763>

<https://orcid.org/0009-0008-5239-6648>

ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ПРОГНОЗИРОВАНИЯ ОЧИСТКИ СТВОЛА СКВАЖИНЫ ОТ ВЫБУРЕННОЙ ПОРОДЫ



А.Б. ШАРАУОВА¹,
PhD, ассистент-профессор,
A.Sharauova@aogu.edu.kz



Д.Н. ДЕЛИКЕШЕВА²,
магистр, старший преподаватель,
d.delikesheva@satbayev.university



И. ЯЛАЛЕТДИНОВ³,
технический директор,
yalaletdinov.idris@gmail.com

¹НАО «АТЫРАУСКИЙ УНИВЕРСИТЕТ НЕФТИ И ГАЗА ИМ. С. УТЕБАЕВА»,
Республика Казахстан, 060027, г. Атырау, ул. М. Баймуханова, 45а

²SATBAYEV UNIVERSITY,
Республика Казахстан, 050000, г. Алматы, ул. К.Сатпаева, 22

³ТОО "СИЛК-ТЕК",
Республика Казахстан, 050000, г. Алматы, ул. Казыбаева, 1

Операции бурения обычно сталкиваются с рядом проблем, которые могут существенно повлиять на программу бурения за счет увеличения времени, необходимого для бурения до заданной глубины. К таким проблемам относят прихват трубы, а устранение такого рода аварий являются самыми сложными, самыми трудоемкими, самыми рискованными, и даже весь ствол скважины или его часть могут быть забросаны.

Данная проблема тесно связана с условиями очистки скважины и могут быть преодолены путем обеспечения хороших условий очистки скважины.

Проблемы с очисткой ствола можно уменьшить, используя модели машинного обучения, которые могут прогнозировать состояние ствола скважины с помощью реальных полевых данных в режиме реального времени и предлагает оптимальные действия. Используя возможности машинного обучения, компании, занимающиеся бурением скважин, могут добиться более точной и эффективной оценки очистки ствола скважины, что приведет к повышению производительности бурения.

В данной работе были обучены две модели машинного обучения: первая модель предназначена для прогнозирования наличия и залегания шламовой подушки в скважине в процессе бурения; вторая модель – это регрессионная модель, которая может использоваться для прогнозирования высоты пласта шлама и помогает показать, насколько серьезна ситуация на забое скважины или она не критична.

Результаты данной работы могут быть использованы инженерами-буровиками, чтобы в режиме реального времени получать уведомления о риске недостаточной очистки скважины во время бурения.

КЛЮЧЕВЫЕ СЛОВА: прихват бурового инструмента, очистка ствола скважины, машинное обучение, регрессионный анализ, классификационный анализ.

ҰҢҒЫМА ОҚПАНЫҢ БҰРҒЫЛАНҒАН ТАУ ЖЫНЫСТАРЫНАН ТАЗАЛАУДЫ БОЛЖАУ ҮШІН МАШИНАЛЫҚ ОҚУ ӘДІСТЕРІН ҚОЛДАНУ

А.Б. ШАРАУОВА¹, PhD, ассистент-профессор, A.Sharauova@aogu.edu.kz
Д.Н. ДЕЛИКЕШЕВА², магистр, аға оқытушы, d.delikesheva@satbayev.university
И. ЯЛАЛЕТДИНОВ³, техникалық директор, yalaletdinov.idris@gmail.com

¹«С. ӨТЕБАЕВАТЫНДАҒЫ АТЫРАУ МҰНАЙ ЖӘНЕ ГАЗ УНИВЕРСИТЕТІ» КЕАҚ,
Қазақстан Республикасы, 060027, Атырау қ., М.Баймұханов көш., 45а

²SATBAYEV UNIVERSITY,
Қазақстан Республикасы, 050000, Алматы қ., Қ. Сәтпаев көш., 22

³«СИЛК-ТЕК» ЖШС,
Қазақстан Республикасы, 050000, Алматы қ., Қазыбаева көш., 1

Бұрғылау операциялары, әдетте, бұрғылау бағдарламасына белгілі бір тереңдікке дейін бұрғылауға кететін уақытты көбейту арқылы айтарлықтай әсер етуі мүмкін бірқатар мәселелерге тап болады. Мұндай мәселелерге құбырдың қысылып қалуы жатады, ал мұндай апаттарды жою ең қиын, көп уақытты қажет етеді, ең қауіпті, тіпті ұңғыманың бүкіл оқпаны немесе оның бір бөлігі лақтырылуы мүмкін.

