

ПРИМЕНЕНИЕ НЕЙРОННОЙ СЕТИ В СИСТЕМЕ УПРАВЛЕНИЯ ДЛЯ ОПТИМИЗАЦИИ ПРОИЗВОДИТЕЛЬНОСТИ ГРУППЫ ШТАНГОВЫХ ГЛУБИННЫХ НАСОСОВ С МЕХАТРОННЫМ ПРИВОДОМ С НЕОДИНАКОВЫМИ ЦИКЛАМИ ПРИ ОГРАНИЧЕННОЙ ПИКОВОЙ ПОТРЕБЛЯЕМОЙ МОЩНОСТИ¹

THE NEURAL NETWORK APPLICATION
IN A CONTROL SYSTEM FOR
PERFORMANCE OPTIMIZATION
OF A GROUP OF ROD DEPTH PUMPS
WITH A MECHATRONIC DRIVE WITH
UNEQUAL CYCLES WITH LIMITED PEAK
POWER CONSUMPTION

**M. Larin
A. Volkov**

Summary. For the development of low- and medium-rate wells, the most commonly used installations are sucker-rod pumps. The group of sucker-rod pumps connected to the same power supply system is installed on the wells of one oilfield. There is a mathematical relation between the maximum power consumption of a group of cycle drives and the performance of this group. In this paper, a strategy for managing a group of sucker-rod pumps with a mechatronic drive has been developed, focused on reducing peak power consumption while maintaining the productivity of the entire group and based on the use of a neural network.

Keywords: Simulation modeling, control system, sucker-rod pumps, oil production, mechatronic drive, energy efficiency, peak power, optimization, adaptation, neural networks.

Ларин Михаил Юрьевич

Ассистент, Санкт-Петербургский
политехнический университет Петра Великого
Lay9991@mail.ru

Волков Андрей Николаевич

Доцент, доктор технических наук, профессор,
Санкт-Петербургский политехнический университет
Петра Великого
Volkov-and-1@yandex.ru

Аннотация. Для разработки скважин с низким и средним дебитом наиболее часто используемыми установками являются штанговые глубинные насосы (ШГН). Группа ШГН, подключенных к одной системе электроснабжения, устанавливается на одном нефтяном месторождении. Существует взаимосвязь между максимальной потребляемой мощностью группы приводов и производительностью этой группы. В данной работе разработана стратегия управления группой ШГН с мехатронным приводом, ориентированная на снижение пиковой потребляемой мощности при сохранении производительности всей группы, основанная на использовании нейронной сети.

Ключевые слова: имитационное моделирование, система управления, штанговые глубинные насосы, нефтедобыча, мехатронный привод, энергоэффективность, пиковая мощность, оптимизация, адаптация, нейронные сети.

¹ Исследование выполнено при финансовой поддержке РФФИ в рамках научного проекта № 20–38–90130.

Введение

На сегодняшний день нефтепродукты продолжают играть ключевую роль в топливной, энергетической, химической отраслях промышленности и мировой экономике в целом. Несмотря на исчерпаемость данного ресурса и общемировую тенденцию к переходу на более экологические чистые источники энергии, до пандемии Covid-19 и потребление, и предложение нефти на общемировом рынке стабильно росло [1]. Хотя Российская Федерация и является одним из лидеров как по добыче, так и по разведанным запасам нефти, большая её часть залегает в труднодоступных и слабозаселённых регионах с неразвитой инфраструктурой. Этот факт способствует повышению себестоимости добычи, что вкупе с прочими внешними ограничениями создаёт повышенный спрос на оптимизацию использования доступных мощностей.

В настоящее время абсолютное большинство нефтяных скважин в мире эксплуатируется механизированным, а не фонтанным способом [2]. Среди различных видов механизированной добычи, каждый из которых имеет свою область применения в зависимости от параметров конкретной скважины, немалую роль играет установка штанговых глубинных насосов. Ввиду отсутствия балансира, такой тип ШГН имеет высокие пиковые значения потребляемой мощности.

Работу каждой из установок ШГН можно рассматривать, как работу циклового привода с повторяющимися нагрузками [3]. При нескоординированной работе группы ШГН пиковые значения потребляемой мощности ШГН могут накладываться друг на друга, что приводит к высоким требованиям к системе питания по номинальной мощности [4]. При этом, обеспечение группы технологического оборудования энергией в условиях удаленности от населенных пунктов и энергомагистралей — сложный ресурсоемкий вопрос [5].

Вышеперечисленные факты делают проблему понижения максимальной потребляемой мощности группы ШГН актуальной.

1. Общие положения для синтеза стратегии управления на основе нейронной сети

Для разработки стратегии управления используются математическая модель, имитационная модель и условные обозначения из работы [6]. В данной работе также показано, что в зависимости от способа определения показателей приоритетности Q_i для ШГН в группе система ШГН с неодинаковыми циклами имеет

различную эффективность при одной и той же доступной мощности N_{fact} . И в общем случае, ни один из представленных способов определения приоритетности не является гарантированно оптимальным, а также не учитывает всех параметров ШГН. Соответственно, необходимо решить две задачи:

1) получить наиболее важные критерии

$$\eta_i = (v_i, T_i, N_{i\,avg}, N_{i\,max}, \dots)$$

для определения приоритетности Q_i в общем виде;

2) синтезировать оптимальную функцию $f(\eta_i)$ для определения показателя приоритетности $Q_i = f(\eta_i)$. Функцию должно быть легко масштабировать под различное количество критериев η_i .

