

See discussions, stats, and author profiles for this publication at: <https://www.researchgate.net/publication/351412086>

ПРИМЕНЕНИЕ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ПРОГНОЗИРОВАНИЯ ЭФФЕКТИВНОСТИ ВНЕДРЕНИЯ ТЕХНОЛОГИЙ БОРЬБЫ С КОНУСООБРАЗОВАНИЕМ

Article in *SOCAR Proceedings* · March 2021

DOI: 10.5510/OGP20210100487

CITATIONS

0

READS

7

3 authors, including:



Elchin Veliyev

"OilGasScientificResearchProject" Institute, SOCAR

35 PUBLICATIONS 406 CITATIONS

[SEE PROFILE](#)



Azizagha Aliyev

"OilGasScientificResearchProject" Institute, SOCAR

4 PUBLICATIONS 12 CITATIONS

[SEE PROFILE](#)

Some of the authors of this publication are also working on these related projects:



In-Situ Fluid Diversion [View project](#)



Моделирование гидродинамических процессов в пластах нефтяных месторождений на поздней стадии разработки [View project](#)



ПРИМЕНЕНИЕ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ПРОГНОЗИРОВАНИЯ ЭФФЕКТИВНОСТИ ВНЕДРЕНИЯ ТЕХНОЛОГИЙ БОРЬБЫ С КОНУСООБРАЗОВАНИЕМ

Э.Ф.Велиев*, А.А.Алиев, Т.Е.Маммедбейли

НИПИ «Нефтегаз», SOCAR, Баку, Азербайджан

Machine Learning Application to Predict the Efficiency of Water Coning Prevention Techniques Implementation

E.F.Veliyev, A.A.Aliyev, T.E.Mammadbayli

«OilGasScientificResearchProject» Institute, SOCAR, Baku, Azerbaijan

Abstract

The increase in number of the mature fields is accompanied by an increase in the water cut of the produced fluids. One of the most common causes of this phenomenon is the process of water coning, that is, the breakthrough of the bottom water to the wellbore, in which water flows form a figure similar to a cone. The paper proposes a ranking mechanism based on machine learning methods that allow to significantly reduce the resource intensity of existing prediction models. In order to preserve the simplicity of presentation, the proposed mechanism is considered on the example of one technology - DWL. Obtained results show about 10% smaller deviation values when using the least squares support vector machine in comparison with the ANN. Both developed models demonstrated acceptable results for practical application.

Keywords:

Water coning;
Artificial neural network;
Least square support vector machine;
Particle swarm optimization method;
Prediction.

© 2021 «OilGasScientificResearchProject» Institute. All rights reserved.

1. Введение

Увеличение количества месторождений находящихся на поздней стадии разработки со временем в подавляющем большинстве случаев неизбежно приводит к росту обводненности добываемой продукции. Причиной данного явления по всей видимости является тот факт, что доминирующим методом увеличения нефтедобычи на протяжении последних десятилетий остается заводнение пласта, что в сочетании с увеличенными темпами отбора нефти неизбежно ускоряет прорыв сторонних вод к стволу добывающей скважины. На сегодняшний день существуют различные методы увеличения нефтеотдачи позволяющие снизить данный негативный эффект [1-5]. Безусловно прорыв воды в скважину является процессом практически неизбежным и исследователями разработаны методы не только превентивного характера, но и направленные на борьбу с излишней обводненностью добываемой продукции [6-9].

В случае, если прорыв воды происходит посредством поднятия вод находящихся ниже водонефтяного контакта (ВНК) (т.е. подошвенных

вод), потоки воды устремляющиеся к стволу скважины образуют фигуру схожую с конусом в связи с чем, этот процесс и называют конусообразованием (рис.1). По сути, конусообразование подошвенных вод является конусообразное поднятие ВНК по отношению к стволу скважины [10-14].


Так как данное явление известно давно, то существует достаточно широкий спектр мероприятий рекомендуемых и проводимых для борьбы с ним. Ниже перечислены наиболее распространенные из них:

- Расположение зоны перфорации максимально удаленно от ВНК [15-17];
- Поддержание значений дебита ниже критических значений [18-21];
- Установка полимерного барьера на границе ВНК [22-25];
- Применение горизонтальных скважин [26-29];
- Раздельная добыча нефти и воды [30-33].

Однако у большинства предложенных методов есть существенные недостатки, что делает их не применимыми в ряде случаев. Так расположение зоны перфорации максимально удаленной от ВНК приводит к закономерному снижению длины перфорационного интервала, что в свою очередь снижает дебиты скважины ниже рентабельных зна-


*E-mail: elchinf.veliyev@socar.az

<http://dx.doi.org/10.5510/OGP20210100487>



чений. Рентабельность скважины является также главным фактором и при поддержании значений дебита ниже критических значений, к сожалению, выполнение именно этой рекомендации на практике зачастую наиболее затруднительно. Установка полимерного барьера на границе ВНК технологически сложный процесс с высоким риском падения проницаемости нефтяной зоны, а горизонтальное заканчивание скважин зачастую сильно ограничено технологией бурения. Раздельная добыча нефти и воды, хоть и является наиболее эффективным методом из вышеизложенных, но и она неразрывно связана с вопросом утилизации значительных объемов добываемой воды и существенным увеличением энергопотребления.