Бұл мәселе ұңғымаларды тазалау жағдайларымен тығыз байланысты және ұңғымаларды тазалаудың жақсы шарттарын қамтамасыз ету арқылы алдын алуға болады.

Нақты уақыттағы дала деректерімен ұңғыма оқпанының күйін болжай алатын және ең жақсы әрекет жолын ұсына алатын машиналық оқыту үлгілерін пайдалану арқылы ұңғымаларды тазалау мәселелерін азайтуға болады. Ұңғымаларды бұрғылаумен айналысатын компаниялар машинаналық оқытудың күшін пайдалана отырып, ұңғыма оқпанын тазалауды дәлірек және тиімді бағалауға қолжеткізе алады, бұл бұрғылау өнімділігін арттырады.

Бұл жұмыста машиналық оқытудың екі моделі үйретіледі: бірінші модель – бұрғылау кезінде ұңғымадағы шлам төсенішінің болуын және пайда болуын болжауға арналған; екінші модель – бұл шлам қабатының биіктігін болжау үшін қолдануға болатын және ұңғыманың кенжарындағы жағдайдың қаншалықты ауыр немесе маңызды емес екенін көрсетуге көмектесетін регрессиялық модель.

Бұл жұмыстың нәтижелерін бұрғылау кезінде ұңғыманы жеткіліксіз тазарту қаупі туралы нақты уақыт режимінде хабарлама алу үшін бұрғылау инженерлері қолдана алады.

ТҮЙІН СӨЗДЕР: бұрғылау аспабының қысылуы, ұңғыма оқпанын тазалау, машинаналық оқыту, регрессиялық талдау, жіктеу талдауы.

APPLICATION OF MACHINE LEARNING METHODS TO PREDICTION OF HOLE CLEANING FROM CUTTINGS

A.B. SHARAUOVA¹, PHD, assistant professor, *A.Sharauova@aogu.edu.kz*
 D.N. DELIKESHEVA², MSc, senior lecturer, *d.delikesheva@satbayev.university*
 I. YALALETDINOV³, technical director, *yalaletdinov.idris@gmail.com*

¹ATYRAU UNIVERSITY OF OIL AND GAS NAMED AFTER S. UTEBAEV,
 Republic of Kazakhstan, 060027, Atyrau, BaimukhanovaSt., 45a

²SATBAYEV UNIVERSITY,
 Republic of Kazakhstan, 050000, Almaty, K. Satpaeva St., 22

³"SILK-TECH" LLP,
 Republic of Kazakhstan, 050000, Almaty, Kazybaev st., 1

Drilling operations typically face several issues that can significantly impact a drilling program by increasing the time required to drill to a given depth. Such problems include pipe sticking, and the elimination of such accidents is the most difficult, the most time-consuming, the most risky, and even the entire wellbore or part of it can be abandoned. This problem is closely related to hole cleaning conditions and can be overcome by providing good hole cleaning conditions. Wellbore cleaning problems can be reduced by using machine learning models that can predict wellbore condition with real-time field data and suggest the best course of action. By leveraging the power of machine learning, well drilling companies can achieve more accurate and efficient hole cleaning estimation, resulting in improved drilling productivity. In this work, two machine learning models were trained: the first model is designed to predict the presence and occurrence of a cutting bed in a well during drilling; the second model is a regression model that can be used to predict the cutting bed height and helps to show how serious the situation is at the bottom of the well or if it is not critical. The results of this work can be used by drilling engineers to receive real-time notifications about the risk of insufficient well cleaning during drilling.

KEY WORDS: *stuck pipe, wellbore cleaning, machine learning, regression analysis, classification analysis.*

Введение. Прихват трубы является типичным внеплановым событием во время буровых работ, но особенно проблематичным, так как на него приходится не менее 25% НПВ (непроизводственное время), что эквивалентно годовым затратам в 2 буро-года [1]. Продолжительность процесса прихвата трубы и восстановления может в основном варьироваться от нескольких дней до более чем месяца для устранения [2].

В дополнение к потерянным времени и дневной норме буровой установки, инциденты с прихватом трубы часто сопровождаются расходами, связанными с ремонтом, такими как потеря инструментов, затраты на ловильные работы и/или затраты на зарезку боковых стволов [3].