Требования к критериям, с учетом того, что изначально неизвестно, какие параметры приводов — и как именно — влияют на производительность:

1) значения критериев различны для приводов в системе;

2) значения критериев характеризуют закон потребления в общем виде;

3) значения критериев линейно независимы друг от друга.

В соответствии с данными требованиями, можно выделить следующие критерии

$$\eta_i = (T_i, N_{i\,max}, N_{i\,avg}, s_{iN}, E_{i\,rec}, E_{i\,work}, v_i):$$

1) T_i — время цикла привода i ;

2) $N_{i\,max}$ — пиковая максимальная потребляемая мощность в цикле;

3) $N_{i\,avg}$ — средняя потребляемая мощность в цикле;

$$4) s_{iN}^2 = \frac{\sum_{j=0}^{ceil(\frac{T_i}{\Delta t})} (N_i(\Delta t \cdot j) - N_{i\,avg})^2}{ceil(\frac{T_i}{\Delta t}) - 1}$$

дисперсия потребляемой мощности;

5) $E_{i\,rec} = \int_0^{T_i} -N_i(t) \cdot h(-N_i(t)) dt$ — энергия, рекуперируемая во время цикла;

6) $E_{i\,work} = \int_0^{T_i} N_i(t) \cdot h(N_i(t)) dt$ — энергия, затрачиваемая на работу во время цикла;

7) v_i — производимый продукт для каждого привода, имеет очевидное влияние на итоговую производительность системы.

Синтез оптимальной функции определения показателя приоритетности привода $f(\eta_i)$ при неизвестном влиянии критериев эффективности каждого привода η_i на итоговую эффективность системы в явном виде невозможен. Однако, возможно задать функцию, учитывающую весь вектор критериев, способную к адаптации с последующей оптимизацией влияния каждого критерия на показатель приоритетности — и, соответственно, на итоговую эффективность всей системы. В качестве такой функции использована нейронная сеть (далее — НС).

2. Применение двухслойной нейронной сети для адаптивной стратегии управления группой ШГН с неодинаковыми циклами

Характеристики нейронной сети:

1) сеть имеет 2 слоя;

2) первый слой состоит из l_1 нейронов с нелинейной функцией активации

$$a(x) = \frac{1}{1+e^{-x}}$$

для добавления нелинейности в систему. При этом, $l_1 = 4$ выбрано исходя из неравенства $1 \leq l_1 \leq l_0$, где $l_0 = 7$ — количество входных критериев;

3) выходной слой имеет один линейный нейрон — $l_2 = 1$, так как выход сети — скаляр, используемый как показатель приоритетности Q_i ;

4) каждый слой нейронов имеет перед собой узел смещения $b = 1$;

5) на вход НС подаются значения критериев эффективности привода η_i . Значения критериев η_i нормированы при помощи Z-нормализации [7] для лучшей сходимости обучающего алгоритма.

6) функция определения показателя приоритетности привода $f(\eta_i)$, задаваемая с помощью НС:

$$\left\{ \begin{array}{l} f(\eta_i, \mathbf{W}) = \left(1, \frac{1}{1 + e^{-(1, \eta_i) \cdot \mathbf{W}_1^T}} \right) \cdot \mathbf{W}_2^T \\ \mathbf{W} = \{ \mathbf{W}_1, \mathbf{W}_2 \} \\ \mathbf{W}_1 = \begin{pmatrix} w_{1,0,1} & \dots & w_{1,l_0,1} \\ \vdots & \ddots & \vdots \\ w_{i_1,0,1} & \dots & w_{i_1,l_0,1} \end{pmatrix} \\ \mathbf{W}_2 = (w_{1,0,2} \quad \dots \quad w_{1,l_1,2}) \end{array} \right.$$

7) функция стоимости отражает разницу между результатом работы системы при ограниченной мощно-

сти и результатом работы системы при полной мощности и имеет следующий вид:

$$J(\mathbf{W}) = \frac{(V_{max}(T) - V(T, \mathbf{W}))}{n} + \frac{\lambda}{2n} \sum_{k=1}^2 \sum_{j=1}^{l_{k-1}} \sum_{i=1}^{l_k} W_{i,j,k}^2$$

где $\frac{\lambda}{2n} \sum_{k=1}^2 \sum_{j=1}^{l_{k-1}} \sum_{i=1}^{l_k} W_{i,j,k}^2$ —

регуляризация; λ — коэффициент регуляризации; i, j, k — номер нейрона в слое, номер входного сигнала на нейрон и номер слоя соответственно; w — синаптические веса нейронов сети; l_{k-1} — количество нейронов или входных узлов — без учета узла смещения — со слоя $k - 1$ на нейрон слоя k . Синаптические веса $w_{0,j,k}$ нейронов, находящиеся после узлов смещения b — в регуляризации не участвуют;

8) обучение системы происходит по алгоритму градиентного спуска со следующими модификациями:

8.1) W_0 инициализируются малыми случайными значениями;

8.2) задаются значения параметров обучающего алгоритма:

- ◆ скорость спуска $\alpha = 100$;
- ◆ коэффициент регуляризации $\lambda = 0.01$;
- ◆ максимальное количество итераций обучения $I_{max} = 100$;
- ◆ номер текущей итерации обучения $I_{curr} = 1$;
- ◆ коэффициент уменьшения шага обучения $k_\alpha = 0.8$;
- ◆ смещения синаптических весов $\Delta \mathbf{W} = 0$;

8.3) проводится имитационное моделирование системы при $N_{fact} = N_{max}$ — вычисляется максимальное продукта $V_{max}(T)$;