Сохранить преимущества раздельной добычи нефти и воды (DWS) позволяет метод создания так называемой призабойной водяной петли (DWL) [34-36]. Технология заключается в заборе и обратной закачке воды в пласт ниже уровня ВНК (рис.2).



Однако эффективность данного метода сильно зависит от расстояния между точками забора и закачки воды в пласт (D/I), которое в свою очередь ограничено размерами (толщиной) подошвенных вод. Ранжирование скважин пригодных для применения данной технологии обладающих потенциально перспективными начальными условиями (т.е. толщина продуктивного пласта, внутрипластовое давление и т.д.) проводится на дорогостоящих и трудоемких коммерческих симуляторах коллектора, что значительно усложняет процесс внедрения.

С аналогичными сложностями сопряжено прогнозирование эффективности имплементации и других технологий борьбы с конусообразованием. Возникает острая необходимость в простом и не ресурсно-затратном механизме оценки скважин по применимости внедряемых технологий, говоря математическим языком - аппаратом позволяющим достаточно эффективно решать задачу классификации. Джин с соавт. предложили весьма эффективную и простую аналитическую модель позволяющую проводить ранжирование скважин пригодных для внедрения технологии DWL [37]. Тем не менее, необходимость проведения многофакторного анализа диктует условия применения более разностороннего математического аппарата для решения данной задачи. Подходы, основанные на применении искусственного интеллекта, такие как ИНС, нечеткая логика, дерево решений (DT) и метода опорных векторов с применением метода наименьших квадратов (LSSVM), являются мощными инструментами для решения задач классификации и регрессии, которые достаточно успешно применялись ранее в ряде вычислений, связанных с нефтяной и химической инженерией [38,39].

В работе предложен механизм ранжирования, основанный на методах машинного обучения позволяющий значительно снизить ресурсоёмкость существующих методологий прогнозирования эффективности имплементации технологий борьбы с конусообразованием.

2. Математическая модель

С целью сохранения простоты изложения, применение машинного обучения для прогнозирования эффективности внедрения технологий борьбы с конусообразованием рассмотрено на примере технологии DWL, но предложенный подход может быть также использован и для других методов борьбы с конусообразованием. Базовой математической моделью, примененной при ранжировании скважин для внедрения технологии DWL, являлась модель предложенная Джин и соавт. вкратце описанная далее [37]. В основу данной модели легла модель, разработанная Сиемеком с соавт. основанная на выводе нелинейного уравнения, описывающего динамическую границу раздела нефть-вода до прорыва воды [30]. Решив данное уравнение, авторы выве-

ли критические значения дебита нефти и воды с учетом крайних (верхних и нижних) положений линии раздела ВНК.

Джин с соавтр. предложили более простой способ рассчитать значения критических дебитов нефти и воды без моделирования всей линии ВНК – с введением понятия вертикального равновесия и заданного уравнением баланса энергии вдоль вертикальной оси скважины законченной по технологии DWL [37]. Значения критических дебитов определялись по следующим уравнениям:

$$Q_H = \frac{Q_{wd} B_w h_o}{MB_o h_w} (1 - D_{di}) + \frac{0.003066 K_o h_o (\gamma_w - \gamma_o)}{B_o \mu_o \ln \frac{r_e}{r_w}} (Z_{op} - Z_{wd} + Z_{wd} D_{di}) \quad (1)$$

$$Q_B = \frac{Q_{op} B_o h_w}{B_w h_o} \frac{1}{(1 - D_{di})} + \frac{0.003066 K_w h_w (\gamma_w - \gamma_o)}{B_w \mu_w \ln \frac{r_e}{r_w}} \frac{(Z_{wd} - Z_{op} - Z_{wd} D_{di})}{(1 - D_{di})} \quad (2)$$

где (1) – уравнение критического дебита нефти

(2) – уравнение критического дебита воды

Необходимо привести краткое описание основных понятий и допущений, применённых авторами при разработке данных уравнений:

1. Q_H - критический дебит нефти, то есть максимально возможное значение дебита нефти для данного интервала D/I без прорыва воды.

2. Q_B - критический дебит воды, то есть максимально возможное значение дебита воды для данного интервала D/I, без образования нефтяного конуса (прим. так называемое обратное конусообразование, ситуация при которой нефть образует конус в водяной зоне пласта (рис.3)).

3. Z_{min} - критический интервал D/I, то есть минимальный интервал D/I, необходимый для предотвращения образования водяных конусов.

Так же авторами было сделано несколько допущений, с подробным списком которых можно ознакомиться, изучив их исследование. В данной работе приведены лишь наиболее значимые из них:




Рис.3. Механизм образования обратного конуса

- рассматривается радиальное стационарное течение, подчиняющееся закону Дарси;
- проницаемость пласта неизменна в радиальном направлении;
- отсутствует газовая шапка.

При разработке моделей, представленных в данной работе, были использованы данные приведенные в статье Джин и соавтор [37].

3. Разработка моделей

3.1. Искусственная нейронная сеть (ИНС)

ИНС - это усовершенствованная модель для обработки и классификации информации, которая имитирует биологическую нейронную сеть в человеческом мозгу и основана на математическом моделировании процессов, происходящих в мозге (рис.4).

