

УДК 622.692

ОСНОВНЫЕ АСПЕКТЫ ПОСТРОЕНИЯ НЕЙРОСЕТЕВОЙ ПРОГНОЗНОЙ МОДЕЛИ РАСХОДА ЭЛЕКТРОЭНЕРГИИ ДЛЯ РАЗВИВАЮЩИХСЯ НЕФТЕПРОВОДОВ

Л.Ф. Шириазданова
ОАО «СЗМН», г. Казань,
e-mail: shililiya@yandex.ru

Макаренко О.А., Козачук Б.А.
Уфимский госудратвенный нефтяной технический университет, г. Уфа,

Габдрахманова Н.Т., Халаби С.М.
Российский университет дружбы народов, г. Москва

Аннотация. Работа посвящена прогнозированию расхода электроэнергии в период планирования работы магистральных нефтепроводов. Разработан алгоритм построения математической модели для развивающихся нефтепроводов на основе реальных данных эксплуатации нескольких магистральных нефтепроводов.

Ключевые слова: нефтепровод, перекачка, прогнозирование, расход электроэнергии, нейронные сети, развивающиеся нефтепроводы

Актуальность решения задачи построения математической модели прогнозирования расхода электроэнергии в трубопроводном транспорте нефти определяется следующим. Транспорт нефти сопряжен со значительными затратами электроэнергии. Стохастический характер этого процесса приводит к тому, что в большинстве случаев наблюдаются отклонения фактического расхода электроэнергии от запланированных значений. Это в свою очередь инициирует процесс применения штрафных санкций к предприятиям по транспорту нефти. С другой стороны, широкое использование вычислительной техники, автоматизация и телемеханизация объектов нефтепроводных систем позволяет не только управлять ими, но и сохранять в памяти историю изменения их состояния. В настоящее время собранная статистическая информация используется при принятии решений по управлению работой магистральных нефтепроводов, однако методы обработки этой информации основаны главным образом на детерминированных операциях и не удовлетворяют возросшему требованию к точности.

В [1] решена задача прогнозирования расхода электроэнергии на нефтепроводе по данным его эксплуатации с использованием искусственных нейронных сетей. Однако при вводе в эксплуатацию новых нефтепроводов, законсервированных нефтеперекачивающих станций, строительстве лупингов на первых этапах эксплуатации нет достаточной статистической информации, отражающей их экс-

плуатационные характеристики, поэтому использование нейронных сетей для составления прогноза расхода электроэнергии на перекачку нефти практически невозможно. В этом случае предлагается модель, которая позволяет использовать как собственную информацию о работе нефтепровода предыдущего периода, даже при незначительном её объеме, так и статистические данные других нефтепроводов.

В общем виде решаемую задачу можно свести к построению математической модели на основании совокупности исходных данных по нескольким магистральным нефтепроводам, подразделяемых на множество входных данных X и на множество выходных данных Y при заданных ограничениях и знаниях о системе Z^N . В множество Z^N включается априорная информация о нескольких магистральных нефтепроводах различных по технологическим характеристикам. Процедура построения математической модели системы Z^N на основе экспериментальных исследований и измерений его входных и выходных данных является задачей идентификации объекта. Решение задачи идентификации включает следующие шаги: 1) определение информативных показателей; 2) выбор критерия близости модели к объекту, учитывающий специфику задачи; 3) выбор и определение структуры модели на основании имеющейся априорной информации об исследуемом процессе; 4) определение параметров модели, оптимальных с точки зрения выбранного критерия идентификации; 5) верификация модели.

Переменные моделирования, описывающие каждый магистральный нефтепровод, определены с учетом с используемых методик [2, 3]. В задаче результирующая (выходная) переменная $y(t)$ – расход электроэнергии на перекачку нефти за период t для каждого магистрального нефтепровода, (кВт·ч/сут). Компоненты входного вектора X для каждого магистрального нефтепровода условно разбиты на две составляющие:

$$X(t) = (v(t), u(t), t),$$

где $v(t)$ – вектор состояния системы;

$u(t)$ – вектор входных сигналов (управляющие воздействия);

t – время.

Компоненты вектора состояния $v(t)$:

$x_1(t)$ – эквивалентный диаметр нефтепровода $D_{\text{экв}}$, (мм);

$x_2(t)$ – протяженность магистрального нефтепровода L , (км);

$x_3(t)$ – разность геодезических отметок нефтепровода ΔZ , (м);

$x_4(t)$ – коэффициент использования резервуарного парка δV .

