

**Леви Л.И., Чичикалов А.В.**

Луганский национальный аграрный университет, г. Луганск, Украина

**Введение.** Эффективность автоматизированной системы орошения во многом зависит от информативности входных данных, поступающих от распределенной сети датчиков. Выбирая оптимальный алгоритм для обработки и анализа массива данных, как правило, основное внимание сосредотачивают на достижении следующих целей: уменьшение размера исходных данных, извлечение полезной информации на фоне шумов, прогнозирование будущих значений.

Для решения подобных задач существует широкий спектр инструментов, и каждый из них обладает своими достоинствами и недостатками. Поэтому, комбинируя различные методы, можно объединить положительные свойства, присущие каждому алгоритму в отдельности и добиться желаемого результата с меньшими вычислительными затратами.

**Обзор литературы.** Существующие системы по сбору и обработке данных все чаще включают в себя кроме традиционного спектрального анализа Фурье, некоторые элементы из теории интеллектуальных вычислений, такие как нейронные сети, эволюционные алгоритмы, нечеткую логику. Актуальность данного направления подтверждает и анализ последних публикаций. Авторы работы [1], рассматривают нечеткий вейвлет метод для анализа нестационарных временных рядов. Подобная задача с применением нечеткой нейронной сети изложена в работе [2]. В статье [3] разработана стохастическая имитационная модель для нестационарных временных рядов, использующая авторегрессионное вейвлет разложение. Тестирование предложенного метода авторы проводили на климатических данных. Но перечень указанных публикаций в большей степени относится к решению алгоритмических задач, обходя стороной вопросы, связанные с технической реализацией интеллектуальных и адаптивных систем.

**Постановка задачи.** Целью этой работы является разработка информационно-измерительного комплекса, который включает в себя универсальные алгоритмы по обработке полевых измерений и легко интегрируется в систему управления процессом орошения.

**Основная часть.** В исходной постановке задачи можно выделить два направления, требующих детальной проработки. Первое связано с практической реализацией системы сбора информации. За основу нами был принят стандарт IEEE 1451, который описывает конструктивные особенности и базовые принципы работы так называемых “умных” датчиков. В отличие от стандартных, они обладают расширенными функциональными способностями за счет внедрения микроконтроллеров. Например, в условиях удаленной работы и агрессивной внешней среды весьма полезными оказываются функции самодиагностики и самокалибровки. К тому же, при обнаружении неисправностей такой датчик сам оповестит об этом обслуживающий персонал при передаче дополнительной диагностической информации. Это сокращает время на техническое обслуживание и позволяет своевременно устранять возникающие неполадки.

Оценка текущего состояния орошаемого участка поля учитывает множество показателей, таких как температура почвы, влажность почвы, температура воздуха,

скорость ветра, уровень солнечной радиации. Как следствие, приходится использовать различные типы датчиков. На рисунке 1 показана структурная схема измерительной системы (ИС), которая позволяет работать с разными наборами датчиков. Каждый датчик последовательно опрашивается микроконтроллером и выполняется аналого-цифровое преобразование сигнала. Далее следует предварительная обработка данных, которая обеспечивает линейризацию и исключение грубых ошибок. После этого, собранная информация отправляется на ПК по беспроводному каналу связи. Если по каким-либо причинам связь отсутствует, то данные сохраняются на внутреннюю флеш-память. Вся последующая обработка данных производится на ПК, так как для работы сложных алгоритмов требуются более мощные вычислительные ресурсы.

Второе направление обусловлено привлечением современных математических методов в процессы идентификации и управления сложными системами. Как известно, планирование поливных работ и выбор оптимальной оросительной нормы не возможен без оценки внешних климатических факторов. Результаты измерений в основном имеют временную зависимость (реже пространственную), поэтому совокупность данных с одного измерительного датчика рассматривается как временной ряд. Любое измерение подвержено случайным воздействиям, что отражается в виде погрешности, а поведение самих величин носит вероятностный характер и определяется выражением:

$$X = x_i + \xi_i$$

где  $x_i = f(t_i)$  - квазидетерминированная составляющая,  $\xi$  - случайная величина.