Многослойный перцептрон (MLP) это наиболее современный и хорошо изученный тип ИНС применяемый для вычисления регрессии и классификации использующий прямой тип контролируемой и гетеро-ассоциативной связи при

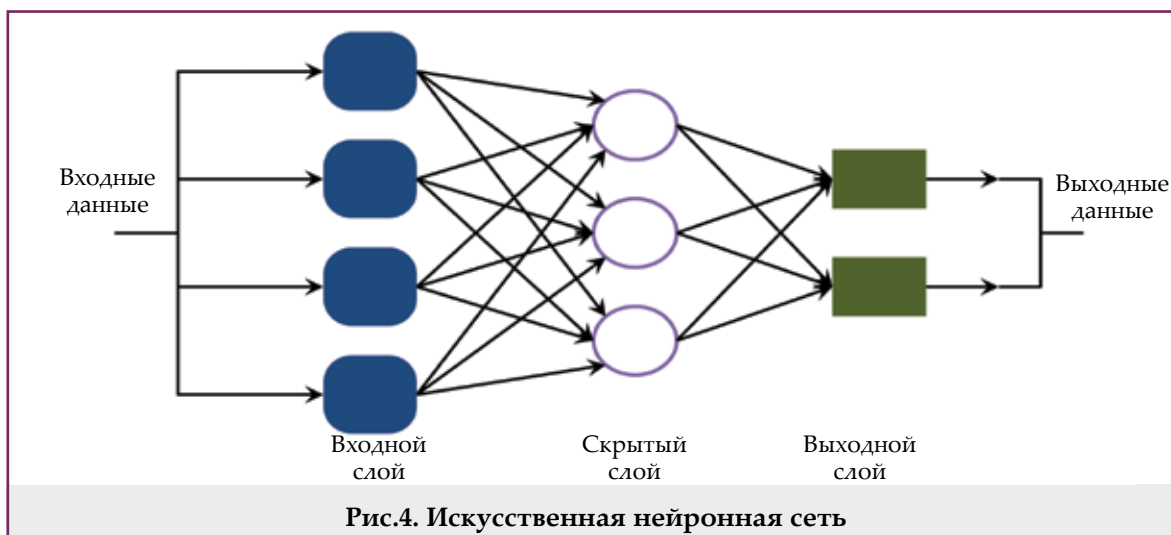
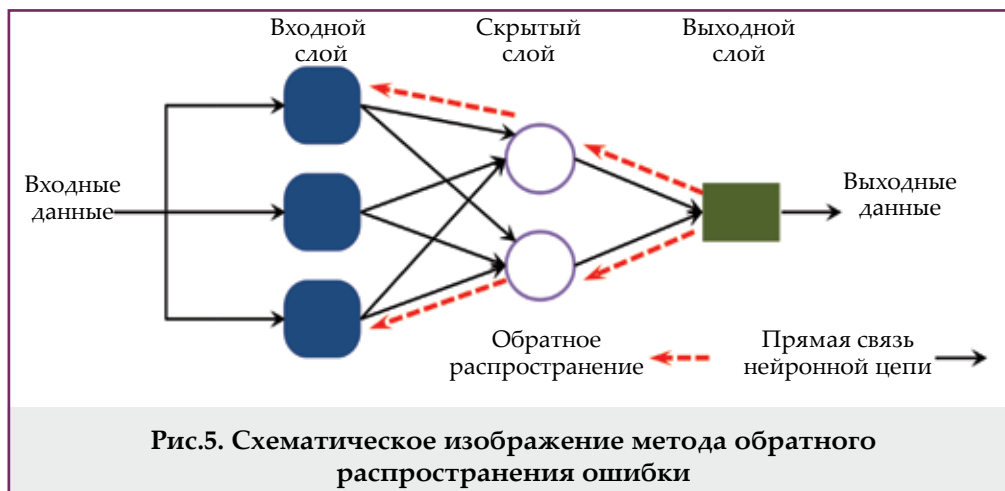


Рис.4. Искусственная нейронная сеть



построении модели нейронной сети [40]. MLP и многие другие нейронные сети используют алгоритм, называемый методом обратного распространения ошибки, по сути, являющимся итеративным градиентным алгоритмом для минимизации ошибки нейронной сети. Механизм работы данного алгоритма заключается в повторном импортировании в нейронную сеть входных данных. На каждой итерации происходит два прохода сети:

- Прямой проход – при этом формируется выходной вектор, отражающий фактическое состояние весов и вычисляется ошибка нейронной сети;
- Обратный проход – в соответствии с вычисленной при прямом проходе ошибкой, которая распространяется от выхода сети к ее входам (прим. отсюда и название метода «метод обратного распространения ошибки») и производится коррекция весов нейронов (рис.5).