Компоненты вектора входных сигналов $u(t)$:

$x_5(t)$ – номер сезона M ;

$x_6(t)$ – плотность нефти при температуре перекачки ρ , (кг/м³);

$x_7(t)$ – вязкость нефти при температуре перекачки ν , (м²/с);

$x_8(t)$ – коэффициент загрузки магистрального нефтепровода относительно проектной пропускной способности δQ , ($\cdot 100$ %);

$$\delta Q = \frac{Q_{сут}}{Q_{пр}},$$

где $Q_{сут}$ – суточный расход нефти, ($\text{м}^3/\text{сут}$);

$Q_{пр}$ – проектный суточный расход нефти, ($\text{м}^3/\text{сут}$);

$x_9(t)$ – коэффициент загрузки предыдущего (начального) режима относительно проектной пропускной способности δq , ($\cdot 100$ %);

$$\delta q = \frac{q_{2ч}}{q_{пр}},$$

где $q_{2ч}$ – двухчасовой расход нефти предыдущего (начального) режима, ($\text{м}^3/2\text{ч}$);

$q_{пр}$ – проектный двухчасовой расход нефти, ($\text{м}^3/2\text{ч}$).

Исследования реального объекта показывают, что выходной сигнал объекта (расход электроэнергии) для любого нефтепровода неизбежно случаен даже при фиксированных векторах входа. Магистральный нефтепровод функционирует в условиях значительной априорной неопределённости, которая вызывается неполнотой информации о входных воздействиях и присутствием неконтролируемых возмущений. Например, производительность любого нефтепровода зависит от режима поставки и приема, запаса нефти и свободной емкости в резервуарных парках нефтепроводной системы, простоев по различным причинам (аварии, неисправности), физико-химических свойств нефти (плотности и вязкости нефти при температуре перекачки), однородности нефти. На рис. 1 изображен тренд суточного расхода нефти на режиме j за 12 дней одного месяца для действующего нефтепровода. Режим j – определенная комбинация одновременно включенных насосных агрегатов.

Из рис. 1 видно, что нормализованный фактический расход нефти режима j за 12 суток изменяется в пределах от “-1,5” до “1,8”, то есть при одной и той же включенной комбинации насосных агрегатов производительность нефтепровода является величиной случайной [4].

Отсюда следует, что требования к результату функционирования магистрального нефтепровода нужно формулировать в вероятностных терминах. В связи с этим в дальнейшем будем исходить из статистической постановки задачи идентификации, считая, что входные воздействия X и реакция системы Y представляют собой случайные величины. Также наша задача характеризуется 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. Для решения поставленной задачи оправдано использо-

вание искусственных нейронных сетей (ИНС), которые являются универсальными аппроксиматорами функций [5].




Рис. 1. Изменение объемного расхода нефти во времени на режиме j

Построение ИНС представляет собой итерационный процесс, который можно условно разбить на два этапа: выбор модельной структуры и поиск оптимальных параметров ИНС. Выбор модельной структуры включает выбор типа ИНС, задание связей между нейронами, числа слоев, числа нейронов в каждом слое, вид активационных функций.

Допустим, что выбрана некоторая модельная структура ИНС $g(w)$:

$$y(t) = g(t, w) + \varepsilon(t).$$

Следующим этапом является оценка параметров выбранной модельной структуры. При использовании нейросетевых модельных структур этот этап представляет собой настройку весовых коэффициентов w сети в результате реализации процедуры обучения на множестве примеров. Обучение представляет собой отображение множества экспериментальных данных на множество нейросетевой модели:

$$Z^N \rightarrow \hat{w},$$

с целью получения оптимального, в силу некоторого критерия, прогноза выходного сигнала \hat{y} . Традиционно используемым критерием является средне-

квадратическая ошибка прогнозирования

$$V_N(w, Z^N) = \frac{1}{2N} \sum_{t=1}^N (y(t) - \hat{y}(t|w))^2 = \frac{1}{2N} \sum_{t=1}^N \varepsilon \varepsilon^2(t|w). \quad (1)$$

Данный подход относится к классу методов ошибок прогнозирования.

Дано: Множество Z^N , содержащее информации об эксплуатации нескольких магистральных нефтепроводов и разбитое множество для формирования ИНС Z_1 и множество для оценки прогностической способности модели Z_2 : $Z_1 \cup Z_2 = Z^N$; $Z_1 \cap Z_2 = \emptyset$.