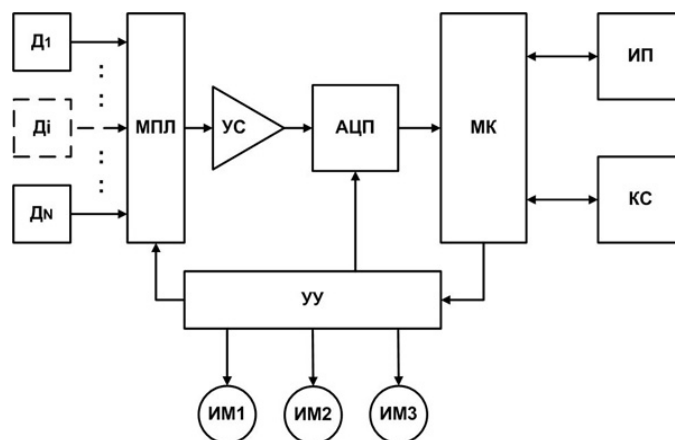


Рисунок 1 - Структурная схема ИС: Д – датчик, МПЛ – мультиплексор, УС – усилитель, АЦП – аналого-цифровой преобразователь, УУ – устройство управления, МК – микроконтроллер, КС – канал связи, ИП – интерфейс пользователя, ИМ – исполнительные механизмы

Для обработки таких сигналов успешно применяется дискретное вейвлет преобразование (ДВП). Основу алгоритма составляет последовательность действий по разложению сигнала на низкочастотную и высокочастотную составляющие с помощью методов цифровой фильтрации [4]. Чтобы найти коэффициенты вейвлет разложения, сигнал пропускается через полуполосные фильтры низкой и высокой частоты с импульсными характеристиками  $H$  и  $G$  соответственно. Выходы фильтров являются результатом операции свертки коэффициентов фильтра с отсчетами входного сигнала:

$$x[n] * h[n] = \sum_m x[m] \cdot h[n - m]$$

После прореживания отсчетов вдвое исходный сигнал распадается на две компоненты: аппроксимирующую ( $A$ ) и детализирующую ( $W$ ). При этом общее число отсчетов составляющих такое же, как и до преобразования. Потом по этой схеме обрабатывается ряд значений  $A$ , после чего весь процесс рекурсивно повторяется до последнего уровня. Выражение (1) - это матричная запись одного уровня дискретного вейвлет разложения. Путем многократного повторение преобразования (1) выполняем декомпозицию сигнала в ряд вейвлет-коэффициентов, где совокупность уровней разложения содержит информацию о частотном диапазоне сигнала.

Обратное вейвлет преобразование позволяет реконструировать функцию по значениям вейвлет-коэффициентов. Полное восстановление сигнала возможно при соблюдении условий корректности расчета фильтров анализа/синтеза и правильного выбора длины сигнала. Чтобы выполнить ДВП без потерь информации, выборка отсчетов цифрового сигнала должна иметь четное количество значений. Для соблюдения этого условия обычно пользуются одним из методов:

- добавление нулей,
- периодизация сигнала,
- симметричное отражение сигнала относительно границы.

$$W = \begin{bmatrix} H \\ G \end{bmatrix} \cdot V = \begin{bmatrix} h_3 & h_2 & h_1 & h_0 & 0 & 0 & \dots & 0 & 0 & 0 & 0 \\ 0 & 0 & h_3 & h_2 & h_1 & h_0 & \dots & 0 & 0 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \dots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & 0 & 0 & \dots & h_3 & h_2 & h_1 & h_0 \\ h_1 & h_0 & 0 & 0 & 0 & 0 & \dots & 0 & 0 & h_3 & h_2 \\ g_3 & g_2 & g_1 & g_0 & 0 & 0 & \dots & 0 & 0 & 0 & 0 \\ 0 & 0 & g_3 & g_2 & g_1 & g_0 & \dots & 0 & 0 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \dots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & 0 & 0 & \dots & g_3 & g_2 & g_1 & g_0 \\ g_1 & g_0 & 0 & 0 & 0 & 0 & \dots & 0 & 0 & g_3 & g_2 \end{bmatrix} \cdot V, \quad (1)$$

где  $g_i = (-1)^i \cdot h_{N-i}$ ,  $i = 0, 1, \dots, N$  - коэффициенты ВЧ фильтра, а  $V^T = [v_0 \ v_1 \ \dots \ v_k]$  - вектор данных на первом уровне, а на последующих - аппроксимирующая составляющая разложения.

Следующий шаг алгоритма направлен на исследование вейвлет спектра. Очевидно, что первые уровни в своем составе имеют как важные для дальнейшего анализа колебательные составляющие сигнала, так и посторонние шумы, вызванные погрешностью средств измерений и случайными флуктуациями. Чтобы разделить полезную информацию и нежелательные шумовые включения, находим статистические характеристики вейвлет-коэффициентов. Эти данные, а также начальные условия задачи являются основополагающими при выборе порога подавления коэффициентов детализации.