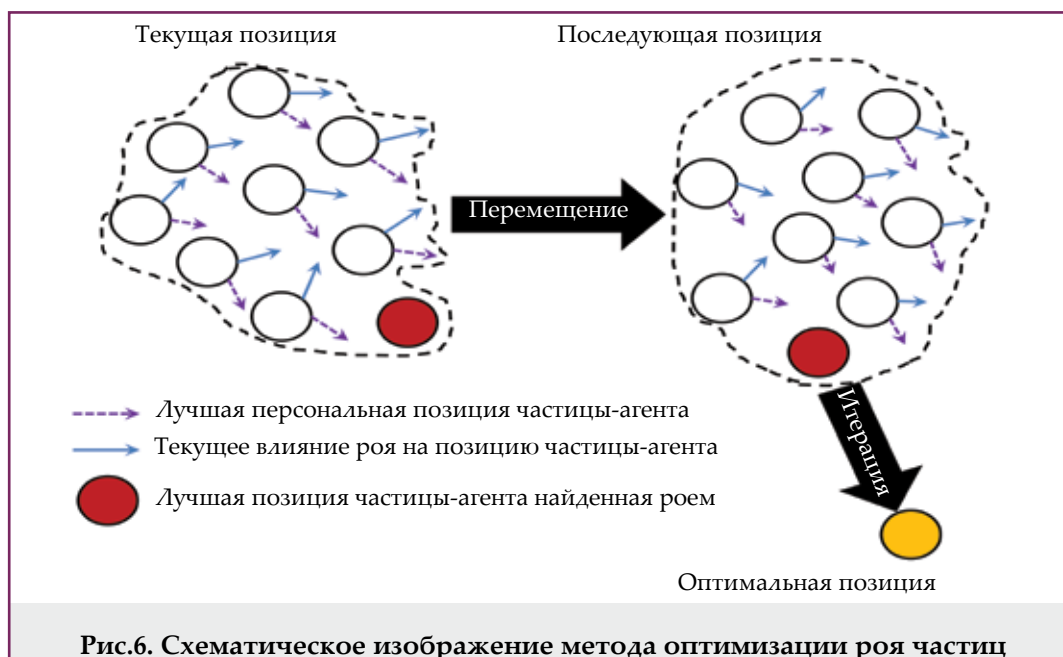
При разработке ИНС в качестве метода численной оптимизации был применен метод оптимизации роя частиц [41], позволяющий произ-

водить процесс оптимизации без знания точного градиента оптимизируемой функции (рис.6). В целом алгоритм довольно прост и заключается в моделировании многоагентной системы, состоящей из агентов-частиц которые обмениваются информацией с соседями в процессе движения к оптимальным решениям. Каждая частица-агент при этом характеризуется двумя параметрами:

- координатами в пространстве решений;
- вектором скорости перемещения.

Следует отметить, что оба параметра первоначально выбираются случайным образом и каждая частица-агент хранит координаты лучших пройденных как ею, так и всеми частицами решений (прим. обмен с соседями). На каждой итерации длина и направление вектора скорости корректируются.

В результате количество скрытых нейронов в скрытом слое оптимизируется методом проб и ошибок. В текущем примере для создания наиболее точной модели ИНС согласно значениям AARD и R^2 количество скрытых нейронов в 2 скрытых слоях составило по 10 нейронов в каждом слое.



3.2. Машина опорных векторов наименьших квадратов (LSSVM)

Машина опорных векторов (SVM), впервые предложенная Вапником, представляет собой механизм позволяющий решать задачи классификации, регрессии и распознавания образов [42] (рис.7). SVM является бинарной системой

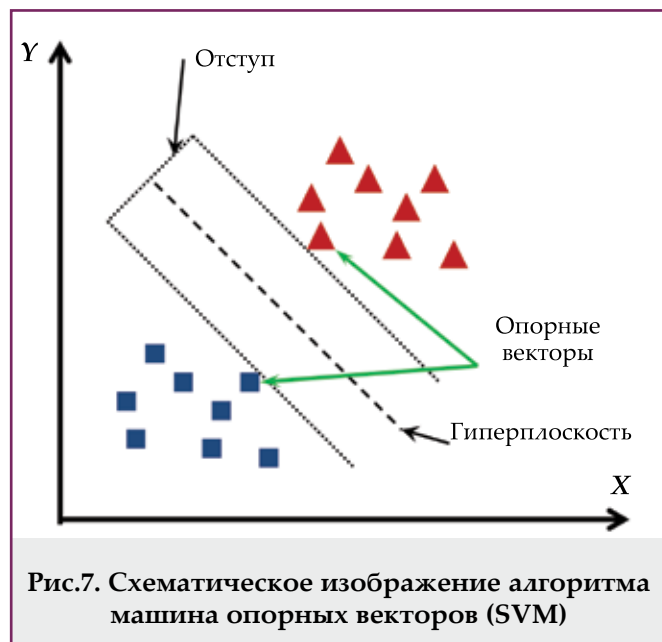


Рис.7. Схематическое изображение алгоритма машина опорных векторов (SVM)

классификации основанная на линейном разделении пространства признаков гиперплоскостью. Данный подход основан на теории статистического обучения (SLT) и концепциях минимизации структурного риска (SRM). Преимуществом применения SVM сравнении с нейронными сетями является быстрота нахождения решающих функций, сведения процесса к решению задачи квадратичного программирования в выпуклой области (т.е. всегда имеющей одно решение). По сути при применении метода опорных векторов протекает два процесса:

- преобразование входных данных к данным высокой размерности в пространстве признаков;
- классификация данных.

Однако этот подход может быть трудоемким и трудным, поскольку он влечет за собой решение набора нелинейных уравнений (квадратичная программа). Сайкенс и Вандевалл [43] предложили модель опорно-векторной машины наименьших квадратов (LSSVM) в качестве альтернативы SVM. LSSVM обладая теми же преимуществами, что и SVM, сводится к решению набора только линейных уравнений (линейное программирование) вместо задачи квадратичного программирования (QP), что является более простым процессом в вычислительном отношении и существенно упрощает процесс. Формулировка LSSVM для оценки нелинейных функций выражается следующим образом.

