

пающего в рудник, увеличивает эффективность проветривания и воздухоподготовки, что в совокупности способствует на практике росту уровня безопасности при ведении горных работ.

*Исследование выполнено при финансовой поддержке Программы ФНИ,  
проект № 0422-2019-0145-С-01 (регистрационный номер темы НИОКТР:  
АААА-А18-118040690029-2).*

## БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Alymenko N.I., Kamenskikh A.A., Nikolaev A.V., Petrov A.L. Numerical modeling of heat and mass transfer during hot and cool air mixing in air supply shaft in underground mine // Eurasian mining. – 2016. – № 2. – С. 45-47.
2. Аэросеть – Решение проблем рудничной вентиляции. [официальный сайт]. – Текст электронный. – URL: <http://aeroset.net>. – (дата обращения: 16.03.2020).
3. Проведение воздушно-депресссионной съемки вентиляционной сети рудника Каральвеем АО «Рудник Каральвеем»: отчет о НИР по договору №15/2020 от 13.03.2020 / ГИ УрО РАН; рук. А.Г. Исаевич. – Пермь, 2020. – 71 с.

УДК 004.85

DOI:10.7242/echo.2020.4.19

## ПРОГНОЗИРОВАНИЕ КОНЦЕНТРАЦИИ МЕТАНА В РАБОЧЕЙ ЗОНЕ УГОЛЬНОЙ ШАХТЫ НА ОСНОВЕ РЕКУРРЕНТНЫХ НЕЙРОННЫХ СЕТЕЙ

А.В. Кашников, Д.М. Бузмаков  
Горный институт УрО РАН, г. Пермь

**Аннотация:** Данная работа описывает модель прогноза содержания метана в атмосфере рабочей зоны угольной шахты. При построении модели использованы оперативные показания датчиков и данные о текущей работе оборудования. В работе приводится сравнение результатов моделирования, полученных с использованием различных видов нейронных сетей. Прогнозирование изменения концентрации метана в рабочей зоне позволяет принимать оперативные решения для обеспечения эффективной работы оборудования при условии минимизации риска аварии.

**Ключевые слова:** искусственный интеллект, метан, угольная шахта, рекуррентная нейронная сеть, прогнозирование временных рядов.

### Введение

В данной работе рассматриваются предприятия, осуществляющие добычу угля подземным способом. В этом случае проблема газовыделений при извлечении горной породы приобретает особое значение ввиду ограниченности подземного пространства, в котором работают люди. Самым опасным фактором при добыче угля является выделение метана [1]. В подземных выработках угольной шахты находятся датчики, которые следят за его процентным содержанием в воздухе. Своевременное прогнозирование этого параметра позволяет подобрать режим работы добычного оборудования таким образом, чтобы обеспечить эффективное производство при соблюдении требований безопасности.

Прогнозирование временных рядов довольно частая тема научных статей, многие авторы представляют свои исследования по данной тематике, однако на сегодняшний день успешные модели прогнозирования опираются на регрессионный анализ данных и на так называемый «метод секущих окон» [2]. Однако данные модели работают ста-

бильно и с большой точностью лишь в тех случаях, когда имеются данные о всех факторах, которые оказывают непосредственное влияние на изучаемую величину. К сожалению, на реальном производстве не всегда можно измерить нужные данные. В настоящей работе рассматривается случай, когда мы имеем данные лишь о косвенных признаках, которые влияют на концентрацию метана в атмосфере рабочей зоны угольной шахты.

### **Выбор модели нейронной сети**

Существует большое количество различных моделей нейронных сетей: однослойный и многослойный персептрон, свёрточные нейронные сети и многие другие. В качестве рабочей модели была выбрана рекуррентная нейронная сеть, так как рекуррентные нейронные сети имеют свойство оценивать предыдущие полученные значения для получения новых значений. Оценивая временные ряды, не сложно понять, что на значения в определённый момент времени влияют не только входные параметры, полученные на данный момент, но и параметры, которые были получены несколько временных промежутков ранее [3]. Особенно это важно при прогнозе выделения метана из горных пород, поскольку он выделяется не только в месте работы комбайна, но и на всем обнажении пласта [4, 7].

