

Турченко В.А., Кочан В.В., Саченко А.А., Головки В.А., Игнатюк О.Н., Triki С.

ПОДХОД К РАЗРАБОТКЕ ПРОГРАММНОГО ОБЕСПЕЧЕНИЯ ВЕРХНЕГО УРОВНЯ ИНТЕЛЛЕКТУАЛЬНОЙ ДИСТРИБУТИВНОЙ СЕНСОРНОЙ СЕТИ

ВВЕДЕНИЕ

Анализ промышленных систем обработки данных лучших мировых фирм производителей [1, 2, 3] показал, что они являются плохой базой для построения систем распределенного измерения и контроля с точки зрения, во-первых, обеспечения высокой точности измерения (включая погрешность сенсора) и, во-вторых, построения сети, обеспечивающей высокую универсальность и адаптивность. Повысить точность измерения физических величин с помощью промышленных сенсоров, то есть компенсировать их погрешность в процессе эксплуатации можно за счет использования методов искусственного интеллекта [4, 5, 6].

В [7] рассматривались основные принципы построения интеллектуальной дистрибутивной сенсорной сети, которая имела возможность адаптироваться к реальным внешним условиям функционирования путем самообучения. Развивая эту проблематику далее, авторы в [8] предложили структуру основного элемента такой сети – интеллектуального узла, который благодаря режиму удаленного перепрограммирования может адаптироваться как к практически любой конфигурации аппаратных средств сети (интерфейсы, протоколы взаимодействия и т.д.), так и к программам обработки данных. Поэтому было предложено использовать данный узел для коррекции погрешностей сенсоров за счет их калибровки или проверки на месте эксплуатации и прогнозирования дрейфа в течении межкалибровочного интервала. Высокое качество прогноза достигается путем использования нейронных сетей [9]. В [8] было показано, что в рамках предложенной ИДСС целесообразно обучение нейронных сетей (НС) осуществлять на верхнем уровне, то есть на наиболее мощном вычислительном компоненте сети – центральном компьютере. Прогнозирование в свою очередь выполняется на среднем уровне – уровне интеллектуального узла, то есть максимально приближается к сенсору. При этом для эффективного решения задачи повышения точности сенсоров важным является обеспечение высококачественного обучения НС. Поэтому ниже рассмотрим особенности проектирования верхнего уровня ИДСС.

1. ОСОБЕННОСТИ ПРОЕКТИРОВАНИЯ ВЕРХНЕГО УРОВНЯ ИДСС

При проектировании верхнего уровня ИДСС следует учитывать особенности, связанные с многоуровневой структурой ИДСС и распределением процедур коррекции по разным уровням системы.

В соответствии с концепцией построения ИДСС [7] верхний уровень играет важную роль в улучшении результата и

технологии измерения, путем использования средств искусственного интеллекта. Так как результат измерения на среднем уровне представлен как значение физической величины с погрешностью, то основной целью выполнения интеллектуальных функций [10] на верхнем уровне является самообучение и самоадаптация всей системы к постоянно меняющимся условиям измерения с целью обеспечения заданной точности. При этом в сети циркулируют только скорректированные результаты измерений, что не только снижает потоки информации в ней, но и обеспечивает использование результатов измерения, сопровождаемых реальным значением погрешности.

Такая структура системы целесообразна для дистрибутивных сенсорных систем и сетей. Однако, для выполнения интеллектуальных функций в ИДСС, в частности процедур самоадаптации и самообучения, на верхнем уровне должны быть обеспечены достаточно мощные вычислительные ресурсы. В данном случае, необходимо одновременное обучение некоторого множества нейронных сетей, индивидуальных для каждого канала сбора данных. Исходя из этого, в качестве центрального компьютера, должен использоваться либо достаточно мощный персональный компьютер, либо высокопродуктивный компьютер с параллельной архитектурой.