Дан набор данных для обучения $\{x_k, y_k\}$, $k=1,2,3,\dots,N$, где $x_k \in R^n$ это k -ные вводимые данные в

пространство входов, $y_k \in R$ это выходные данные для переменной x_k , а N - количество обучающих примеров.

Используя нелинейную функцию $\varphi(\cdot)$, которая отображает обучающий набор во входном пространстве в многомерное пространство, строится следующая регрессионная модель:

$$y = \omega^T \varphi(X) + b, \text{ где } \omega \in R^{n_s}, b \in R, \varphi(\cdot) \in R^n \rightarrow R^{n_s}$$

где ω обозначает вектор весов, b - смещение. Обратите внимание, что верхний индекс n относится к размерности пространства данных, а n_s - это (очень высокое, даже бесконечное) измерение пространства неизвестных признаков [44]. LSSVM метод решает следующую оптимизационную задачу:

$$\min_{\omega, b, e} I(\omega, e) = \frac{1}{2} \omega^T \omega + \frac{1}{2} \gamma \sum_{k=1}^N e_k^2$$

при следующих ограничениях равенства:

$$y_k = \omega^T \varphi(x_k) + b + e_k, k = 1, 2, 3, \dots, N$$

где γ - параметр регуляризации, который уравнивает сложность модели и ошибки обучения, e_k - ошибка регрессии.

Далее строится функция Лагранжа для решения задачи условной оптимизации:

$$L(\omega, b, e, \alpha) = I(\omega, e) - \sum_{k=1}^N \alpha_k \{ \omega^T \varphi(x_k) + b + e_k - y_k \}$$

где α_k - множители Лагранжа (опорные значения).

Дифференцируя данное уравнение по ω ; b ; e_k ; α_k получаем:

$$\frac{\partial L(\omega, b, e, \alpha)}{\partial \omega} = 0 \rightarrow \omega = \sum_{k=1}^N \alpha_k \varphi(x_k)$$

$$\frac{\partial L(\omega, b, e, \alpha)}{\partial b} = 0 \rightarrow \sum_{k=1}^N \alpha_k = 0$$

$$\frac{\partial L(\omega, b, e, \alpha)}{\partial e_k} = 0 \rightarrow \alpha_k = \gamma e_k, k = 1, \dots, N$$

$$\frac{\partial L(\omega, b, e, \alpha)}{\partial \alpha_k} = 0 \rightarrow y_k = \varphi(x_k) \omega^T + b + e_k, K = 1, \dots, N$$

После удаления переменных ω и e процесс сводится к решению эквивалентной дуальной задачи, где данные переменные заменяются на ядерные функции. В основе данного механизма лежит переход к произвольным ядрам от скалярных произведений, так называемый kernel trick.

$$\begin{bmatrix} 0 & 1_v^T \\ 1_v & \Omega + I/Y \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix}$$

где $y = [y_1, \dots, y_N]^T$, $1_v = [1, \dots, 1]^T$, $\alpha = [\alpha_1, \dots, \alpha_N]^T$ - регулирующий параметр (подбираемый согласно качеству прогноза на тестовой выборке); Ω - матрица, рассчитываемая по формуле:

$$\Omega_{ij} = \varphi$$

Наиболее распространенными ядрами являются:

- $K(x, x_k) = \exp(-\|x - x_k\|^2) / 2\sigma^2$ радиальная базисная функция;

- $K(x, x_k) = x_k^T x$ - линейное ядро;
- $K(x, x_k) = \tanh(\theta)$ - MLP ядро;
- $K(x, x_k) = (\tau + x_k^T x)^d$ - полиномиальное ядро степени d .

Таким образом, конечная формулировка модели LSSVM для функции прогноза имеет вид:

$$y(x) = \sum_{k=1}^N \alpha_k K(x, x_k) + b$$

где α, b являются решениями линейного уравнения.

4. Результаты и обсуждение

При прогнозировании критических значений дебита воды и нефти при применении технологии DWL как для ИНС, так и для LSSVM использовались те же входные переменные, включая коэффициент разности плотностей и безразмерную скорость. С этой целью собранная база данных случайным образом была разделена на две выборки: обучающую и тестовую. Процентное соотношение данных выборок составило 80 к 20%.

Для оценки точности рассматриваемых моделей применялось два следующих параметра: квадрат коэффициента корреляции (R^2) и среднее абсолютное относительное отклонение (AARD) рассчитываемые по следующим формулам:

$$AARD = \frac{1}{n} \sum_{i=1}^n \left| \frac{X_{exp} - X_{rep/pred}}{X_{exp}} \right| * 100$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (X_{(i)exp} - X_{(i)rep/pred})^2}{\sum_{i=1}^N (X_{(i)rep/pred} - \bar{X})^2}$$

Для разработки точной модели ИНС был использован метод оптимизации роя частиц для настройки регулируемых параметров алгоритма ИНС с прямой связью, включая смещение и вес. В результате количество скрытых нейронов в скрытом слое было оптимизировано методом проб и ошибок.

