

ОСНОВНЫЕ АСПЕКТЫ МАТЕМАТИЧЕСКОГО МОДЕЛИРОВАНИЯ РАСХОДА ЭЛЕКТРОЭНЕРГИИ НА МАГИСТРАЛЬНОМ НЕФТЕПРОВОДЕ*

Н.Т. Габдрахманова¹, С.М. Халаби²

¹Кафедра высшей математики

Факультет физико-математических и естественных наук

²Кафедра гидравлики и гидротехнических сооружений

Инженерный факультет

Российский университет дружбы народов

ул. Орджоникидзе, 3, Москва, Россия, 115419

Рассматривается актуальная задача планирования расхода электроэнергии на перекачку нефти по магистральному нефтепроводу. Приводятся основные результаты статистического анализа свойств моделируемого объекта, принципы и приемы построения математической модели. Для построенных моделей приводятся полученные оценки их адекватности и результаты проведенной верификации. Задача решена с использованием реальных данных наблюдения одного линейного участка магистрального нефтепровода.

Ключевые слова: нейронные сети, стохастический процесс, магистральный нефтепровод, расход электроэнергии.

Существующая система единого нефтеснабжения имеет весьма сложную структуру, развитие которой сопровождается не только строительством новых и модернизацией действующих трубопроводов. Для нее актуальна задача поиска резервов повышения эффективности трубопроводного транспорта, важнейшим из которых является снижение эксплуатационных расходов. Одной из основных статей эксплуатационных расходов магистральных нефтепроводов являются затраты на электроэнергию. Вместе с тем энергозатраты являются такой статьей расходов, которая может существенно изменяться в процессе работы трубопроводов из-за качества планирования и практической реализации режимов загрузки трубопроводов, надежности функционирования основного насосно-силового оборудования, ритмичности работы поставщиков и потребителей нефти, экономичности используемого энергетического оборудования и многих других факторов. Все это определяет актуальность решаемой задачи. На данный момент имеется значительное количество работ, касающихся оптимизации перекачки нефти по магистральным нефтепроводам. Наибольшее число публикаций представлено по выбору оптимальных режимов работы систем нефтепроводов. В отличие от существующих разработок в данной работе решается задача разработки алгоритма построения прогнозирующей модели расхода электроэнергии на магистральном нефтепроводе с целью использования последних для решения различных управленческих задач.

Объектом моделирования является линейный участок нефтепровода, схема которого представлена на рис. 1. Считается, что перекачка нефти от резервуарного

* Работа выполнена при финансовой поддержке РФФИ, проект 10-01-00381-а.

парка ЛПДС «А» до резервуарного парка конечного пункта является законченным технологическим процессом. В этих условиях расход электроэнергии определяется для нефтепровода в целом с учетом всех объектов и фиксируется ежедневно для каждого насоса. В блоке качества нефти, расположенном на участке технологического трубопровода между резервуарным парком и подпорной нефтенасосной ЛПДС «А», ведется измерение мгновенных реологических свойств нефти. На конечном пункте предусмотрена система измерения количества нефти (V), перекачиваемой по нефтепроводу [3].




Рис. 1. Схематическое изображение нефтепровода

Задача формулируется следующим образом: для заданного линейного участка нефтепровода, объемов резервуарных парков и наличия в них нефти, реологических свойств перекачиваемой нефти, выполнения требований к объему перекачиваемой нефти необходимо осуществить прогноз затрат электроэнергии на перекачку нефти.

Разработан итеративный алгоритм построения модели. На первом шаге на основе корреляционного анализа данных и согласно данным экспертных исследований для построения модели выбраны следующие переменные моделирования.

Результирующая (выходная) переменная:

$Y(t)$ — расход электроэнергии за период t , (кВт·ч);

объясняющие (входные) переменные:

ρ — плотность нефти ($\text{кг}/\text{м}^3$);

ν — вязкость нефти ($\text{м}^2/\text{с}$);

V — объем перекачиваемой нефти или производительность нефтепровода (м^3);

δV — коэффициент использования резервуарной емкости.

Для учета наличия нефти и свободной емкости РП ЛПДС «А» введена величина δV — коэффициент использования резервуарной емкости, определяется как отношение объема нефти ($V_{\text{тов}}$) к общему объему РП ($V_{\text{РП}}$):

$$\delta V = \frac{V_{\text{тов}}}{V_{\text{РП}}}.$$

Расход электроэнергии Y для магистрального нефтепровода функционально зависит от выбранных входных показателей и может быть представлен зависимостью

$$Y(t) = f(\rho(t), \nu(t), V(t), \delta V(t)) + \xi, \quad t \in T, \quad (1)$$

где f — неизвестная функция, ξ — ожидаемая ошибка, представляющая наше незнание зависимости между входными показателями и выходным показателем или «шум».

