Д.В. Кратиров, А.В. Меркушева
D.V. Kratyrov, A.V. Merkusheva

АЛГОРИТМ, ОСНОВАННОЫЙ НА ВЕЙВЛЕТ-ПРЕОБРАЗОВАНИИ И НЕЙРОННОЙ СЕТИ, ДЛЯ БЕСКОНТАКТНОГО ИЗМЕРЕНИИ ПАРАМЕТРОВ ГАЗОЖИДКОСТНОГО ПОТОКА

ALGORITHM, BASED ON WAVELET TRANSFORMATION AND NEURAL NETWORK, FOR INCONTACT MEASUREMENT OF GAS-LIQUID FLOW PARAMETERS

Санкт-Петербургский государственный технический университет
St. Petersburg State Technical University

The algorithm is suggested for free gas content determination in commodity oil by means of radioisotope method for incontact density measurement. Algorithm is based on wavelet decomposition of density-meter signal and neural network.

Полноценный учет объема продукции товарной нефти на стадии добычи, транспортировки по трубопроводам и на нефтегазоперекачивающих станциях зависит от возможности регистрации относительной доли свободного газа (ОДСГ). Интервалы потока нефтегазовой смеси, в которых газовая фракция присутствует в форме пузырей, спорадически перемежаются с интервалами чистой нефти. ОДСГ (φ) связана с объемами жидкости и газа ($V_ж$ и $V_г$), проходящими через контролируемое сечение трубопровода, соотношением (1) и может быть выражена через плотность нефти $\rho_ж$ и плотность нефтегазовой смеси $\rho_{см}$ по (2):

$$\varphi = 1 - \frac{V_{ж}}{V_{ж} + V_{г}} \qquad (1) \qquad\qquad \varphi = 1 - \frac{\rho_{см}}{\rho_{ж}} \qquad (2)$$

Контроль плотности лежит в основе бесконтактного метода измерения ОДСГ в ИИС “Фактор”, разработанной в ЦНИИ РТК [1]. Метод использует измерение интенсивности гамма-излучения Cs-137 после поглощении его потоком с переменной плотностью, обусловленной наличием интервалов с содержанием свободного газа. Переменная интенсивность гамма-излучения контролируется блоком детектирования (БД) со стинцилляционным кристаллом Na(J) и фотоумножителем.

Ввиду большой скорости потока (до 5 м/с) контроль его производится непрерывно и дает информацию в форме нестационарного процесса с интенсивностью отсчетов, зависящей от ОДСГ. Сложным этапом обработки и интерпретации этой информации является разделение длительности контроля потока на интервалы с чистой нефтью и с нефтегазовой фракцией, включающей пузыри. В ИИС использованы два способа обработки. Метод бегущей выборки с оценкой статистических параметров распределения отсчетов БД, получением отношения правдоподобия и сравнением его с допуском. Метод, использующий полуэмпирические зависимости автокорреляции отсчетов и результаты градуировки на поверочно-испытательном стенде. Оба метода не вполне совершенны и имеют небольшую зависимость от скорости потока и плотности нефти. Это стимулирует поиск новых форм анализа измерительной информации.

Измерение и обработка сигналов в ИИС, связана со сложным изменением характеристик процессов, которые трудно описать априорными моделями. Основой обработки нестационарного сигнала может служить информация о динамике его частотной структуры, получаемая с помощью время – частотных преобразований (ВЧП) или вейвлет – преобразования (ВП). Анализ группы ВЧП (Габора, Зака. Вигнера, Бесселя) [2] показал их эффективность для сигналов специального вида, отсутствие быстрых алгоритмов и ограниченность по разрешению. ВП дают неравномерную (логарифмическую) шкалу разрешения по частоте, быстрые алгоритмы реализации на основе квадратурных зеркальных фильтров (КИХ - фильтров с короткими характеристиками и рядом специальных свойств) и имеет разновидности, определяемые видом базиса ВП [3]. Выбор базиса определяется требованиями к его свойствам (ортогональности, симметрии и наличию нулевых моментов), которые обеспечивают сохранение фазовых соотношений при восстановлении сигнала и экономное его представление при наличии полиномиального дрейфа. Модификация вейвлет – преобразования в форме вейвлет – пакетов позволяет получать желаемую неравномерность разрешения по шкале частот.

В связи с этими преимуществами ВП, при разработке нового метода обработки информации в ИИС «Фактор» оно использовано в качестве основы анализа нестационарного сигнала. Вторая составляющая метода - применение нейронной сети для определения типов интервалов регистрации (с чистой нефтью или с примесью газообразной фракции).