При разработке второй модели, алгоритм машины опорных векторов наименьших квадратов был объединен со стратегией оптимизации, известной как CSA, для получения оптимальных значений параметров LSSVM (γ и σ^2). В результате значения, настроенные моделью для прогнозирования критических значений дебита нефти и воды составляли $\sigma_H^2 = 1.02441$, $\sigma_B^2 = 1.001321$ и $\gamma_H = 1.3E + 10$, $\gamma_B = 1.2E + 10$ соответственно.

Рассчитанные значения AARD для рассматриваемых моделей свидетельствуют о большей точности модели основанной на LSSVM. (табл) Так значения AARD для модели LSSVM практически на 10% меньше по сравнению с ИНС, но при этом результаты, полученные с применением модели основанной на нейронной сети, также обладают достаточной для практического применения точностью.

Для сравнения характеристик разработанных моделей, полученные данные были отображены в графическом виде. Как видно из рисунков 8-13, все модели, разработанные в этом исследовании, имеют лучшие характеристики при высоких значениях прогнозируемых величин по сравнению с более низкими значениями.

Рассчитанные значения AARD				Таблица
Модель	Параметр	AARD, %	R^2	
ИНС (ANN)	Критический дебит нефти	12.99	0.7155	
	Критический дебит воды	11.32	0.8036	
ОВМНК(LSSVM)	Критический дебит нефти	1.55	0.9948	
	Критический дебит воды	1.52	0.997	




Рис.8. Прогнозируемые значения критического дебита нефти при применении модели LSSVM


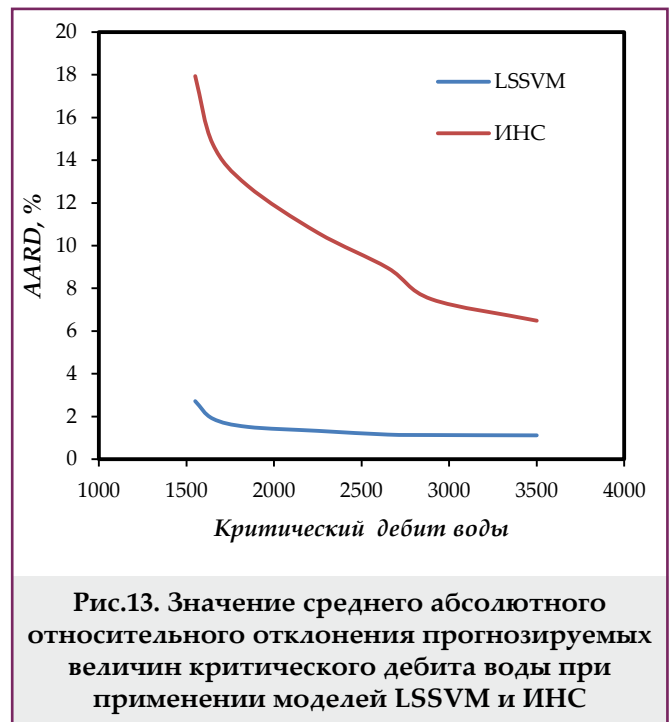





Рис.9. Прогнозируемые значения критического дебита воды при применении модели LSSVM



Выводы

- Результаты проведенных исследований показали высокую эффективность применения машинного обучения для прогнозирования эффективности применения технологии DWL в борьбе с конусообразованием;
- Анализ методов машинного обучения показал примерно на 10% меньшие значения отклонения прогнозируемых величин при применении машины опорных векторов наименьших квадратов в сравнении с ИНС;
- Обе разработанные модели продемонстрировали приемлемые для практического применения результаты.