8.4) устанавливается значение доступной мощности для дальнейшего моделирования системы $N_{fact} \in [0, N_{max}]$;

8.5) устанавливаются новые значения $\mathbf{W}_{i_{curr}} = \mathbf{W}_{i_{curr-1}} + \alpha \cdot \Delta \mathbf{W}$;

8.6) для каждого привода i в группе вычисляется Q_i :

$$Q_i = f(\eta_i, \mathbf{W}) = \left(1, \frac{1}{1 + e^{-(1, \eta_i) \cdot \mathbf{W}_1^T}} \right) \cdot \mathbf{W}_2^T$$

8.7) приоритеты приводов p определяются в зависимости от Q — чем выше значение Q_i привода i , тем выше приоритет p_i привода i ;

8.8) проводится имитационное моделирование системы для вычисления $V(T, \mathbf{W})$ при N_{fact} и $\mathbf{W}_{i_{curr}}$ вы-

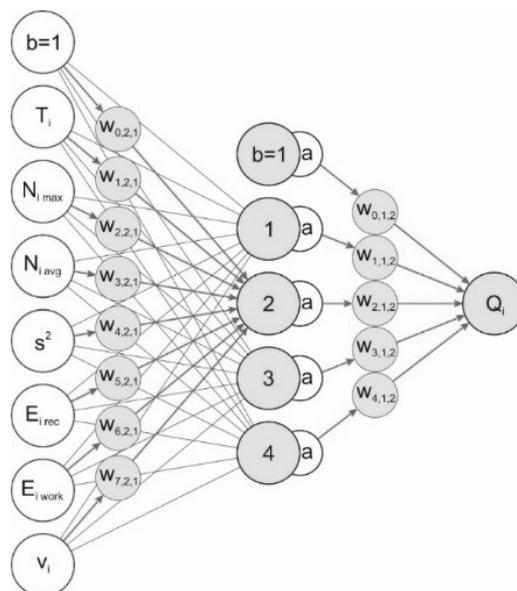


Рис. 1. Схема применяемой НС. Синаптические веса первого слоя показаны только для нейрона 2

числяется функция стоимости $J_{I_{curr}}(\mathbf{W}_{I_{curr}})$ на текущей итерации обучения I_{curr} ;

8.9) проверка на ошибку алгоритма обучения. Псевдокод проверки:

```

IF ( $I_{curr} > 1$ ) THEN
  IF ( $J_{I_{curr}}(\mathbf{W}_{I_{curr}}) > J_{min}$ ) THEN
     $\mathbf{W}_{I_{curr}} := \mathbf{W}_{J_{min}}$ ;  $\alpha := \alpha \cdot k_{\alpha}$ ; GOTO 8.5)
  ELSE IF ( $\frac{\alpha}{k_{\alpha}} \leq \alpha_{max}$ ) THEN  $\alpha := \alpha / k_{\alpha}$  ENDIF
   $J_{min} := J_{I_{curr}}(\mathbf{W}_{I_{curr}})$ ;  $\mathbf{W}_{J_{min}} := \mathbf{W}_{I_{curr}}$ 
ENDIF
ELSE  $J_{min} := J_{I_{curr}}(\mathbf{W}_{I_{curr}})$ ;  $\mathbf{W}_{J_{min}} := \mathbf{W}_{I_{curr}}$  ENDIF
    
```

8.10) вычисляются смещения синаптических весов $\Delta \mathbf{W}$. Используется метод обратного распространения ошибки;

8.11) если не достигнуто максимальное количество итераций обучения $I_{curr} < I_{max}$, то $I_{curr} := I_{curr} + 1$, затем переход к п. 8.5). В противном случае — заканчиваем обучение.

Схема используемой нейронной сети представлена на Рисунок 1. Для обучения двухслойной НС необходимо использовать метод обратного распространения ошибки (далее — метод ОРО) [8, с. 140].

В общем случае, метод ОРО для градиентного спуска выглядит следующим образом:

$$w_{i(k),j(k),k}(I_{curr}) = w_{i(k),j(k),k}(I_{curr} - 1) + \alpha \cdot \delta_{i(k),k} \cdot a_{j(k),k-1}$$

1) выходной слой: $\delta_{i(k),k} = -\frac{\partial J(y_{i(k),k})}{\partial y_{i(k),k}}$;

2) скрытые слои:

$$\delta_{i(k),k} = \sum_{i(k+1)} (w_{i(k+1),i(k),k+1} \cdot \delta_{i(k+1),k+1}) \cdot \frac{\partial a_k(y_{i(k),k})}{\partial y_{i(k),k}}$$

Функция стоимости J — в частности, значение $V(T, \mathbf{W})$, которое и нужно максимизировать при ограниченной мощности N_{fact} — связана с \mathbf{W} через выход имитационной модели. Частные производные этой зависимости не могут быть взяты теоретически. Следовательно, метод ОРО необходимо модифицировать.

Основное правило обучения для выходного слоя применительно к использованной НС:

$$w_{1,j(2),2}(I_{curr}) = w_{1,j(2),2}(I_{curr} - 1) - \alpha \cdot \frac{\partial J(w_{1,j(2),2})}{\partial w_{1,j(2),2}}$$

В методе ОРО это правило имеет следующую форму:

$$w_{1,j(2),2}(I_{curr}) = w_{1,j(2),2}(I_{curr} - 1) + \alpha \cdot \delta_{1,2} \cdot a_{j(2),1},$$

где $\delta_{1,2} = \frac{\partial J(v_{(2)})}{\partial y_2}$.