При построении ИНС всё множество Z_1 разбивается на три непересекающихся подмножества: обучающее Z_1^0 , валидационное (проверочное) и тестовое Z_1^T . В обучающем и валидационном массивах множества Z_1 используются наблюдения по эксплуатации группы магистральных нефтепроводов (разного диаметра и коэффициента загрузки), содержащие достаточную статистическую информацию за предыдущей период и одинакового объема для каждого нефтепровода. В нашем случае информация о магистральном нефтепроводе с ограниченным количеством наблюдений в обучающем и валидационном массивах множества Z_1 , составляет 6 % от их объема. Эта величина индивидуальна для каждого рассматриваемого примера и зависит от наличия информации на момент построения ИНС. Тестирование обученной ИНС проводится на тестовой выборке Z_1^T , которая состоит из данных о магистральном нефтепроводе с ограниченным количеством имеющихся наблюдений, отражающих изменение условий перекачки.

Математическая постановка задачи:

1. множество точек обучающего массива $Z_1^0 = \{(x(t), y(t)), t \in N_1\}$,
множество точек тестового множества $Z_1^T = \{(x(t), y(t)), t \in N_2\}$;
2. множество $Z_2 = \{(x(t), y(t)), t \in N_3\}$ точек верификации для оценки прогнозной способности модели.
3. $L = \{K, M\}$ – число нейронов скрытых слоёв;
4. W – множество весов;
5. H – ограничение сверху на относительную погрешность вычисления.

Требуется: 1) Путём построения ИНС по данным обучающего массива найти наилучшие значения числа нейронов скрытого слоя и весовых коэффициентов. Найти отображение $F(L, w)$, удовлетворяющее ограничению

$$h < H, \quad (2)$$

где $h = \max_{t \in T} h_t$,

$$h_t = \left| \frac{y(t) - \hat{y}(t)}{y(t)} \right|, (x(t), y(t)) \in Z_1^T. \quad (3)$$

Основные результаты

Для решения задачи аппроксимации выбрана следующая структура нейронной сети: тип ИНС – многослойный персептрон; число скрытых слоёв – 2; алгоритм обучения ИНС – backpropagation; функция активации нейронов скрытого слоя – нечётная сигмоидальная функция $\varphi = \frac{1 - \exp(-av)}{1 + \exp(-av)}$; функция активации нейронов выходного слоя – линейная функция.

В случае многослойного персептрона с двумя скрытыми слоями нейронная сеть строит отображение вида:

$$\hat{Y}(t) = F(X(t)) = f_3 \left(w_{30} + \sum_{k=1}^K w_{3k} f_2 \left(w_{20m} + \sum_{m=1}^M w_{2m} f_1 \left(\sum_{i=1}^n w_{1i} x_i(t) + w_{10i} \right) \right) \right), \quad (4)$$

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 и второго скрытого, и выходного слоя;

$x_i(t)$ – i -я координата входного вектора.

При использовании (4) основная задача состоит в нахождении параметров модели посредством минимизации функционала

$$\hat{w} = \arg \min_w V_N(w, Z^N). \quad (5)$$

На рис. 2 приведён график среднеквадратической ошибки обучающего и валидационного множества в зависимости от шага итерации (эпохи). Графики свидетельствуют о хорошем качестве обучения. На рис. 3 диаграмма модельных и реальных значений результирующего показателя точек тестового множества. Эти графики почти совпадают.

Оценка прогнозной способности оптимальной ИНС получена на множестве Z_2 . На вход ИНС поданы входные сигналы множества Z_2 и вычислены модельные значения выходного сигнала. Для каждой точки вычислены относительные погрешности вычисления. Фрагмент вычисления приведён в табл. 1. Все значения u приведены в нормированном виде.




Рис. 2. Фрагмент результатов обучения ИНС




Рис. 3. График результатов тестирования ИНС, построенной по данным нескольких нефтепроводов

Таблица 1. Фрагмент верификации прогнозной модели расхода электроэнергии

t	$y(t)$	$\hat{y}(t)$	$h_t, \%$
1	1,3072	1,2890	1
2	-1,2855	-1,3173	2
3	-1,2974	-1,2594	3
4	-1,3038	-1,3050	0
5	0,3475	0,3509	1
6	1,2919	1,2666	2
7	-1,2745	1,2604	1

Средняя относительная ошибка прогнозирования расхода электроэнергии по статистической информации группы нефтепроводов составила 2,5 %.