Учитывая то, что данные с датчиков зачастую не являются непрерывными (в силу выхода из строя оборудования, сетей передачи данных), предварительной обработке данных было отведено большое значение. С помощью регрессионного анализа различные доступные параметры были исследованы на предмет влияния их на контрольное содержание метана. После чего были выделены следующие ведущие показатели:

- средняя сила тока, подаваемая на режущие органы комбайна;
- мощность, потребляемая лавным конвейером;
- расход воздуха, зафиксированный на всех датчиках дегазационных установок;
- расход воздуха, зафиксированный на входящей на рабочую зону струе воздуха;
- содержание метана, зафиксированное на входящей на рабочую зону струе воздуха.

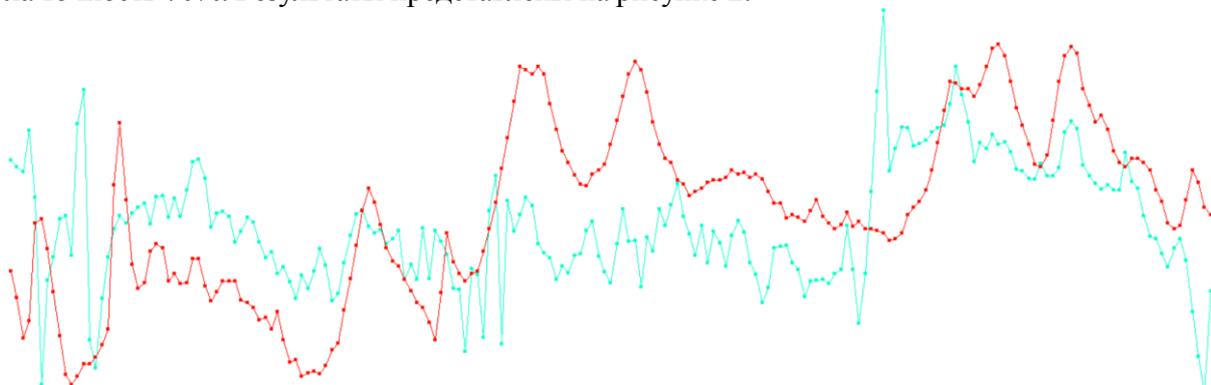
После этого данные были нормализованы, профильтрованы и преобразованы к нужному виду для подачи на вход рекуррентной нейронной сети.

Наш выбор выпадает на архитектуру «многие-к-одному», так как мы имеем несколько входных параметров и один выходной. С технической точки зрения модель рекуррентной нейронной сети будет отличаться лишь типом скрытого слоя. Выбор будет происходить между двумя альтернативами: Simple RNN и LSTM. В силу специфики предметной области был выбран слой Simple RNN, так как нам необходимо учитывать только самые близкие значения, не принимая во внимание то, что было в системе задолго до текущего состояния.