Видно, что $\delta_{1,2} \cdot a_{j(2),1} = -\frac{\partial J(w_{1,j(2),2})}{\partial w_{1,j(2),2}}$.

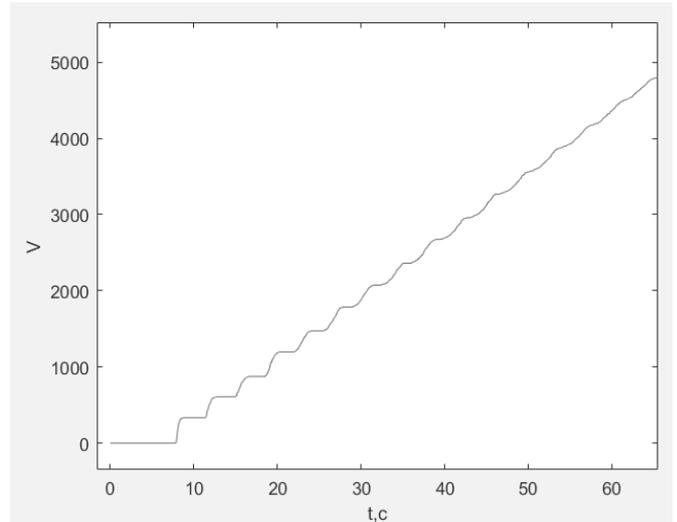
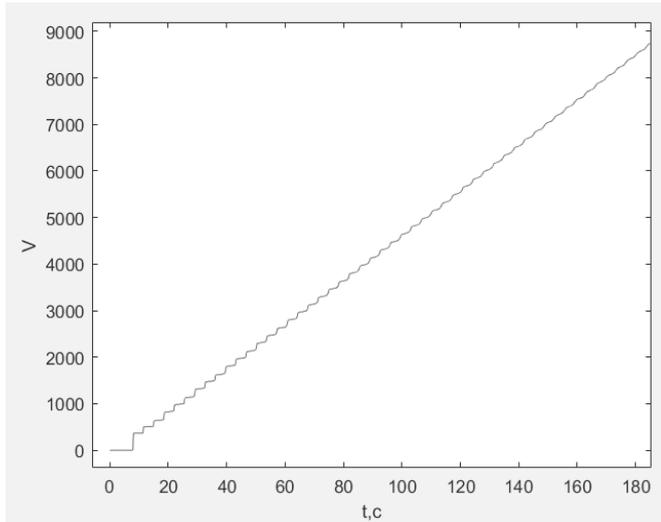


Рис. 2. Зависимость $V(t)$ с рекуперацией при $N_r = 0.1$ (слева) и без рекуперации при $N_r = 0.2$ (справа)

Введена дополнительная индексация $j(2)$ для $\delta_{1,2}$, чтобы сохранить соответствие доли распределенной поправки входному сигналу на нейрон:

$$\delta_{1,j(2),2} = -\frac{1}{a_{j(2),1}} \cdot \frac{\partial J(w_{1,j(2),2})}{\partial w_{1,j(2),2}}$$

Тогда для нейронов предпоследнего скрытого слоя:

$$\delta_{i(1),1} = (w_{1,i(1),2} \cdot \delta_{1,i(1),2}) \cdot \frac{\partial a_1(y_{i(1),1})}{\partial y_{i(1),1}}$$

С помощью имитационной модели возможно вычислить значения

$$a_{j(2),1} \text{ и } \frac{\partial J(w_{1,j(2),2})}{\partial w_{1,j(2),2}}$$

Значения $a_{j(2),1}$ становятся известны при прямом расчете сигналов НС. Для вычисления

$$\frac{\partial J(w_{1,j(2),2})}{\partial w_{1,j(2),2}} \text{ учетом дискретности вычислений:}$$

$$\frac{\partial J(w_{1,j(2),2})}{\partial w_{1,j(2),2}} \approx \frac{\Delta J(w_{1,j(2),2})}{\Delta w_{1,j(2),2}}$$

Примем $\Delta w_{1,j(2),2} = 2h$, где h — малый шаг дискретизации $w_{1,j(2),2}$. Зависимость $J(W_2)$ имеет определенное квантование — только изменения W_2 , которые меняют порядок приоритетов для приводов, приводят к изменению значения $J(W_2)$. Поэтому в $J(w_{1,j(2),2})$ присутствуют плато различной ширины по $w_{1,j(2),2}$. Это приводит к следующим проблемам:

1) если Δw выбран меньше, чем ширина плато, то

$$\frac{\partial J(w_{1,j(2),2})}{\partial w_{1,j(2),2}} = 0$$

и обучение остановится на данном значении $w_{1,j(2),2}$;

2) чем больше Δw , тем сильнее разница между

$$\frac{\partial J(w_{1,j(2),2})}{\partial w_{1,j(2),2}} \text{ и } \frac{\Delta J(w_{1,j(2),2})}{\Delta w_{1,j(2),2}}$$

Для решения первой проблемы и уменьшения влияния второй применяется адаптивная длина шага по $w_{1,j(2),2}$, отдельно в положительную и в отрицательную стороны:

$$w_{1,j(2),2 p} = w_{1,j(2),2} + \Delta w_{1,j(2),2 p}$$

$$w_{1,j(2),2 n} = w_{1,j(2),2} - \Delta w_{1,j(2),2 n}$$

$$\begin{aligned} \Delta w_{1,j(2),2} &= w_{1,j(2),2 p} - w_{1,j(2),2 n} = \\ &= \Delta w_{1,j(2),2 p} + \Delta w_{1,j(2),2 n} \end{aligned}$$

Основная идея заключается в том, чтобы изменять $\Delta w_{1,j(2),2 p}$ от $\Delta w_{1,j(2),2 p min}$ до $\Delta w_{1,j(2),2 p max}$ с малым шагом h_w , пока порядок приоритетов не изменится по сравнению с порядком приоритетов при $w_{1,j(2),2}$. Аналогично для $\Delta w_{1,j(2),2 n}$.