References

1. Suleimanov, B. A., Veliyev, E. F., Dyshin, O. A. (2015). Effect of nanoparticles on the compressive strength of polymer gels used for enhanced oil recovery (EOR). *Petroleum Science and Technology*, 33(10), 1133-1140.
2. Suleimanov, B.A., Latifov, Y. A., Veliyev, E. F. (2019). Softened water application for enhanced oil recovery. *SOCAR Proceedings*, 1, 19-29.
3. Veliyev, E. F. (2020). Mechanisms of polymer retention in porous media. *SOCAR Proceedings*, 3, 126-134.
4. Suleimanov, B. A., Guseynova, N. I., Veliyev, E. F. (2017, October). Control of displacement front uniformity by fractal dimensions. SPE-187784-MS. In: *SPE Russian Petroleum Technology Conference. Society of Petroleum Engineers*.
5. Suleimanov, B. A., Veliyev, E. F., Azizagha, A. A. (2020). Colloidal dispersion nanogels for in-situ fluid diversion. *Journal of Petroleum Science and Engineering*, 193, 107411.
6. Veliyev, E. F. (2020) Review of modern in-situ fluid diversion technologies. *SOCAR Proceedings*, 2, 50-66.
7. Veliyev, E. F., Aliyev, A. A., Guliyev, V. V., Naghiyeva, N. V. (2019, October). SPE-198351-MS. Water shutoff using crosslinked polymer gels. In: *SPE Annual Caspian Technical Conference. Society of Petroleum Engineers*.
8. Suleimanov, B. A., Dyshin, O. A., Veliyev, E. F. (2016, October). Compressive strength of polymer nanogels used for enhanced oil recovery EOR. SPE-181960-MS. In: *SPE Russian Petroleum Technology Conference and Exhibition. Society of Petroleum Engineers*.
9. Suleymanov, B. A., Ismaylov, F. S., Veliyev, E. F. (2014). On the metal particles effect on the strength of polymer gels based on carboxymethyl cellulose, applying at oil recovery. *Oil Industry*, 1, 86-88.
10. Ahmed, T. (2018). Reservoir engineering handbook. Gulf professional publishing.
11. Muskat, M., Wycokoff, R. D. (1935). An approximate theory of water-coning in oil production. *Transactions of the AIME*, 114(01), 144-163.
12. Wheatley, M. J. (1985, January). An approximate theory of oil/water coning. SPE-14210-MS. In: *SPE Annual Technical Conference and Exhibition. Society of Petroleum Engineers*.
13. Meyer, H. I., Searcy, D. F. (1956). Analog study of water coning. *Journal of Petroleum Technology*, 8(04), 61-64.
14. Chierici, G. L., Ciucci, G. M., Pizzi, G. (1964). A systematic study of gas and water coning by potentiometric models. *Journal of Petroleum Technology*, 16(08), 923-929.
15. Boyun, G., Lee, R. H. (1993). A simple approach to optimization of completion interval in oil/water coning systems. *SPE Reservoir Engineering*, 8(04), 249-255.
16. Gunning, J., Paterson, L., Poliak, B. (1999). Coning in dual completed systems. *Journal of Petroleum Science and Engineering*, 23(1), 27-39.
17. Chaney, P. E., Noble, M. D., Henson, W. L., Rice, T. D. (1956). How to perforate your well to prevent water and gas coning. *Oil & Gas Journal*, 55(53), 108-114.
18. Abass, H. H., Bass, D. M. (1988, January). The critical production rate in water-coning system. SPE-17311-MS. In: *Permian Basin Oil and Gas Recovery Conference. Society of Petroleum Engineers*.
19. Schols, R. S. (1972). An empirical formula for the critical oil-production rate. *Erdoel-Erdgas*, 88, 6-11.
20. Menouar, H. K., Hakim, A. A. (1995, January). Water coning and critical rates in vertical and horizontal wells. SPE-29877-MS. In: Middle East Oil Show. Society of Petroleum Engineers.
21. Yue, P., Jia, B., Sheng, J., et al. (2019). A coupling model of water breakthrough time for a multilateral horizontal well in a bottom water-drive reservoir. *Journal of Petroleum Science and Engineering*, 177, 317-330.
22. Karp, J. C., Lowe, D. K., Marusov, N. (1962). Horizontal barriers for controlling water coning. *Journal of Petroleum Technology*, 14(07), 783-790.
23. Liang, J. T., Lee, R. L., Seright, R. S. (1993). Gel placement in production wells. *SPE Production & Facilities*, 8(04), 276-284.
24. Siddiqi, S. S., Wojtanowicz, A. K. (2002, January). A study of water coning control in oil wells by injected or natural flow barriers using scaled physical model and numerical simulator. SPE-77415-MS. In: SPE Annual Technical Conference and Exhibition. *Society of Petroleum Engineers*.
25. Zhang, P., Wen, X. H., Ge, L., et al. (2008, January). Existence of flow barriers improves horizontal well production in bottom water reservoirs. SPE-115348-MS. In: SPE annual technical conference and exhibition. *Society of Petroleum Engineers*.