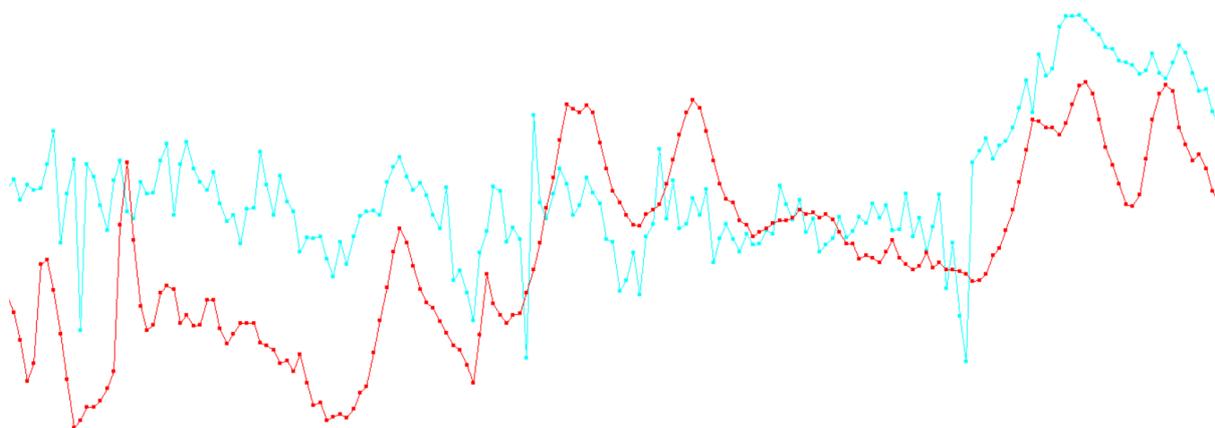
Вся разработка модели происходила с помощью стандартных возможностей открытой нейросетевой библиотеки Keras. Модель нейронной сети представляла из себя входной слой, скрытый рекуррентный слой Simple RNN, и один выходной слой. Simple RNN – простой слой рекуррентной сети, который способен предсказывать значение, основываясь лишь на нескольких предыдущих наборах данных. Активационной функцией выступал гиперболический тангенс. Самые лучшие результаты были получены при анализе 15 предыдущих минут для текущего значения. Результат обучения нейронной сети представлен на рисунке 1.

В результате получившаяся модель оценивает значение метана с точностью 67%. Данная модель имеет множество различных вариантов доработки. При увеличении интервала обучения точность модели уменьшается. Это связано в большей степени с тем, что исходные данные имеют некоторые интервалы отсутствующих значений. Неполнота данных может быть связана с различными рода проблемами на производстве. Поэтому интервал для обучения был выбран с наибольшим количеством имеющихся значений. Также для нахождения

минимума функции и избегания попадания в локальные экстремумы был применён приём случайных весов нейронов для нахождения самых благоприятных начальных значений, что привело к необходимости повторного обучения нейронной сети. В итоге нейронная сеть дала точность 70%. Результаты представлены на рисунке 2.



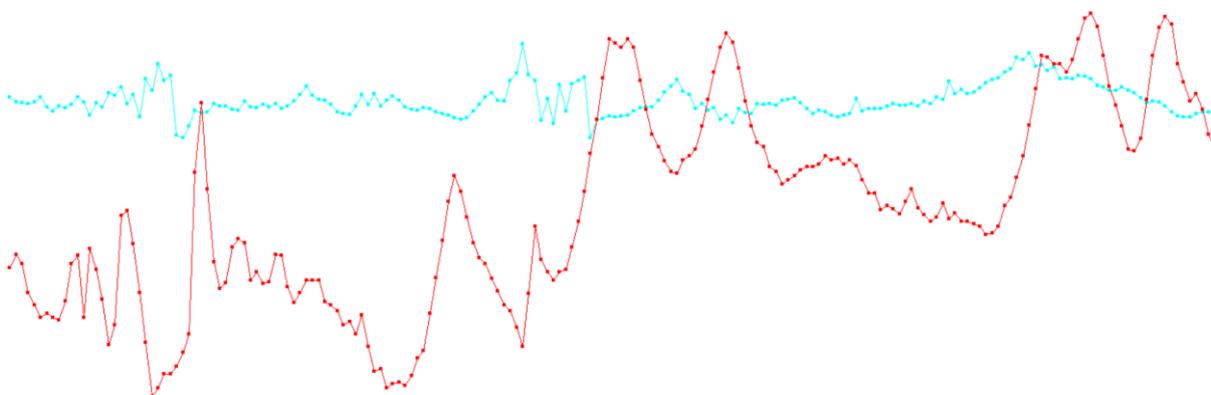
**Рис. 1.** Графики реального содержания метана (красный) и предсказанного RNN значения на основе пятнадцати предыдущих данных (синий)



**Рис. 2.** Графики реального содержания метана (красный) и предсказанного RNN значения (синий) с использованием случайной инициализации нейронов

Если сравнить данный график с предыдущим, то можно заметить, что многие из пиков не совсем точно совпадают.