Каждое определение значения производной

$$\frac{\partial J(w_{1,j(2),2})}{\partial w_{1,j(2),2}}$$

требует проведения имитационного моделирования дважды. Имитационное моделирование — ресурсоемкий процесс, поэтому возникает задача его оптимизации для повышения скорости обучения НС. Есть

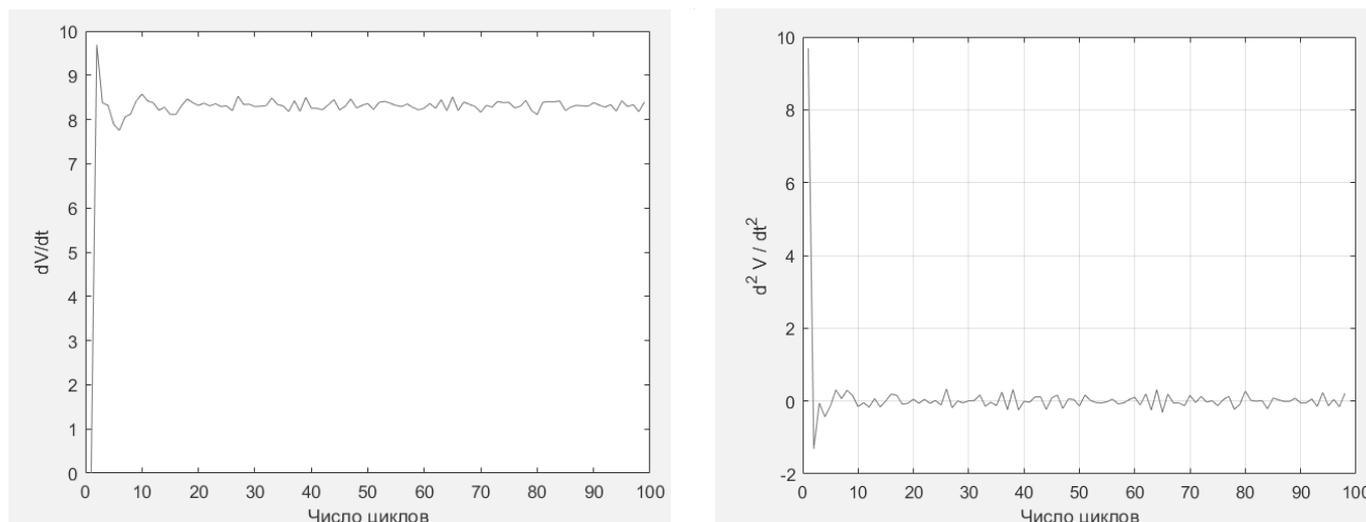


Рис. 3. Зависимости $\frac{\partial V(t)}{\partial t}$ и $\frac{\partial^2 V(t)}{\partial t^2}$

для группы 100 ШГН без рекуперации при $N_r = 0.2$ и ширине фильтра скользящего среднего $3T_{avg}$

три очевидных способа повышения скорости расчетов имитационной модели:

1. увеличение временного шага вычислений имитационной модели;
2. уменьшение модельного времени;
3. использование параллельных вычислений, где это возможно.

Для рассматриваемой модели способ 1 не приемлем, так как моделирование узких пиков законов потребления приводов требует большой временной дельтализации.

Применение способа 2 является оптимальным. В модели, принятой за основу, модельное время

$$T = \frac{\sum_{i=1}^n T_i}{n} \cdot 100.$$

Оно взято таким, чтобы начальный переходный процесс не влиял на результат моделирования. Модельное время можно уменьшить без потери точности результата, если исключить переходный процесс из результата моделирования.

Графики зависимости объема произведённого продукта от времени работы системы для группы из 100 ШГН представлены на рисунке 2.

Со временем функция производительности приближается к линейной зависимости, что соответствует установившемуся режиму работы системы. В начальный момент времени наблюдаются значительные ко-

лебания, а также отсутствие произведённого продукта до завершения первого цикла.

Чтобы определить примерную длительность переходного процесса найдём производительность системы. Для этого объём произведённого продукта за несколько средних рабочих циклов

$$T_{avg} = \frac{\sum_{i=1}^n T_i}{n}$$

необходимо усреднить по времени с помощью фильтра скользящего среднего [9], чтобы найти величину мгновенной производительности группы ШГН

$$\frac{\partial V(t)}{\partial t}. \text{ Далее необходимо найти } \frac{\partial^2 V(t)}{\partial t^2}$$

и определить момент, когда она

$$\frac{\partial^2 V(t)}{\partial t^2} \approx 0$$

этот момент принят за окончание переходного процесса (рисунок 3).

По результатам моделирования видно, что $\frac{\partial^2 V(t)}{\partial t^2} \approx 0$

при $t \geq 10 \cdot T_{avg}$ работы ШГН. Отметим, что данный результат меняется незначительно при усреднении производительности по 2, 3, 5 и большему числу циклов.