@2002, электронная версия подготовлена ЗАО АВТЭКС Санкт-Петербург, http://www.autex.spb.ru

Таким образом, в целях совершенствования наиболее критического этапа измерения ОДСГ в потоке нефти исследован метод на основе вейвлет – преобразования и нейросетевого алгоритма на многослойном персептроне. ВП позволяет локализовать частотные свойства сигнала во времени, дает сжатую форму его представления, снижает уровень шумов и для сигнала со спорадически чередующимися характерными типами интервалов позволяет применить нейронную сеть для различения типа интервала. Использование билинейного базиса обеспечивает сохранение фазы при восстановлении сигнала и быстрый алгоритм вычислений при ВП.

Метод использует вейвлет – преобразование на последовательности сегментов измерительных данных, поступающих с блока детектирования ИИС, вычисление мощности вейвлет – коэффициентов в каждой области разложения, нормирование вектора мощности и использование его в виде входного вектора для нейронной сети, в качестве которой применен персептрон для бинарной классификации типа интервала.

Выполнено исследование, позволившее выбрать структуру многослойного персептрона и обосновать метод обучения, имеющего лучшую скорость сходимости. Для повышения эффективности алгоритма обучения персептрона выбрана его конфигурация с использованием метода наращивания. Сопоставление структур проводилось на двух лучших (для анализируемых данных) алгоритмах обучения, и предпочтение отдано структуре 5-2-1.

Обучение персептрона основано на алгоритме с обратным распространением ошибки. Алгоритм реализуется итеративно с двумя проходами по сети – прямым и обратным, при которых вычисляются функциональные преобразования вектора входного сигнала $\mathbf{x}=(x_1 \ \dots \ x_p)^T$ и корректировка вектора параметров **w**. При обратном проходе на каждой итерации n определяется локальный градиент $\delta_j(n)$ - по (3), если нейрон в выходном слое, и по (4), если в скрытом слое:

$$\delta_j(n)=e_j(n)\varphi'(v_j(n)) \qquad (3) \qquad \delta_j(n)=y_j(n)[1-y_j(n)]\sum_k \delta_k w_{jk} \qquad (4)$$

где $v_j(n)$, $y_j(n)$, $e_j(n)$ – возбуждение, выход и ошибка j-нейрона, φ'- производная его функции нелинейности, w_{jk} – параметры веса.. Величина $\delta_j(n)$ используется для корректировки весов с помощью δ-правила по (5) или с помощью модифицированного δ-правила по (6):

$$\Delta w_{ji}(n)=\eta\delta_j(n)y_i(n) \quad (5) \qquad \Delta w_{ji}(n)=\alpha\Delta w_{ji}(n-1)+\eta\delta_j(n)y_i(n) \quad (6)$$

где α – параметр инерции, η – параметр скорости обучения.

Другой подход к обучению персептрона для детектирования типа интервала основан на трактовке этой фазы как оптимизация нелинейной функции отображения вход – выход [3]. В исследовании применен метод сопряженных градиентов и метод Бройдена-Флетчера [5]. В методе сопряженных градиентов коррекция вектора весов персептрона $\vec{w}(n)$ осуществляется в направлении вектора $\vec{p}(n)$ по (7):

$$\vec{w}(n+1)=\vec{w}(n)+\eta(n)\vec{p}(n) \qquad \vec{p}(n+1)=-\vec{g}(n+1)+\beta(n)\vec{p}(n) \qquad (7)$$

где $\vec{g}(n)$ - вектор градиента, а параметр β(n) определяется по (8) – в методе Флетчера-Ривса и по (9) – в методе Полака-Рибере [6]:

$$\beta(n)=\left[\frac{\vec{g}^T(n+1)\cdot\vec{g}(n+1)}{\vec{g}^T(n)\cdot\vec{g}(n)}\right] (8) \qquad \beta(n)=\left[\frac{\vec{g}^T(n+1)[\vec{g}(n+1)-\vec{g}(n)}{\vec{g}^T(n)\cdot\vec{g}(n)}\right] (9)$$

Оценка параметра η(n) включает линейный поиск. В качестве более совершенного способа поиска использован метод адаптации параметра скорости обучения на основе правила Джекобса (дельта-дельта правило) [6]. Метод Бройдена-Флетчера является модификацией метода Ньютона и связан с аппроксимацией матрицы Гессе с помощью конечных разностей градиента функции ошибок.

Проведенный анализ показал, что лучшие результаты дает обобщенный метод дельта-дельта и метод Бройдена-Флетчера. Алгоритмы, реализованные для этих методов, дают близкую эффективность по длительности обучения и вероятности ошибочных решений. Они использованы для моделирующей программы при исследовании характеристик метода обработки информации.

Моделирование процесса регистрации состояния гетерогенного потока нефти аппаратурой ИИС “Фактор” осуществлено с помощью программы, выполненной в среде Microsoft Visual C 6.0. Алгоритм имитирует симметричную геометрию расположения блока гамма-излучения и блока

детектирования. Нестационарный характер изменения поглощения потока гамма-квантов за счет переменной плотности нефтегазовой смеси моделируется с помощью модуля “генератора пузырей”, который формирует газосодержание как процесс авторегрессии с автокорреляционной функцией экспоненциального вида. Величина параметра затухания этой функции (α) значительно влияет на погрешность определения ОДСГ.