Перед выполнением прогнозирования решается задача уменьшения размерности матрицы коэффициентов. Это необходимо для ускорения работы следующих алгоритмов, в частности, уменьшения времени обучения рекуррентных нейронных сетей. В общем случае эта задача сводится к нахождению многообразия меньшей размерности с минимальной потерей информации. Этот принцип реализует метод главных компонент, широко используемый при анализе временных рядов [5]. Пусть матрица данных  $M$  имеет  $i$  строк и  $j$  столбцов, что

обычно трактуется, как множество из  $i$  точек в пространстве размерности  $j$ . Тогда сингулярное разложение для  $M$  запишется в виде:

$$M = UDV^T$$

где столбцы матриц  $U$  и  $V$  являются собственными векторами  $MM^T$  и  $M^T M$  соответственно, а  $D$  - диагональная матрица.

Обозначив  $T = UD$  и  $P = V$ , получаем разложение матрицы  $M$ , как произведение матриц  $T$  и  $P$ :

$$M = TP^T + E, \quad (2)$$

где  $T$ - матрица счетов,  $P$ - матрица нагрузок,  $E$ - матрица остатков.

Условием оптимальности факторизации (2) служит квадратичная норма на матрицу остатков. Размер матриц  $T$  и  $P$  меньше матрицы  $M$ . Чтобы перейти к общей форме метода анализа главных компонент используют нелинейный вид функции для проецирования исходных данных. Такое преобразование реализуется на классе нейронных сетей (НС) с “узким горлом” (Mark A. Kramer, 1991). По своей структуре это сети прямого распространения с четырьмя или пятью слоями, между которыми находится сжимающий слой (рис. 2). После обучения сети выходы среднего слоя соответствуют сжатому вектору входных данных.




Рисунок 2 - Топология репликативной нейронной сети

Алгоритм сжатия данных разбит на несколько действий:

- 1) формирование обучающей выборки векторов из последовательности данных;
- 2) нормализация данных;
- 3) выбор целевой функции;
- 4) выбор метода оптимизации;
- 5) обучение сети.

По функциональному назначению сеть можно условно разделить на две части. Первая половина схемы выполняет нелинейное преобразование над матрицей входных значений и уменьшает размерность данных, а вторая служит для восстановления сжатых данных до исходной размерности. Центральный слой (“узкое горло”) при этом содержит меньшее число нейронов, чем размер вектора входных данных и определяет уровень компрессии. Преобразования во входной части репликативной НС имеют следующий вид:

$$\begin{bmatrix} z_1 \\ \dots \\ z_k \end{bmatrix} = \left[ f_2 \left[ f_1 \left[ \begin{bmatrix} x_1 \\ \dots \\ x_n \end{bmatrix}^T \cdot \begin{bmatrix} w_{11}^{(1)} & \dots & w_{1n}^{(1)} \\ \dots & \dots & \dots \\ w_{m1}^{(1)} & \dots & w_{mn}^{(1)} \end{bmatrix}^T \cdot \begin{bmatrix} w_{11}^{(2)} & \dots & w_{1m}^{(2)} \\ \dots & \dots & \dots \\ w_{k1}^{(2)} & \dots & w_{km}^{(2)} \end{bmatrix}^T \right] \right]^T,$$

где  $f_j$ - функция активации  $j$ -го слоя,  $w$  - весовые коэффициенты нейрона,  $x$  - входной вектор данных,  $z$ - сжатый вектор ( $k < n$ ).

Обратное преобразование во второй части сети соответственно равно:

$$\begin{bmatrix} x_1 \\ \dots \\ x_n \end{bmatrix} = \left[ f_4 \left[ f_3 \left[ \begin{bmatrix} z_1 \\ \dots \\ z_k \end{bmatrix}^T \cdot \begin{bmatrix} w_{11}^{(3)} & \dots & w_{1k}^{(3)} \\ \dots & \dots & \dots \\ w_{r1}^{(3)} & \dots & w_{rk}^{(3)} \end{bmatrix}^T \cdot \begin{bmatrix} w_{11}^{(4)} & \dots & w_{1r}^{(4)} \\ \dots & \dots & \dots \\ w_{n1}^{(4)} & \dots & w_{nr}^{(4)} \end{bmatrix}^T \right] \right]^T.$$

Для слоев 1 и 3 в качестве функций активации выбран гиперболический тангенс:

$$f_1 = f_3 = \tanh(S)$$

Качество обучения определяется нормой:

$$E = \sum_j \sum_i \|D_i - O_i\|^2 \rightarrow \min,$$

где  $D$  и  $O$  - значения входов и выходов сети соответственно.