Применение данного способа в имитационной модели следующее:

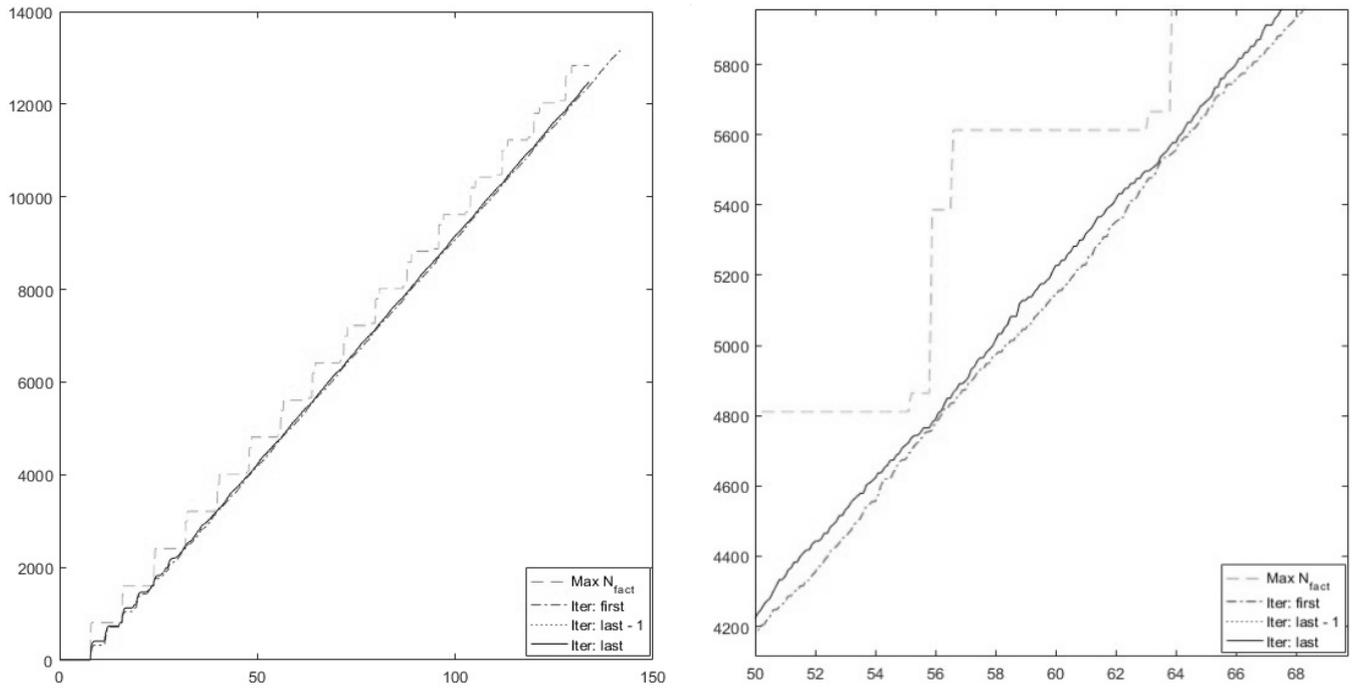


Рис. 4. Графики $V(t)$, справа — в увеличенном масштабе

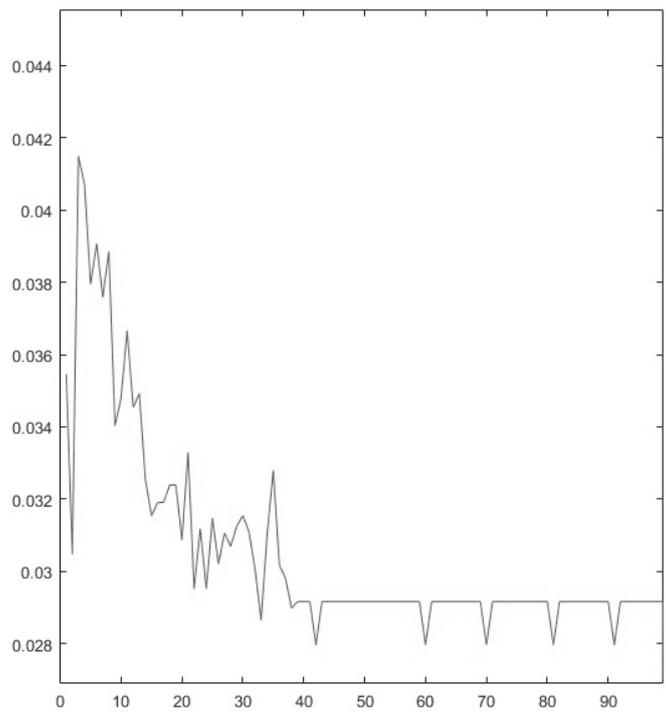


Рис. 5. График $J(I_{curr})$

1) определить, что система вышла в квазистационарный режим по величине

$$\frac{\partial^2 V(t)}{\partial t^2} \approx 0 \text{ в момент } t_s;$$

2) промоделировать фиксированное количество времени T_s до момента $t_f = t_s + T_s$;

3) результатом моделирования является величина $V(T) = V(t_f) - V(t_s)$.

По результатам моделирования для группы 100 ШГН без рекуперации при $N_r = 0.2$ и ширине фильтра скользящего среднего $3T_{avg}$, величина $t_s \approx 5T_{avg}$, что при $T_s = 12T_{ava}$ сокращает модельное время T с $T = 100T_{avg}$ до $T = t_f \approx 17T_{avg}$ — в 5.88 раз.

Результаты обучения НС и моделирования системы из 100 ШГН без рекуперации при $N_r = 0.25$ на разных итерациях обучения представлены на Рисунок 4. Для сравнения выведено 4 графика: $\text{Max } N_{fact}$ — график производительности при $N_r = 1$; Iter: first — график производительности перед первой итерацией обучения НС; Iter: last и Iter: last-1 — графики производительности на последней и предпоследней итерациях обучения. График функции стоимости в зависимости от итерации обучения представлен на рисунке 5.