Одним из главных причин прихвата трубы является неэффективная очистка ствола скважины от выбуренной породы, которая может возникнуть на различных этапах бурения скважины [4,5].

Эффективная транспортировка шлама и очистка скважины во время бурения необходимы для правильной оптимизации буровых работ. При наклонном и горизонтальном бурении вопросы очистки скважины являются общими и сложными проблемами, так как при увеличении угла наклона скважины за счет оседания шлама вдоль забоя и низкого борта скважины образуется «подушка» твердых частиц [5,6].

Транспортировка шлама зависит от многих переменных, таких как наклон скважины, угол, диаметр отверстия и бурильной трубы, скорость вращения бурильной трубы, эксцентриситет бурильной трубы, скорость проходки, характеристики шлама, такие как размер шлама и пористость пласта, и характеристики буровых растворов, такие как дебит, скорость жидкости, режим течения, тип бурового раствора и неньютоновская реология бурового раствора. Ключевыми факторами для оптимизации очистки скважины являются хороший план скважины, правильные свойства бурового раствора и хороший опыт бурения [6,7].

Проблемы с очисткой ствола можно уменьшить, используя алгоритмы на основе методов машинного обучения, которые можно обучать на данных прошлых операций бурения для выявления закономерностей и взаимосвязей, которые можно использовать для прогнозирования оптимальных параметров бурения для данной скважины.

В этой работе будут рассмотрены алгоритмы и подходы машинного обучения, которые можно использовать для этой цели, включая обучение с учителем. Помимо этого, в работе будут обсуждены проблемы и ограничения использования машинного обучения для оценки высоты шламовой подушки, а также возможные решения этих проблем.

Сначала был произведен анализ данных, и проверка их на наличие потенциальных проблем, после были отображены результаты различных методов машинного обучения и сформулированы выводы о практическом значении результатов.

Материалы и методы исследований. Данные, используемые в этой работе, были получены с помощью программного обеспечения WellPlan. Он состоит из планов бурения 8 скважин с различными конфигурациями бурового долота и бурильных колонн. После ввода всех необходимых данных, которые состоят из литологии, характеристик машин и оборудования и обсадной колонны.

И после извлечения данных получаем данные, которые показаны в *таблице 1*.

Непрерывная переменная, которую мы пытаемся предсказать, а именно высота шламовой подушки. Поэтому в данном исследовании для моделирования проблемы используются алгоритмы регрессии. Среди включенных методов – линейная регрессия, анализ основных компонентов, деревья решений и глубокое обучение [8].

Регрессия — это тип контролируемой задачи машинного обучения, которая включает прогнозирование непрерывного числового значения. Он часто используется для прогнозирования реальных величин, таких как цены, температуры или вес. Регрессия с использованием нейронных сетей, также известная как регрессия нейронной сети, представляет собой метод использования нейронной сети для прогнозирования непрерывного числового значения [9].

Для предсказания наличия шлама в стволе скважины была применена задача машинного обучения – классификация.

Классификация – задача машинного обучения, целью которой является определение к какому классу из многих относится наблюдение. В своем самом базовом

виде нужно определить к какому из 2 классов относиться наблюдение, также называемая – бинарная классификация. Используя её в этой работе, мы можем, обучив нейронную сеть, разделить интервал бурения на участки с риском образования шламовой подушки и без [10].

Чтобы обучить нейронную сеть, используется алгоритм оптимизации, такой как стохастический градиентный спуск (SGD) или Адам, чтобы минимизировать ошибку между предсказанными значениями и истинными значениями в обучающих данных. Ошибка обычно измеряется с использованием функции потерь, такой как среднеквадратическая ошибка (MSE) или средняя абсолютная ошибка (MAE) [11].