В алгоритме моделирования использована аппроксимация закона Пуассона для распределения отсчетов БД Гауссовым законом, где $\sigma^2_{\{N_i\}} = \overline{N}_i$ (N_i - отсчеты БД, $\overline{N}_i$ - параметр среднего). Корректность аппроксимации обеспечивает высокая интенсивность отсчетов БД.

Погрешность определения ОДСГ показана на рис.1. Использование предложенного метода дает лучшие результаты при измерениях в потоках, которые характеризуются высокой степенью затухания автокорреляционной функции, то есть в потоках, содержащих мелкие газовые включения и высокие скорости перемещения.

Литература

1. Кратиров В.А., Казаков А.Н. и др. Способ измерения параметров газожидкостного потока. Патент на изобретение N94007263/25(007607), 1996.
2. Исмаилов Ш.Ю., Меркушева А.В. Анализ время-частотных преобразований //Тезисы НТК «50 лет развития кибернетики», С-Пб, 1999, с.14.
3. Jawerth B, Sweldens W. SIAM Review, 1994, v.36, n.3, p.377.
4. Hornic K., Stinchcombe M. Whit H Neural Networks, 1990, v.3, p.551
5. Химмельблау Р. Прикладное нелинейное программирование, М., 1975, с.98.
6. Jacobs R.A. Neural networks, 1988, v.1, p.295

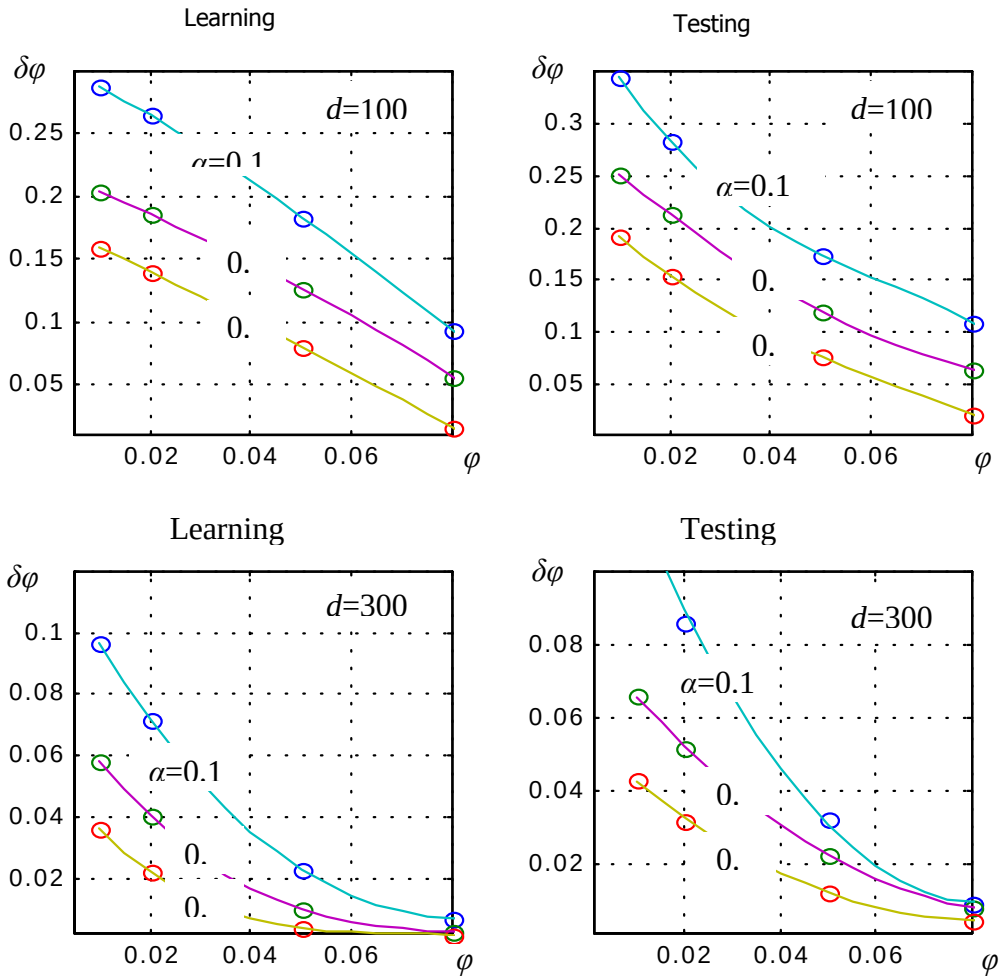


Fig. Free-gas relative-content error for measurement on pipes of 100 and 300 mm by means of neural network algorithm.