Выводы

Полученные результаты свидетельствуют о том, что для решения задачи прогнозирования расхода электроэнергии для развивающихся и вводимых в эксплуатацию магистральных нефтепроводов, то есть для таких нефтепроводов, у которых количество имеющихся наблюдений, отражающих изменение условий перекачки, ограничено, можно использовать нейросетевые технологии. Точность прогнозирования расхода электроэнергии для таких магистральных нефтепроводов будет тем выше, чем больше будет статистической информации об эксплуатации данного магистрального нефтепровода. Данный факт свидетельствует о возможности типизации моделей и о возможности использования моделей при проектировании магистрального нефтепровода. Разработанные математические модели позволят автоматизировать процесс прогнозирования расхода электроэнергии, что повысит эффективность обслуживания магистрального нефтепровода.

Литература

1. Шаммазов А.М., Козачук Б.А., Габдрахманова Н.Т., Шириязданова Л.Ф. Алгоритм решения задачи прогнозирования расхода электроэнергии в трубопроводном транспорте нефти с использованием нейронных сетей // Электронный научный журнал «Нефтегазовое дело», 2010, № 2.
URL http://www.ogbus.ru/authors/Shammazov/Shammazov_2.pdf.
2. Регламент разработки технологических карт, расчета режимов работы магистральных нефтепроводов ОАО «АК «Транснефть», Москва, 2008.

3. Тугунов П.И., Новоселов В.Ф., Коршак А.А., Шаммазов А.М. Типовые расчеты при проектировании и эксплуатации нефтебаз и нефтепроводов. Учебное пособие для ВУЗов. – Уфа: ООО «Дизайн-ПолиграфСервис», 2002 – 658с.

4. Колпаков Л.Г. и др. Статический анализ гидравлической системы насосные станции – нефтепровод. Транспорт и хранение нефти и нефтепродуктов. РНТС/ВНИИОЭНГ, М., 1977, №9.

5. Хайкин С. Нейронные сети: полный курс, 2-е издание: Пер. с англ. – М. Издательский дом «Вильямс», 2006. – 1104 с.

**THE BASIC ASPECTS OF NEURAL NETWORK FORECASTING MODEL
OF THE ELECTRIC POWER CONSUMPTION
FOR DEVELOPING OIL PIPELINES**

L.F. Shiriazdanova

*SZMN JSC, Kazan, Russia
e-mail: shililiya@yandex.ru*

O.A. Makarenko, B.A. Kozachuk

Ufa State Petroleum Technological University, Ufa, Russia

N.T. Gabdrakhmanova, S.M. Halabi

Peoples' Friendship University of Russia, Moscow, Russia

Abstract. *The work is devoted to forecasting of electricity consumption in the planning period of operation of main oil pipelines. The algorithm of construction of mathematical model is developed for developing oil pipelines on the basis of the real data of operation of several main oil pipelines.*

Keywords: *oil pipeline, pumping, forecast, power consumption, neural networks, developing oil pipelines*

References

1. Shammazov A.M., Kozachuk B.A., Gabdrakhmanova N.T., Shiriazdanova L.F. Algoritm resheniya zadachi prognozirovaniya raskhoda elektroenergii v truboprovodnom transporte nefi s ispol'zovaniem neironnykh setei (Algorithm of the decision of the problem of forecasting power consumption in pipeline transport of oil with use of neural networks). *Electronic scientific journal "Neftegazovoe Delo - Oil and Gas Business"*, 2010, Issue 2. http://www.ogbus.ru/authors/Shammazov/Shammazov_2.pdf.
2. Reglament razrabotki tekhnologicheskikh kart, rascheta rezhimov raboty magistral'nykh nefteprovodov (Rules of development technological cards and calculation of the operating conditions of the main oil pipelines Transneft JSC AK). Moscow, 2008.
3. Tugunov P.I., Novoselov V.F., Korshak A.A., Shammazov A.M. Tipovye raschety pri proektirovanii i ekspluatatsii neftebaz i nefteprovodov. Uchebnoe posobie dlya VUZov (Routinel calculations for the design and operation of oil depots and oil pipelines. Textbook for High Schools). Ufa: "Dizain-PoligrafServis" JSC, 2002. 658 p.
4. Kolpakov L.G. et al. Statische analiz gidravlicheskoj sistemy nasosnykh stantsii - nefteprovod (Static analysis of the hydraulic system "pump stations - oil"). *Transport i hranenie nefi i nefteproduktov*. RNTS/VNIOENG, Moscow, 1977, Issue 9.
5. Khaikin S. Neironnye seti: polnyi kurs, 2-e izd. (Translated from *Simon Haykin Neural Networks: A Comprehensive Foundation Second Edition*, Prentice Hall, 1998, 842 p.). Moscow: Williams Publishing House, 2006. 1104 p.