Таблица 1 – Отчет о классификации

Мин. расход	Расстояние вдоль колонны	Вертикальная глубина	Температура	Давление	Плотность	Пластическая вязкость	Скорость проникновения	Параметр частиц шлама	Пористость шламовой подушки	Скорость ротора	Плотность частиц шлама	Интервал расчета по глубине ствола скважины	Насосы подачи
15.539	120	119.35	30	1	1120	14	15	3	36	40	2.5	10	30
11.872	30	30	21	1	1200	20	15	3	36	40	2.5	10	32
14.889	1341.12	639.71	35	1	1230	18	8	3.18	36	80	2.5	30.48	16
5.812	190	190	30	1	1120	18	10	3.18	36	25	2.145	10	15
5.814	290	29	30	1	1120	18	10	3.18	36	25	2.145	10	15
19.408	579.12	472.55	35	1	1180	18	10	3.18	36	80	2.5	30.48	15
12.13	10	10	30	1	1120	14	15	3	36	40	2.5	10	30
11.875	230	230	21	1	1200	20	15	3	36	40	2.5	10	32

В нашем случае в ходе экспериментов с различными оптимизаторами и метриками мы пришли к оптимальной конфигурации, которая выглядит следующим образом: NAdam (Адам с импульсом Нестерова) как оптимизатор и метрика оценки MSE.

Результаты и обсуждение. После создания вышеуказанного набора данных на нем была обучена многослойную нейронную сеть. В ходе нескольких экспериментов пришли к выводу, что оптимальной по скорости вычислений и производительности является следующая конфигурация, состоящая из 14 входных единиц, 2 скрытых слоев, состоящих из 12 и 8 опорных единиц, и последней выходная сигмовидная единица, которая была использована для классификации.

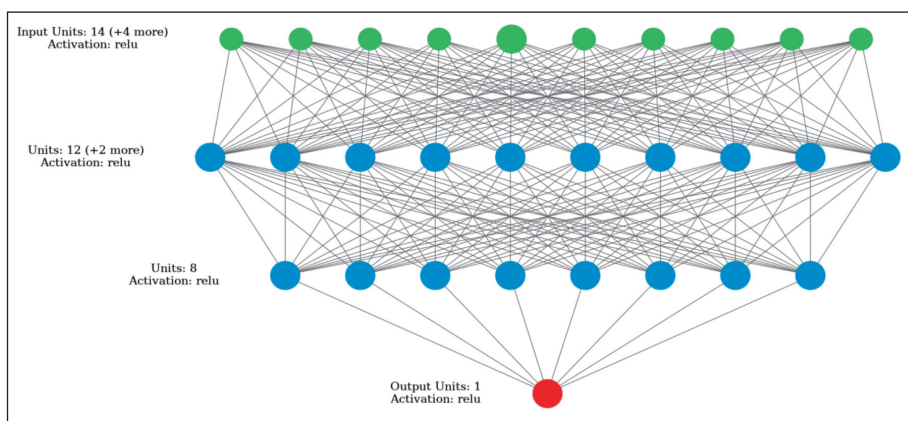


Рисунок 1 – Структура классификационной нейронной сети

При применении нейронных сетей для решения задач часто возникают проблемы недообучения и переобучения. Они обе ведут к неудовлетворительным результатам прогнозирования. В первом случае из-за недостаточного количества данных для обучения или плохо подобранной архитектуры сети. Решить эту проблему можно увеличив размер данных и поэкспериментировать со структурой.

Во втором случае модель слишком хорошо обучена на заданном обучающем наборе данных и не может обобщить свои прогнозы на новые, невиданные прежде данные. Чтобы это предотвратить можно разбить данные используемы для обучения на тренировочные, тестовые и валидационные. Данные для валидации играют роль новых наблюдений, которые модель ещё не видела, поэтому проводим это разделения до начала обучения. Тренировочные и тестовые можно разбить случайным образом, первые используются для обучения модели, а вторые для оценки качества обученной модели.

После обучения наша модель, показывает следующие результаты на данных для валидации:

точность отзыв f1-метрика поддержка

0	0.90	1.00	0.95	106
1	1.00	0.61	0.76	31
точность			0.91	137
макрос сред	0.95	0.81	0.85	137
взвешенное сред	0.92	0.91	0.90	137

Статистика, называемая точностью, используется в машинном обучении для оценки того, насколько хорошо работает модель категоризации. Он рассчитывается как общее количество точных положительных прогнозов модели, деленное на количество истинных положительных прогнозов. Другими словами, точность подсчитывает долю правильно предсказанных положительных результатов.

У нас есть ситуация, когда точность является наиболее подходящей оценочной метрикой, потому что, если мы не обнаружим образование гребней, это может привести к проблемам, описанным в начале работы.

Во время проверки на новых данных, которые не были включены в процедуру обучения (рисунки 2, 3), мы получили следующие результаты:

Как видно, наша модель хорошо работает с новыми данными. Он начинает прогнозировать образование шлама раньше, чем фактически, но это приведет к минимуму дополнительных усилий, учитывая, что это поможет предотвратить образование слоя шлама, который может вызвать прихват буровой колонны.