Использование нейронных сетей позволяет обеспечить высокое качество прогноза дрейфа сенсоров [9]. Известно, что чем больший размер выборки обучения, тем выше точность прогноза [11]. Однако, на практике, на количество калибровок накладываются технологические ограничения, поэтому их число, как правило, недостаточно для качественного обучения нейронных сетей. Кроме того, задача повышения точности сенсора становится актуальной сразу после начала его эксплуатации. Таким образом, при применении нейронных сетей формируется противоречие. С одной стороны, целью использования нейронных сетей для прогнозирования погрешности сенсоров в ИДСС является увеличение межкалибровочного интервала каналов сбора данных. С другой стороны, результаты калибровок (поверок) служат входными данными для обучения нейронной сети. Суть противоречия состоит в том, что качественное прогнозирование требует качественного обучения нейронной сети, которое в свою очередь требует большого количества входных данных для обучения, то есть увеличения количества калибровок (поверок).

Для разрешения этого противоречия (искусственного увеличения количества точек обучения прогнозирующей нейронной сети) предложено использовать исторические данные – данные о дрейфе однотипных сенсоров в аналогичных условиях эксплуатации, полученные в результате их проверки

Турченко Владимир Александрович. Лаборатория автоматизированных систем и сетей, Институт компьютерных информационных технологий, Тернопольская академия народного хозяйства.

Кочан Владимир Владимирович. Лаборатория автоматизированных систем и сетей, Институт компьютерных информационных технологий, Тернопольская академия народного хозяйства.

Саченко Анатолий Алексеевич. Лаборатория автоматизированных систем и сетей, Институт компьютерных информационных технологий, Тернопольская академия народного хозяйства.

Украина, Тернополь, 46004, пл. Победы 3, тел.: +380 (352) 33-0830, Факс: +380 (352) 33-0024, E-Mail: vtu@tanet.edu.te.ua.

Игнатюк Олег Николаевич. Лаборатория искусственных нейронных сетей, кафедра ЭВМиС Брестского государственного технического университета.

Беларусь, БГТУ, 224017, ул. Московская 267, Факс: +375 (162) 422127, E-mail: gva@brpi.unibel.by.

Chefi Triki. Department of Electronics, Informatics and Systems.

Parallel Computing Laboratory, 87036 Rende - Cosenza, ITALY, Fax: +39 984 494713, E-mail: lugran@unical.it.

или калибровки [9] и дополнительные нейронные сети [12]. Наиболее целесообразно совместное использование этих методов. Очевидно, что наилучшее качество прогноза обеспечивается обучением прогнозирующей нейронной сети на реальных данных о дрейфе (полученных в результате поверок или калибровок). Поэтому, по мере накопления реальных данных в процессе эксплуатации сенсора, они должны вытеснить исторические данные.

Первая поверка нового сенсора позволяет скорректировать начальный разброс его характеристики преобразования. Вторая поверка позволяет получить первое реальное значение дрейфа. Цель использования исторических данных – на основе этого значения дрейфа спрогнозировать значения дрейфа в моменты будущих калибровок. Для этого целесообразно использовать отдельную интегрирующую исторические данные нейронную сеть (ИИДНС). ИИДНС должна прогнозировать значение дрейфа нового сенсора для следующей калибровки на основе исторических данных текущей калибровки. Количество имеющихся исторических данных дрейфа сенсоров определяет структуру входного слоя ИИДНС, при этом для данной НС необходимо специальным образом формировать выборку обучения [13]. Для прогноза можно применить модель однослойного персептрона с линейной функцией активации нейрона.

Однако количество полученных в результате применения всех вариантов ИИДНС значений дрейфа соответствует количеству точек поверки сенсоров, образующих исторические данные, что недостаточно для качественного обучения прогнозирующей нейронной сети (ПНС). Для дополнительного увеличения количества данных обучения прогнозирующей нейронной сети целесообразно использовать аппроксимирующую нейронную сеть (АНС). Она обучается на результатах прогноза, полученных с помощью ИИДНС при шаге обучения, соответствующем шагу поверки сенсоров, обеспечивших получение исторических данных. При ее использовании шаг уменьшается, что обеспечивает получение достаточного объема данных для обучения ПНС. В качестве АНС использован трехслойный персептрон. В качестве ПНС использована трехслойная рекуррентная нейронная сеть, содержащая один скрытый слой нелинейных нейронов и один линейный выходной нейрон.