Выводы

Итоги по применению адаптивной стратегии управления с использованием нейронной сети:

1. удалось добиться незначительного повышения производительности на 1% при тех же ограниче-

ниях по пиковой мощности для исследованных групп ШГН по сравнению с рассмотренными ранее вариантами определения показателя приоритетности;

2. ввиду невыпуклой формы функции стоимости — нет гарантии сходимости процесса обучения к наиболее оптимальному результату. Необходимо проводить несколько полных циклов обучения нейронной сети;
3. в данной стратегии управления присутствует большое количество гиперпараметров, которые влияют на качество обучения и работы НС;
4. преимущество данного метода в универсальности по отношению к набору параметров группы ШГН и величинам этих параметров. Это значит, что данная стратегия управления сможет показывать наилучшие результаты по сравнению с другими стратегиями управления независимо от значений параметров ШГН в группе при правильном подборе гиперпараметров;
5. НС в данном применении является обучаемой, как следует из графика функции стоимости, а применение НС в системе управления группой ШГН с мехатронным приводом с неодинаковыми циклами для повышения производительности при ограничении по пиковой мощности является возможным и достигает лучших результатов, чем неадаптивные методы, однако использование градиентного спуска в качестве основной функции оптимизации синаптических весов вызывает сложности, так как зависимость функции стоимости от синаптических весов не является гладкой функцией.