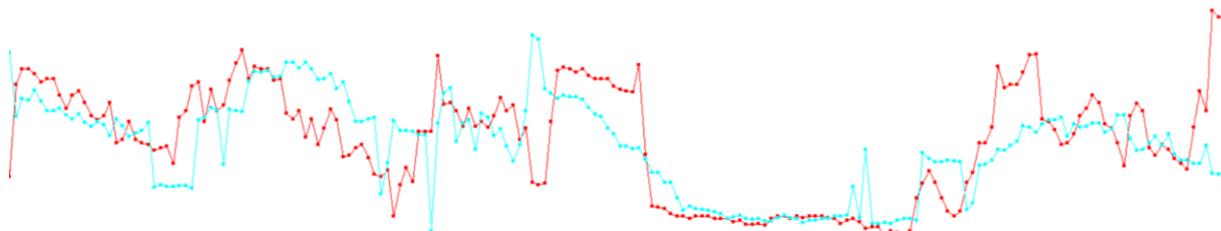
Также в качестве эксперимента для сравнения была построена глубокая нейронная сеть со стандартным слоем активации [5]. Результат представлен на рисунке 3.



**Рис. 3.** Графики реального содержания метана (красный) и предсказанного значения (синий) с использованием глубокой нейронной сети

Глубокие нейронные сети достаточно непредсказуемо себя ведут, поэтому они подходят для определённого круга задач. Как видно из графика, эксперимент привел к ухудшению точности модели.

После этого было соединено два подхода к архитектурам нейронных сетей и получена глубокая нейронная сеть с рекуррентным слоем [6, 8]. Результат представлен на рисунке 4.



**Рис. 4.** Графики реального содержания метана (красный) и предсказанного RNN значения (синий) с использованием глубокой нейронной сети

Стоит отметить, что увеличение количества слоёв улучшило обучение, но также усложнило настройку сети.

### Выводы

Лучший результат был получен с помощью глубокой нейронной сети с тремя скрытыми слоями и использованием метода «скользящих окон». Многослойный перцептрон, рекуррентная нейронная сеть и глубокая нейронная сеть дали результаты хуже, если сравнивать среднюю абсолютную ошибку [9]. Модель предсказывает значения метана со средней абсолютной ошибкой 0,0025. Поэтому для предсказания временных рядов было решено использовать именно её.

Модель была построена с помощью библиотеки Keras на языке Python в соответствии с существующим прототипом в системе Ktime [10]. Модель была выгружена в формате .h5. Таким образом, результатом является файл «methaneModel.h5», который содержит в себе всю необходимую информацию для предсказания метана. Полученная модель легко встраивается в любые информационные системы и системы управления технологическими процессами.

*Исследование выполнено в рамках Программы ФНИ, проект № 0422-2019-0007-С-01 (регистрационный номер темы НИОКТР: АААА-А19-119091690020-0).*

### БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Скрицкий В.А. Причины взрывов метана в высокопроизводительных угольных шахтах Кузбасса // Инноватика и экспертиза: научные труды. – 2017. – Вып. 2 (20). – С. 171-180.
2. Ясницкий Л.Н. Интеллектуальные информационные технологии и системы: учеб.-метод. пособие. – Пермь: Изд-во Перм. ун-та, 2007. – 270 с.
3. Осовский С. Нейронные сети для обработки информации / пер. с пол. И.Д. Рудинского. – М.: Финансы и статистика, 2002. – 343 с.
4. Журавлев Е.И. Разработка геоинформационной системы прогнозирования динамических проявлений в углевмещающем массиве при подземной разработке угольных месторождений: автореф. дис. к.т.н. 25.00.35 / Журавлев Евгений Игоревич. – М., 2016. – 22 с.
5. Николенко С., Кадури А., Архангельская Е. Глубокое обучение. Погружение в мир нейронных сетей. – СПб: Питер, 2018. – 480 с.
6. Schmidhuber J. Deep Learning in neural networks: An overview // Neural Networks. – 2015. – V. 61. – P. 85-117. DOI: [10.1016/j.neunet.2014.09.003](https://doi.org/10.1016/j.neunet.2014.09.003).