В начале эксплуатации ИДСС может возникнуть также ситуация, когда нет исторических данных (а тем более реальных данных). В этом случае целесообразно применение гипотетических данных, которые представляют собой обобщенные математические модели дрейфа сенсоров конкретного типа. Эти данные формируются по литературным источникам, результатам научно-технических исследований, информации производителя и т.д. Однако они хуже по сравнению с историческими данными характеризуют дрейф конкретного сенсора в конкретных условиях эксплуатации.

Рассмотренные особенности обуславливают структуру программного обеспечения центрального компьютера верхнего уровня, которую рассмотрим ниже.

2. СТРУКТУРА ПРОГРАММНОГО ОБЕСПЕЧЕНИЯ ВЕРХНЕГО УРОВНЯ ИДСС

Верхний уровень ИДСС, представленный центральным компьютером, оперирует данными на уровне знаний об объекте измерения. На рисунке 1 представлена обобщенная структура программного обеспечения центрального компьютера, которая состоит из двух уровней: базового программного обеспечения (Менеджер НС, Менеджер точности (МТ), Супервизор) и пользовательского программного обеспечения (Менеджер ИДСС, база данных ИДСС). Компоненты (модули) программного обеспечения взаимодействуют между собой по технологии клиент-сервер, причем, как правило, моду-

ли базового уровня выполняют функции модулей-серверов, а модули пользовательского уровня являются клиентами.

Супервизор – ядро программного обеспечения. Он функционирует невидимо для пользователя и осуществляет следующие системные функции: мониторинг процессов, которые происходят в ИДСС, организация взаимодействия между компонентами ПО ЦК в реальном времени, дистанционное перепрограммирование интеллектуальных узлов среднего уровня [8] и т.п. Главной целью использования МТ является обеспечение заданной точности сбора данных сенсоров путем реализации интеллектуальных функций [7]. При этом он формирует запросы: Менеджеру НС – на обучение необходимого множества нейронных сетей; супервизору – на передачу обученных нейронных сетей как математических моделей дрейфа сенсора соответствующему интеллектуальному узлу и т.п. Менеджер нейронных сетей по запросу МТ осуществляет планирование и диспетчеризацию обучения некоторого множества НС и возвращает МТ результат их использования. Менеджер ИДСС – программа пользователя, с помощью которой можно осуществить инициализацию ИДСС и конфигурацию произвольных каналов сбора данных и интеллектуального узла, а также взаимодействие с МТ. Кроме того, с помощью данной программы осуществляется доступ пользователя к базе данных ИДСС, которая содержит информацию об всех элементах каналов сбора данных (сенсоры, коммутаторы, аналого-цифровые преобразователи и т.п.) и интеллектуальных узлах в составе ИДСС.

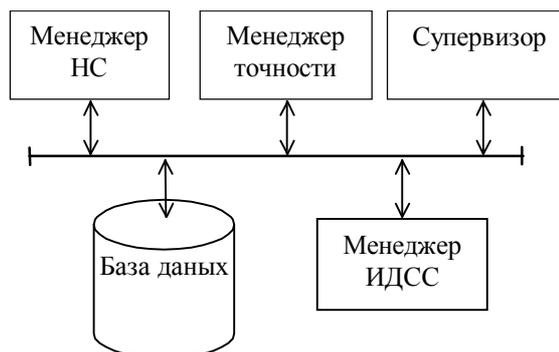


Рисунок 1 – Обобщенная структура ПО ЦК.

Обобщенный алгоритм функционирования модуля-сервера представлен на рисунке 2. Каждый модуль-сервер имеет свою собственную очередь сообщений. Взаимодействие между модулями осуществляется путем записи соответствующего входного запроса в очередь сообщений соответствующей программы-сервера. После завершения обработки входного запроса соответствующий модуль-сервер посылает запрос-ответ серверу или клиенту, который инициировал его работу. Клиентом в данной структуре является программа-Менеджер ИДСС, хотя в различные моменты времени клиентами могут быть модули-серверы.