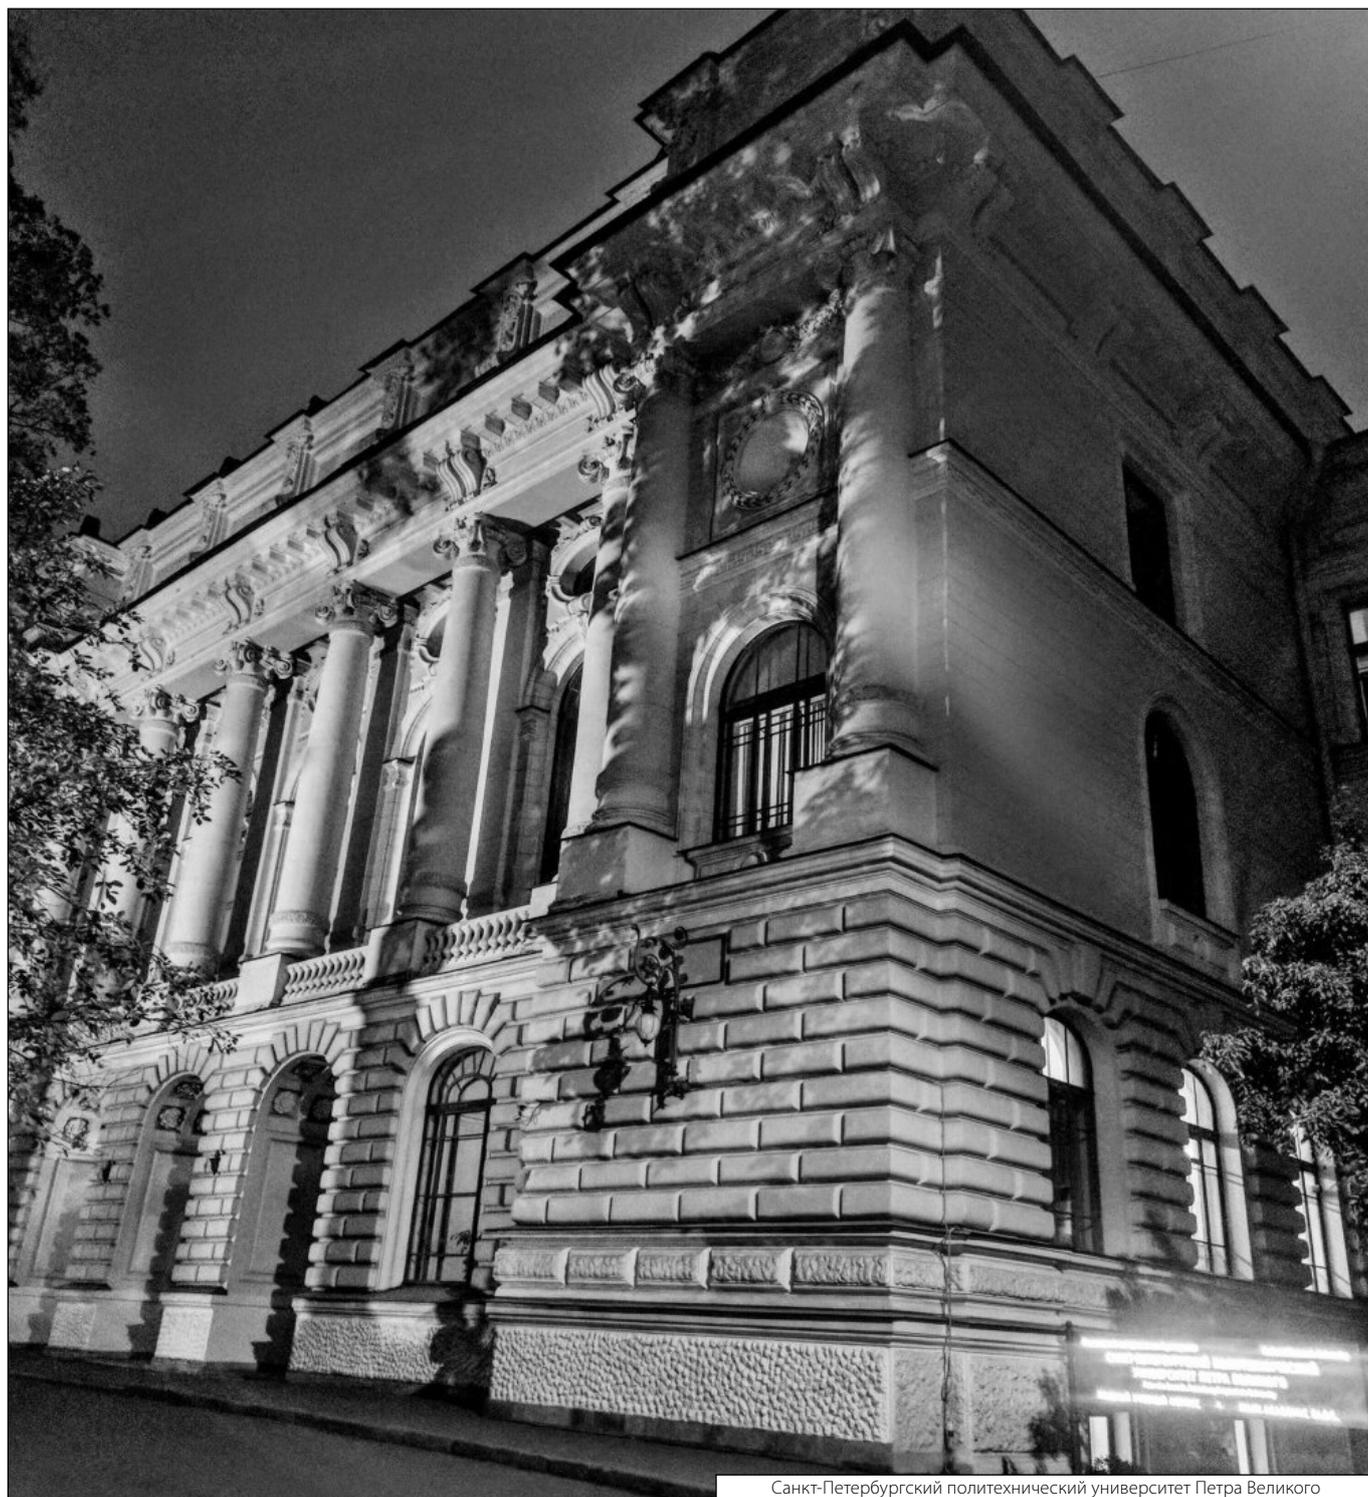
ЛИТЕРАТУРА

1. Обзор мировых энергетических рынков: рынок нефти январь 2021 // Научно-исследовательский финансовый институт министерства финансов Российской Федерации. М., 2021. URL: https://www.nifi.ru/images/FILES/energo/2021/oilmarket_january_2021.pdf (дата обращения 8.11.2021)
2. Перспективное скважинное оборудование для добычи сланцевой нефти баженовской свиты / С.В. Рудницкий, А.Ю. Зацепин, Е.В. Демин, Т.С. Ющенко // ПРОнефть. Профессионально о нефти. — 2021. — Т. 6. — № 1. — С. 64–75. — DOI 10.51890/2587-7399-2021-6-1-64-75.
3. Гизатуллин Ф.А. Анализ режимов работы электроприводов штанговых скважинных насосных установок / Гизатуллин Ф.А., Хакимьянов М.И. // Электротехнические и информационные комплексы и системы. 2017. т. 13. № 1. С. 11–18.
4. Camponogara, E. Scheduling pumpoff operations in onshore oilfields under electric-power constraints. / Camponogara, E., Oliveira, M.D., De Aguiar, M.A.S. // European Journal of Operational Research. 2015. 247 (3), 13008. С. 945–956.
5. Ларин М.Ю. Исследование зависимости эффективности работы системы штанговых насосов с шестеренно-реечным приводом от установленной мощности и алгоритма управления / Ларин М.Ю., Мацко О.Н., Полищук М.Н., Анисимова М.В., Моисеев Д.В. // Автоматизация и приборостроение: проблемы, решения. Материалы международной научно-технической конференции. Севастопольский государственный университет; науч. ред. В.Я. Копп. 2016. С. 45–46.
6. Volkov A.N., Larin M. Yu. Reducing the maximum power consumption of a group of sucker-rod pumps with the mechatronic drive by optimizing the control algorithm // E3S Web Conf., 326 (2021) 00037.
7. [Электронный ресурс]: Материалы сайта loginom. URL: <https://wiki.loginom.ru/articles/data-normalization.html>, (режим доступа — свободный), (дата обращения: 01.09.2022).

8. Воронина В.В., Михеев А.В., Ярушкина Н.Г., Святлов К.В. Теория и практика машинного обучения: учебное пособие. — Ульяновск: УлГТУ, 2017. — 290 с.
9. [Электронный ресурс]: Материалы сайта Википедия. URL: [https://ru.wikipedia.org/wiki/Скольльзящая_средняя_\(фильтр\)](https://ru.wikipedia.org/wiki/Скольльзящая_средняя_(фильтр)) (режим доступа — свободный), (дата обращения: 01.09.2022).

© Ларин Михаил Юрьевич (Lay9991@mail.ru), Волков Андрей Николаевич (Volkov-and-1@yandex.ru).

Журнал «Современная наука: актуальные проблемы теории и практики»



Санкт-Петербургский политехнический университет Петра Великого