7. Садовникова Н.А., Шмойлова Р.А. Анализ временных рядов и прогнозирование: учебник для вузов. – М.: Ун-т Синергия, 2016. – 151 с.
8. Бендерская Е.Н., Никитин К.В. Рекуррентная нейронная сеть как динамическая система и подходы к ее обучению // Научно-технические ведомости Санкт-Петербургского государственного политехнического университета. Информатика. Телекоммуникации. Управление. – 2013. – № 4. – С. 29-40.
9. Рудой Г.И. Выбор функции активации при прогнозировании нейронными сетями // Машинное обучение и анализ данных. – 2011. – Т. 1, №1. – С. 16-39. – Текст электронный. – URL: <http://jmla.org/papers/doc/2011/JMLDA2011no1.pdf>. (Дата обращения 8.10.2020).
10. Джулли А., Пал С. Библиотека Keras – инструмент глубокого обучения / Под ред. Мовчан Д. А.; пер. А.А. Слинкин. – М.: ДМК Пресс, 2017. – 294 с.

УДК 622.445

DOI:10.7242/echo.2020.4.20

## ОБОСНОВАНИЕ НЕОБХОДИМОСТИ ВВЕДЕНИЯ ДОПОЛНИТЕЛЬНОГО ФАКТОРА ДЛЯ РАСЧЕТА КОЛИЧЕСТВА ВОЗДУХА, НЕОБХОДИМОГО ДЛЯ ПРОВЕТРИВАНИЯ НЕФТЯНЫХ ШАХТ

Д.Ю. Седнев, К.В. Симонова  
Горный институт УрО РАН, г. Пермь

**Аннотация:** Расчет количества воздуха для проветривания уклонных блоков нефтяных шахт должен производиться с учетом теплового фактора, позволяющего учесть тепловыделения и обеспечить соблюдение температурно-влажностного режима в буровых галереях. Тепловой фактор является определяющим фактором при расчете количества воздуха, необходимого для проветривания буровых галерей нефтяных шахт и рассчитывается на основе данных о площадях и температурах поверхностей горных выработок уклонных блоков, а также о тепловом потоке, выделяемом оборудованием. Учет теплового фактора при расчетах вентиляции необходим для поддержания микроклиматических параметров в подземных горных выработках в пределах, определяемых правилами промышленной безопасности.

**Ключевые слова:** нефтяная шахта, проветривание, уклонный блок, тепловой фактор, критерий предельного вентиляционного пути.

Нефтяные шахты Ярегского нефтетитанового месторождения (недропользователь – ООО «ЛУКОЙЛ-Коми») являются специфическими горными предприятиями, в подземных горных выработках которых ведется добыча тяжелой высоковязкой нефти. Система разработки термощахтная, сбор нефти осуществляется в уклонных блоках. Уклонный блок представляет собой систему горных выработок (уклон, ходок, буровая галерея, насосные камеры, сбойки), включающую сетку добычных и парораспределительных скважин. Длина скважин, пробуренных из буровых галерей, в настоящее время составляет около 800 м.

Для сбора нефти в буровых галереях в настоящее время используется система сбора нефтесодержащей жидкости (НСЖ) открытого типа. НСЖ из добывающих скважин самотеком или под давлением пара поступает в водоотливные канавки и по ним стекает в водонефтяной зумпф уклонного блока, откуда откачивается насосами на центральную нефтеперекачивающую станцию либо на поверхность.

Система проветривания нефтяной шахты является одной из важнейших систем жизнеобеспечения, и требует постоянного контроля и оценки факторов, которые могут напрямую или косвенно оказывать влияние на эффективность ее работы. Основной задачей проветривания является создание в рабочих зонах условий труда, пригодных для профессиональной деятельности горнорабочих, а именно: обеспечение