Необходимость использования архитектуры клиент-сервер обусловлена распределением вычислительных мощностей в ИДСС (см. раздел 1) – обучение НС целесообразно осуществлять на верхнем уровне, а использование НС (прогнозирование, аппроксимация и т.п.) – на среднем. Процесс обучения различных архитектур НС, в частности ИИДНС, АНС, ПНС, требует различного реального времени. Например, на компьютере Р-П-350 время обучения ИИДНС, АНС, ПНС составляет в среднем 6 мин., 2 мин., 10 мин. соответственно, кроме того время обучения в значительной степени зависит от параметров выборки обучения и выбранной архитектуры НС. Поэтому для эффективного использования вычислительных ресурсов центрального компьютера ИДСС его



Рисунок 2 – Обобщенный алгоритм функционирования модуля-сервера.

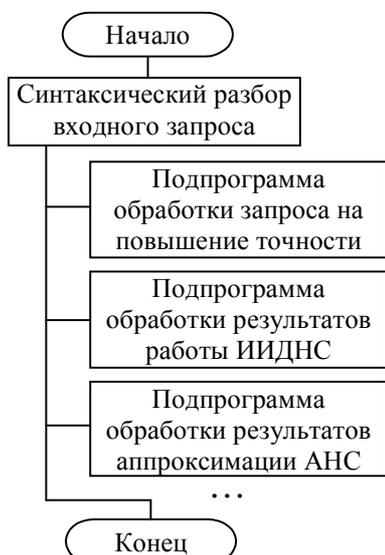


Рисунок 3 – Обобщенный алгоритм функционирования МТ.

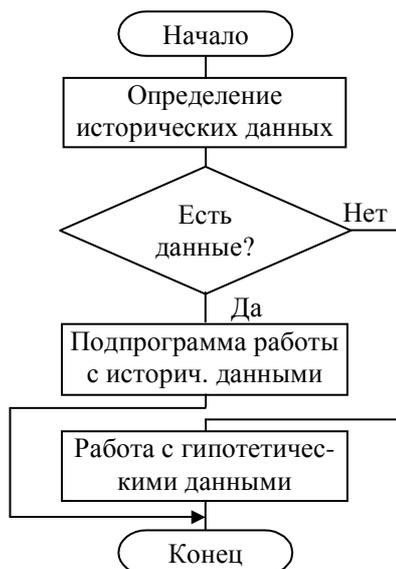


Рисунок 4 – Обобщенный алгоритм подпрограммы повышения точности МТ.

ПО должно быть реализовано в реальном времени, что обеспечивается использованием архитектуры клиент-сервер. Контроль реального времени осуществляет одна из подпрограмм супервизора. Кроме того, такой модульный принцип построения ПО ЦК предполагает легкость наращивания, разработки и замены новых модулей, как на базовом, так и на уровне пользовательском уровне.

Рассмотрим ниже, как на уровне базового программного обеспечения реализуется менеджер точности метод повышения точности сбора данных с использованием НС. Запрос на выполнение процедуры повышения точности может выходить как от супервизора, так и от пользователя путем использования менеджера ИДСС. Обобщенный алгоритм функционирования МТ наведен на рисунке 3, где показаны только те подпрограммы, которые относятся к методу повышения точности. После синтаксического разбора входного запроса загружаются на выполнение подпрограммы его обработки (см. рисунок 3). Подпрограмма обработки запроса на повышение точности (рисунок 4) сначала определяет, есть ли для данного канала ИДСС исторические данные, и в соответствии с этим, осуществляет вызов процедур работы с историческими или гипотетическими данными.

Подпрограмма работы с историческими данными (рисунок 5) находит количество моментов времени определения дрейфа сенсоров N . Во время работы алгоритма для всех N значений формируются выборки обучения для каждого i -го момента времени определения дрейфа. После формирования выборки обучения подпрограмма посылает запрос в очередь сообщений менеджера НС на обучение i -го варианта ИИДНС на i -й выборке обучения. Таким образом, данная подпрограмма формирует выборки обучения для всех N моментов времени определения дрейфа и посылает МНС N запросов на обучение ИИДНС.