Прогнозирование высоты шламовой подушки. В нашем случае в ходе экспериментов с различными оптимизаторами и метриками мы пришли к оптимальной конфигурации, которая выглядит следующим образом: NAdam (Адам с импульсом Нестерова) как оптимизатор и метрика оценки MSE.

Наша нейронная сеть состоит из 14 входных единиц («Мин. q», «Измеренная глубина», «Вертикальная глубина», «Температура», «Давление», «Плотность»,




Рисунок 2 – Реальные результаты о наличии шламовой подушки




Рисунок 3 – Прогнозирование наличия шламовой подушки

«Пластичная вязкость», «Скорость проникновения», «Диаметр шлама», 'Пористость шлама', 'Обороты в минуту', 'Плотность шлама', 'Интервал расчета по глубине ствола скважины', 'Нагнетательная способность'), 3 скрытых слоя с функцией активации relu с 12, 8 и 16 единицами и единицей вывода relu. Вы можете увидеть визуализацию нашей модели на *рисунке 4*.

После обучения и оценки на тестовой выборке наша MSE составляет 0,00648, но это может быть результатом переобучения, поэтому мы должны проверить нашу модель на новых данных, проверка которых не была включена в обучение.

После прогнозирования новых данных мы получили следующие результаты (*рисунки 5, б*).

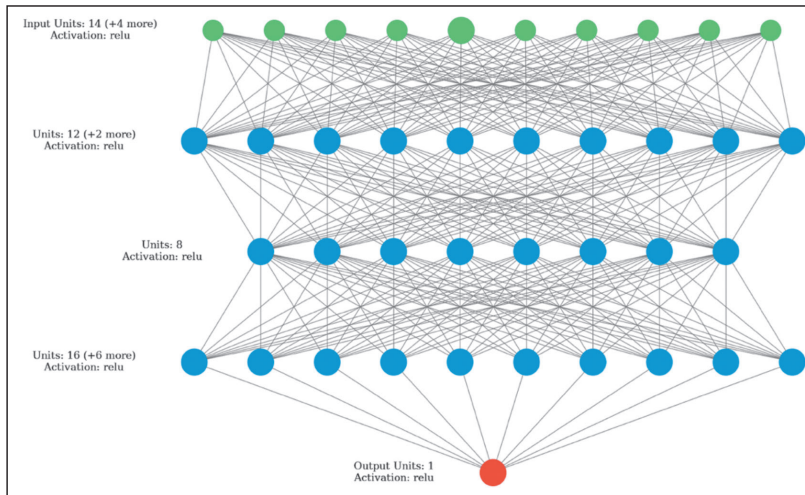


Рисунок 4 – Конфигурация регрессионной нейронной сети

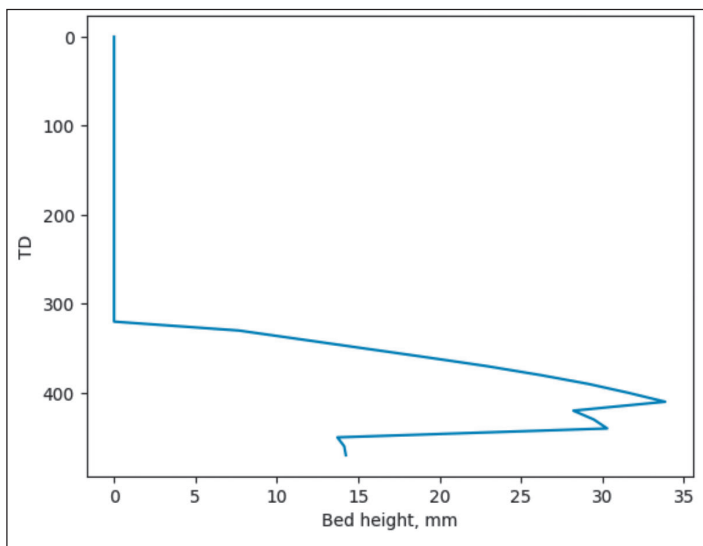


Рисунок 5 – Результаты высоты шламовой подушки по реальным данным




Рисунок 6 – Результаты высоты шламовой подушки по прогнозированным данным

Выводы.