Обозначим $X(t) = (\rho(t), \nu(t), V(t), \delta V(t))$ — вектор входных показателей. Из-за действия случайных факторов в системе и окружающей среде переменные, влияющие на расход электроэнергии Y , являются случайными. Пусть существует N реализаций случайного вектора $\{X(t)\}_{t=1}^N$ и соответствующее им множество реализаций случайного вектора Y , которое обозначим $\{Y(t)\}_{t=1}^N$. Эти реализации (измерения) в совокупности составляют выборку

$$P = \{X(t), Y(t)\}_{t=1}^N. \quad (2)$$

Математическая модель функциональной взаимосвязи между X и Y неизвестна:

$$Y(X) = f(X) + \xi, \quad (3)$$

где $f(X)$ — некоторая детерминированная функция векторного аргумента; ξ — ожидаемая ошибка представляющая наше незнание зависимости между X и Y .

Необходимо по данным выборки (2) найти функцию $F(X)$ близкую к $f(X)$ по критерию

$$\|F(X) - f(X)\| \rightarrow \min \quad (4)$$

по всем точкам X из области ее определения D .

Статистическая модель, описанная выражением (3), называется регрессионной [1]. Вычислить (4) нельзя. В качестве оценки (4) используем среднеквадратическую ошибку на множестве экспериментальных точек:

$$E = \frac{1}{2N} \sum_{t=1}^N (Y(t) - F(X(t)))^2 \rightarrow \min. \quad (5)$$

Для решения поставленной задачи предлагается использовать нейронные сети (НС). Применение НС оправдано, если задача обладает следующими признаками: отсутствует алгоритм или неизвестны принципы решения задач, но накоплено достаточное число примеров; проблема характеризуется большими объемами входной информации; данные неполны или избыточны, «зашумлены», частично противоречивы. Наша задача характеризуется всеми перечисленными признаками. НС являются универсальными аппроксиматорами функций [2]. При нейросетевом моделировании вид нелинейной функции $f(X)$ может быть неизвестен. В случае многослойного персептрона с двумя скрытыми слоями нейронная сеть строит отображение вида

$$\hat{Y}(t) = F(X(t)) = f_3 \left(w_{30} + \sum_{k=1}^K w_{3k} f_2 \left(w_{20m} + \sum_{m=1}^M w_{2m} f_1 \left(\sum_{i=1}^n w_{1i} x_i(t) + w_{10i} \right) \right) \right),$$

где $i = 1, 2, \dots, n$ — число нейронов входного слоя; $m = 1, 2, \dots, M$ — число нейронов первого скрытого слоя; $k = 1, 2, \dots, K$ — число нейронов второго скрытого слоя; f_1, f_2, f_3 — функции активации нейронов первого и второго слоев; w_{10i}, w_{20m}, w_{30} — начальное возбуждение i -го, k -го нейрона первого, второго скрытого и выходного слоя; w_{1i}, w_{2m}, w_{3k} — весовые коэффициенты; $x_i(t)$ — i -тая координата входного вектора.

Предполагается также, что функции активации нейронов одного слоя одинаковые. Вид функции активации определяется характером решаемой задачи. Например, в качестве функции активации может быть использована на первом слое нечетная сигмоидальная функция:

$$\varphi(v) = \frac{1 - \exp(-av)}{1 + \exp(-av)}.$$

Необходимо по данным наблюдений (2) построить нейросетевое отображение, аппроксимирующую (3):

$$\hat{W}(t) = F(X(t), w), \quad (6)$$

где $F(X, w)$ оператор нейросетевого отображения. Вид F — зависит от выбранной модельной структуры нейронной сети.

При выбранной модельной структуре нейросети процедура обучения представляет собой отображение множества экспериментальных данных на множество параметров (весовых коэффициентов) нейросетевой модели с целью получения оптимального в силу некоторого критерия, выходного сигнала. Для набора данных обучения вектор синаптических весов w можно вычислить путем минимизации функции стоимости по w [4]:

$$E_c(w) = \frac{1}{2N} \sum_t (Y(t) - F(X(t), w))^2 \rightarrow \min, \quad w \in W, \quad (7)$$

где w — набор свободных параметров (синаптических весов), выбранных из пространства параметров весов.

В качестве критерия оптимальности модельной структуры НС используются оценки математического ожидания и дисперсии ошибки прогноза на T шагов упреждения:

$$\hat{M} = \frac{1}{T} \sum_{t \in T} (Y(t) - \hat{Y}(t))^2, \quad (8)$$

$$\hat{D} = \frac{1}{T} \sum_{t \in T} (Y(t) - \hat{M})^2. \quad (9)$$

Оценки (8) и (9) получены на основе T последних точек выборки (2), не использованных при построении НС. С помощью значений функций (8), (9) оценивается вероятность прогнозирования характеристики системы в заданных пределах.

Приведем основные результаты решения задачи.

При построении НС весь массив данных разбит на три массива: обучающая, валидационная и тестовая выборка. По данным обучающей и валидационной выборки построены НС с ранним останом. Архитектура нейросети: многослойный перцептрон с двумя скрытыми слоями. Функция активации нейронов скрытого слоя — гиперболический тангенс; выходного слоя — линейная функция. Алгоритм обучения: алгоритм обратного распространения ошибки.