26. Chaperon, I. (1986, January). Theoretical study of coning toward horizontal and vertical wells in anisotropic formations: subcritical and critical rates. SPE-15377-MS. In: *SPE annual technical conference and exhibition. Society of Petroleum Engineers.*
27. Yue, P., Jia, B., Sheng, J., Lei, T., Tang, C. (2019). A coupling model of water breakthrough time for a multilateral horizontal well in a bottom water-drive reservoir. *Journal of Petroleum Science and Engineering*, 177, 317-330.
28. Okon, A. N., Appah, D. (2018). Water coning prediction: an evaluation of horizontal well correlations. *Engineering and Applied Sciences*, 3(1), 21-28.
29. Oloro, J. O., Adewole, S. E. (2020). Performance and behavior of a horizontal well in reservoir subject to double-edged water drive. *Nigerian Journal of Technology*, 39(2), 417-423.
30. Siemek, J., Stopa, J. (2002). A simplified semi-analytical model for water-coning control in oil wells with dual completions system. *Journal of Energy Resources Technology*, 124(4), 246-252.
31. Ould-Amer, Y., Chikh, S., Naji, H. (2004). Attenuation of water coning using dual completion technology. *Journal of Petroleum Science and Engineering*, 45(1-2), 109-122.
32. Alblooshi, Y. A., Wojtanowicz, A. K. (2018, May). Dynamic water control in naturally fractured bottom water-drive reservoirs via downhole water sink well deployment: first experimental study. SEG-2018-35. In: *Research and Development Petroleum Conference and Exhibition 2018 (Vol. 2018, No. 1, pp. 128-131). European Association of Geoscientists & Engineers.*
33. Pratama, I. S., Adiwena, M. D. (2018). Integrated study of down-hole water sink technology to water coning development in thin layers.
34. Jin, L., Wojtanowicz, A. K. (2010). Performance analysis of wells with downhole water loop installation for water coning control. *Journal of Canadian petroleum technology*, 49(06), 38-45.
35. Jin, L., Wojtanowicz, A. K. (2011, January). Minimum produced water from oil wells with water-coning control and water-loop installations. SPE-143715-MS. In: *SPE Americas E&P Health, Safety, Security, and Environmental Conference. Society of Petroleum Engineers.*
36. Wojtanowicz, A. K., Xu, H. (1995). Downhole water loop-a new completion method to minimize oil well production watercut in bottom-water-drive reservoirs. *Journal of Canadian Petroleum Technology*, 34(08).
37. Jin, L., Wojtanowicz, A. K., Hughes, R. G. (2009, January). An analytical model for water coning control installation in reservoir with bottom water. PETSOC-2009-098. In: *Canadian International Petroleum Conference. Petroleum Society of Canada.*
38. Suleimanov, B. A., Ismailov, F. S., Dyshin, O. A., Veliyev, E. F. (2016, October). Screening evaluation of EOR methods based on fuzzy logic and Bayesian inference mechanisms. SPE-182044-MS. In: *SPE Russian Petroleum Technology Conference and Exhibition. Society of Petroleum Engineers.*
39. Suleimanov, B. A., Ismayilov, F. S., Dyshin, O. A., Veliyev, E. F. (2016). Selection methodology for screening evaluation of EOR methods. *Petroleum Science and Technology*, 34(10), 961-970.
40. Rafiq, M. Y., Bugmann, G., Easterbrook, D. J. (2001). Neural network design for engineering applications. *Computers & Structures*, 79(17), 1541-1552.
41. Kennedy, J., Eberhart, R. (1995, November). Particle swarm optimization. In: *Proceedings of ICNN'95 - International Conference on Neural Networks.*
42. Vapnik, V., Vapnik, V. (1998). *Statistical learning theory.* New York: Wiley-IEEE Press.
43. Suykens, J. A., Vandewalle, J. (1999). Least squares support vector machine classifiers. *Neural Processing Letters*, 9(3), 293-300.
44. Vong, C. M., Wong, P. K., Li, Y. P. (2006). Prediction of automotive engine power and torque using least squares support vector machines and Bayesian inference. *Engineering Applications of Artificial Intelligence*, 19(3), 277-287.

Применение машинного обучения для прогнозирования эффективности внедрения технологий борьбы с конусообразованием

Э.Ф.Велиев, А.А.Алиев, Т.Е.Маммедбейли
НИПИ «Нефтегаз», SOCAR, Баку, Азербайджан

Реферат

Неуклонный рост фонда месторождений находящихся на поздней стадии разработки сопровождается увеличением обводненности добываемой продукции. Одной из наиболее распространённых причин данного явления является процесс конусообразования, то есть прорыва подошвенных вод к стволу скважины, при котором потоки воды образуют фигуру схожую с конусом. В работе предложен механизм ранжирования, основанный на методах машинного обучения позволяющий значительно снизить ресурсоёмкость существующих моделей для прогнозирования эффективности внедрения технологий борьбы с конусообразованием. С целью сохранения простоты изложения, предложенный механизм рассмотрен на примере одной технологии - DWL. Анализ методов машинного обучения показал примерно на 10% меньшие значения отклонения прогнозируемых величин при применении машины опорных векторов наименьших квадратов в сравнении с ИНС. Обе разработанные модели продемонстрировали приемлемые для практического применения результаты.

Ключевые слова: конусообразование; искусственная нейронная сеть; машина опорных векторов наименьших квадратов; метод оптимизации роя частиц; прогнозирование.

Konus əmələgəlmə ilə mübarizə texnikalarının tətbiqinin effektivliyinin proqnozlaşdırılması üçün maşın öyrənmənin istifadəsi

E.F.Vəliyev, Ə.A.Əliyev, T.E.Məmmədbəyli
«Neftqazəlmətdəqiqatlayihə» İnstitutu, SOCAR, Bakı, Azərbaycan

Xülasə

İşlənmənin son mərhələsində olan yataqların sayının artması əksər hallarda quyuların sulaşması ilə müşayiət olunur. Bu fenomenin ən çox yayılmış səbəblərindən biri konus əmələgəlmə prosesidir, yəni daban sularının quyudibinə doğru konus formasında hərəkətidir. Məqalədə mövcud proqnozlaşdırma modellərinin resurs sərfinin əhəmiyyətli dərəcədə azaldılması məqsədilə maşın öyrənmə (machine learning) üsullarına əsaslanan qiymətləndirmə mexanizmi təqdim olunmuşdur. Təklif olunan mexanizmin təqdimatını sadələşdirmək məqsədilə yalnız DWL texnologiyası tədqiq olunmuşdur. Əldə olunan nəticələr göstərir ki, ən kiçik kvadratlar dəstəkli vektor maşının (LSSVM) tətbiqi Süni Neyron Şəbəkəsinin tətbiqindən daha dəqiqdir, belə ki, LSSVM istifadəsi ilə alınan nəticələr 10% daha az kənarlaşmaya malik olur. Hər iki tədqiq olunmuş modelin nəticələri praktiki tətbiq üçün qənaətbəxşdir.

Açar sözlər: konus əmələ gəlmə; süni neyron şəbəkəsi; ən kiçik kvadratlar dəstəkli vektor maşını; hissəcik yığını optimallaşdırma metodu; proqnozlaşdırma.