Так как диапазон выходных значений нейрона с тангенциальной функцией активации ограничен значениями  $-1 \dots 1$ , входные данные предварительно нормализуются согласно выражению:

$$x_i = \frac{X_i - \min(X_i)}{\max(X_i) - \min(X_i)}$$

На заключительном этапе проводится прогнозирование временного ряда. Структура модели, которая описывает поведение стохастического временного ряда, основывается на рекуррентной нейронной сети. Динамические свойства сетей этого класса объясняются введением обратных связей, которые могут охватывать как отдельный слой, так и всю сеть в целом. Таким образом, выход НС зависит не только от значений входного вектора, но и от состояния сети в предыдущие моменты времени.

Такая архитектура сети реализует нелинейную модель авторегрессии со скользящим средним, что соответствует выражению:

$$y(n+1) = f(y(n), \dots, y(n-d+1), u(n), \dots, u(n-m+1)),$$

где  $f$  - нелинейная функция,  $u(n)$  - значение входа в момент времени  $n$ ,  $y(n)$  - значение выхода.

Процесс обучения сети производится в статическом режиме с разомкнутой обратной связью. Эффект прогнозирования достигается за счет введения элементов задержки на входе сети. Вся процедура обучения состоит в подстройке весов сети таким образом, чтобы установить функциональную зависимость между прошлыми значениями ряда и следующим отсчетом выборки. Для этого по всему множеству обучающей выборки необходимо минимизировать среднеквадратичную ошибку между входным и желаемым вектором данных.

Значения обучающей выборки генерируются путем движения скользящего окна вдоль последовательности данных. Размер окна соответствует числу входов сети. Таким образом, смещая окно на один отсчет, мы формируем матрицу

значений входных векторов, а следующее за вектором значение отсчета представляет собой желаемый выход.

**Выводы.** Предложенная измерительная система состоит из распределенной сети датчиков. Они регистрируют текущие параметры агроэко системы, которые используются при принятии управляющих решений в орошаемом земледелии. Алгоритм анализа данных включает в себя четыре основных этапа. Первый этап - это предварительное преобразование данных непосредственно датчиком. Далее следует обработка цифровой последовательности на ПК с вейвлет разложением и исключением случайных компонент, которые соответствуют шуму во входном сигнале. На третьем этапе осуществляется сжатие данных с использованием репликативной нейронной сети. Последний шаг заключается в прогнозировании данных с помощью динамической нейронной сети и восстановлении последовательности по отдельным составляющим вейвлет ряда для получения суммарного прогноза. Представленная в работе структура измерительной системы может быть использована в качестве модуля в схеме управления с предсказанием или как часть системы принятия решений в орошаемом земледелии.

#### **Литература**

1. Hyun-Han Kwon. Stochastic simulation model for nonstationary time series using an autoregressive wavelet decomposition: Applications to rainfall and temperature / Hyun-Han Kwon, Urmanu Lall, and Abedalrazq F. Khalil // *Water Resources Research*. – 2007. – vol. 43. – P. 1–15.
2. Tao Li. A Survey on Wavelet Applications in Data Mining / Tao Li, Qi Li, Shenghuo Zhu, Mitsunori Ogihara // *SIGKDD Explorations*. – 2002. – Volume 4, Issue 2. – P. 49–68
3. Бурнаев Е. В. Об итеративном алгоритме подсчета взвешенных главных компонент / Е. В. Бурнаев, С. С. Чернова // *Информационные процессы*. – 2008. – Т. 8, № 2. – С. 99–107.
4. Дремин И. М. Вейвлеты и их использование / И. М. Дремин, О. В. Иванов, В. А. Нечитайло // *Успехи физических наук*. – 2001. – Т. 171, № 5. – С. 445–501.
5. Чичикалов А. В. Обработка агроклиматических данных с интервальной неопределенностью методом ССА / Чичикалов А. В., Леви Л. И. // *Информационные процессы и технологии «Информатика – 2012» : материалы международной научно-практической конференции молодых ученых и студентов*. – Севастополь, 2012. – С. 13 – 15.