Результаты обучения НС представлены в табл. 1. В таблице использованы следующие обозначения:

MSE — среднеквадратическая ошибка обучения;

NMSE — нормализованная среднеквадратическая ошибка обучения;

Min Abs Error — минимальная абсолютная ошибка обучения нейросети;

Max Abs Error — максимальная абсолютная ошибка обучения нейросети;

r — коэффициент корреляции между двумя столбцами: столбцом вычисленных и реальных значений выходного параметра.

Таблица 1

Результаты обучения НС

Performance	Y
MSE	0,010729
NMSE	0,013018
MAE	0,082562
Min Abs Error	0,00316
Max Abs Error	0,298512
r	0,993624

Результаты тестирования НС:

Training — обучение;

Cross Validation — перекрестная проверка;

Epoch # — число эпох;

Minimum MSE — минимальная среднеквадратическая ошибка обучения;

Final MSE — финальная среднеквадратическая ошибка обучения.

Таблица 2

Результаты тестирования НСМ1

Best Networks	Training	Cross Validation
Epoch #	1 000	1 000
Minimum MSE	0,001165	0,001449
Final MSE	0,001165	0,001449

Приведенные результаты свидетельствуют о хорошей степени аппроксимации.

На рис. 1 приведен график среднеквадратической ошибки перекрестной проверки и обучающего массива в зависимости от шага итерации. Графики свидетельствуют о хорошем качестве обучения. На рис. 2 приведена диаграмма модельных и реальных значений результирующего показателя точек тестового множества. Эти графики почти совпадают.




Рис. 1. Результаты обучения НС




Рис. 2. Диаграмма модельных и экспериментальных значений на множестве тестовых точек

Фрагмент результатов прогнозирования расхода электроэнергии для нормализованных данных представлен в табл. 3. Ошибка прогноза для данных одного месяца в основном составила 2%, только для двух наблюдений ошибка равна 3%.

Таблица 3

Фрагмент результатов прогноза расхода электроэнергии

t	ρ	v	V	δV	Y	\hat{Y}	$\varepsilon = \left \frac{Y - \hat{Y}}{Y} \right \cdot 100\%$
1	0,0127	0,1593	2,0168	1,4127	1,3072	1,2890	1%
2	2,4854	1,3690	0,4319	-1,5801	-1,2855	-1,3173	2%
3	2,0572	1,2671	0,7520	-1,4383	-1,2974	-1,2594	3%
4	1,7306	0,8511	1,0274	-1,4687	-1,3038	-1,3050	0%
5	0,3642	0,2227	0,1125	0,4252	0,3475	0,3509	1%
6	1,1341	1,1652	-1,3552	-1,4237	1,2919	1,2666	2%
7	1,3057	1,2332	0,9583	1,4148	-1,2745	1,2604	1%

Полученные результаты свидетельствуют об адекватности моделей, построенных по разработанному алгоритму. Числовые эксперименты свидетельствуют

об эффективности использования нейросетевых технологий для решаемой задачи. Построенные модели по данным одного линейного участка апробированы на данных аналогичного линейного участка трубопровода. Расчеты показали, что точность прогноза для другого линейного участка также удовлетворяет требованиям прогноза. Данный факт свидетельствует о возможности типизации моделей и о возможности использования моделей при проектировании магистрального нефтепровода. Разработанные математические модели позволяют автоматизировать процесс планирования расхода электроэнергии, что повысит эффективность обслуживания магистрального нефтепровода.

ЛИТЕРАТУРА

- [1] Айвазян С.А. Методы эконометрики: Учебник. — М.: Магистр; ИНФРА-М, 2010.
- [2] Хайкин С. Нейронные сети: полный курс. 2-е изд. / Пер. с англ. — М.: Вильямс, 2006.
- [3] Регламент разработки технологических карт, расчета режимов работы магистральных нефтепроводов ОАО «АК „Транснефть“». — М., 2008.

BASIC ASPECTS OF MATHEMATICAL MODELING OF ELECTRIC ENERGY CONSUMPTION ON MAINLINE PIPELINE

N.T. Gabdrachmanova¹, S.M. Halabi²

¹Department of Mathematics
Faculty of science
Peoples' Friendship University of Russia

²Department of Hydraulics and Hydraulic Structures
Engineering faculty
Peoples' Friendship University of Russia
Ordzhonikidze str., 3, Moscow, Russia, 115419

An actual task planning of electric energy consumption on throughput for trunk oil pipeline are considered in this article. Main results of the statistical analysis of characteristics of simulated object, principles and methods of construction of mathematical models were shown. For built models are obtained to assess their adequacy and results verification. The problem is solved by using real data observation one linear plot of trunk oil pipeline.

Key words: neural networks; stochastic process; mainline pipeline; electricity consumption.