1. Была обучена нейронная сеть для задачи классификации, которая используется для прогнозирования залегания пластового шлама в скважине в процессе бурения. Его могут использовать инженеры-буровики, чтобы в режиме реального времени получать уведомления о риске недостаточной очистки скважины во время бурения.

2. Была обучена нейронная сеть на основе регрессионной модели, которая может использоваться для прогнозирования высоты пласта шлама и помогает показать, насколько серьезна ситуация в скважине или она не критична. После обучения и оценки на тестовой выборке MSE составляет 0,00648, но это может быть результатом переобучения, поэтому необходимо проверить модель на новых данных. 🌐

Статья подготовлена в рамках проекта № AP13068658 «Разработка моделей крутящего момента, сопротивления и гидравлики для предупреждения прихвата труб путем мониторинга параметров бурения в режиме реального времени» в рамках проводимого конкурса на грантовое финансирование фундаментальных и прикладных исследований молодых ученых по научным и (или) научно-техническим проектам на 2022–2024 г.г. Министерства науки и высшего образования Республики Казахстан.

ЛИТЕРАТУРА

- 1 Muqem M.A, Weekse A.E, Al-Hajji A.A. Stuck pipe best practices: a challenging approach to reducing stuck pipe costs // Saudi Arabia section technical symposium and exhibition. – Al-Khobar, Saudi Arabia, 2012. <https://doi.org/10.2118/160845-MS>
- 2 AbdelhalimKh., Al ZaabiM., Al Ali S., Abdel Karim I., JadallahH., Al BeshrA., Shigeru E.A Challenging Drilling Campaign Unleashed a Unique Fast Drill String Recovery Methodology Eliminating Utilizing Wireline, CT and Overcome Highly Deviated String Accessibility // Middle East Drilling Technology Conference and Exhibition. – Abu Dhabi, UAE, 2021. doi: <https://doi.org/10.2118/202153-MS>

- 3 Aljubran M. J., Looni Q. D., Ramadhan, A. A., Neacsu M., Mora C. T., Emam A. A., Alomoush J., Ali A. M. Completion Planning and Execution of the World's Longest ICD Partially Cemented Production System in an Offshore Horizontal Well // Abu Dhabi International Petroleum Exhibition & Conference. – Abu Dhabi, UAE, 2016. doi: <https://doi.org/10.2118/182937-MS>
- 4 Mitchell J. Trouble-Free Drilling, third edition. – Houston: Drillbert Engineering, 2004. – P.230.
- 5 Egenti N.B. Understanding Drill-cuttings Transportation in Deviated and Horizontal Wells // Nigeria Annual International Conference and Exhibition. – Lagos, Nigeria, 2014.
- 6 Malekzadeh N., Mohammadsalehi M. Hole Cleaning Optimization in Horizontal Wells: A New Method to Compensate Negative Hole Inclination Effects // Brasil Offshore. – Macae', Brazil, 2011. <https://doi.org/10.2118/143676MS>.
- 7 Busahmin B., Saed N.H., Alusta G. Analysis of Hole Cleaning for a Vertical Well // Open Access Library Journal. – 2017. – Vol. 4. – P.1-10. <https://doi.org/oalib.1103579>.
- 8 Hastie T., Tibshirani R., Friedman J. The Elements of Statistical Learning (Second). – Springer, 2017. – P.727.
- 9 Noshi Christine I., Jerome J. Schubert. The Role of Machine Learning in Drilling Operations; A Review // Eastern Regional Meeting. – Pittsburgh, USA, 2018. doi: <https://doi.org/10.2118/191823-18ERM-MS>.
- 10 Soofi A. A., Awan A. Classification techniques in machine learning: applications and issues // J. Basic Appl. Sci. – 2017. – Vol. 13. – P. 459-465. <https://doi.org/10.6000/1927-5129.2017.13.76>
- 11 Diederik P. Kingma, Jimmy Lei Ba. Adam : A method for stochastic optimization // ICLR. – San Diego, USA, 2014. <https://doi.org/10.48550/arXiv.1412.6980>
- 12 Drew Mitchell, Nan Ye, Hans De Sterck. Nesterov Acceleration of Alternating Least Squares for Canonical Tensor Decomposition: Momentum Step Size Selection and Restart Mechanisms // Numerical Linear Algebra with Applications, 2018. – Vol.27. <https://doi.org/10.48550/arXiv.1810.05846>.