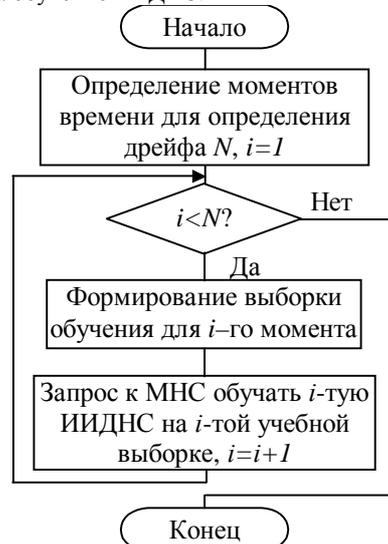


Рисунок 5 – Обобщенный алгоритм подпрограммы работы с историческими данными МТ.

Менеджер НС, получив входной запрос, загружает на обучение несколько архитектур ИИДНС, лучший результат прогнозирования присылает в виде запроса-ответа МТ. Проанализировав входной запрос, МТ загружает на выполнение подпрограмму обработки результатов прогноза ИИДНС (см. рисунок 3). Подпрограмма обработки результатов прогноза ИИДНС (рисунок 6) записывает результат прогнозирования в базу данных ИДСС, и проверяет для всех ли N моментов времени определения дрейфа результаты прогноза записаны в базу данных. Если результаты такого прогноза есть, то данная



Рисунок 6 – Обобщенный алгоритм подпрограммы обработки результатов прогноза ИИДНС в МТ.

подпрограмма формирует запрос к менеджеру НС на обучение АНС. В этом случае выборка обучения для АНС состоит из N прогнозируемых значений дрейфа сенсора в моменты времени его определения.

После этого, менеджер НС, получив входной запрос, загружает на обучение несколько архитектур АНС, лучший результат аппроксимации присылает в виде запроса-ответа МТ. Проанализировав входной запрос, МТ загружает на выполнение подпрограмму обработки результатов аппроксимации АНС (см. рисунок 3). Подпрограмма обработки результата аппроксимации записывает этот результат в базу данных ИДСС, и формирует запрос-ответ супервизору о готовности к использованию математической модели повышения точности по данному каналу сбора данных и о готовности к записи этой модели в соответствующий интеллектуальный узел среднего уровня. Использование ПНС также осуществляется путем вызова менеджера нейронных сетей для увеличения межкалибровочного интервала.

На уровне пользовательского программного обеспечения функционирует менеджер ИДСС и база данных ИДСС. База данных ИДСС состоит из многих файлов, основными из них являются: "Сенсоры", "Коммутаторы", "Измерительные схемы", "Устройства нижнего уровня", "Интеллектуальный

узел", "Конфигурация ИДСС", "Калибровки/поверки" и т.д. Для примера рассмотрим, в виде каких атрибутов сохраняется информация об устройствах нижнего уровня ИДСС (рисунок 7). По атрибутам со звездочкой (*) осуществляется индексирование и поиск информации в базе данных.

На рисунке 8 представлен сценарий диалога подпрограммы конфигурации канала сбора данных ИДСС. Используя эту подпрограмму, пользователь конфигурирует определенный канал сбора данных, предварительно введя в базу данных ИДСС данные о всех составляющих этого канала. Кроме того, здесь можно сразу настроить параметры метода повышения точности для данного канала.

3. ЭКСПЕРИМЕНТАЛЬНЫЕ ИССЛЕДОВАНИЯ

Метод повышения точности с использованием трех нейронных сетей (ИИДНС, АНС, ПНС) был выполнен с использованием экспериментальных данных. Как исторические были использованы 10 кривых дрейфа сенсоров. При обучении ИИДНС достигнута среднеквадратическая ошибка $10E-7$. Относительная погрешность прогнозирования ИИДНС только в одном случае превысила 10%. Для оценки АНС использованы 5 точек калибровок исторических данных. При обучении АНС с 5 скрытыми нейронами и сигмоидной функцией активации достигнута среднеквадратическая ошибка $2.4E-7$. Максимальная относительная погрешность не превысила 2%. Результат аппроксимации состоял из 25 точек на которых

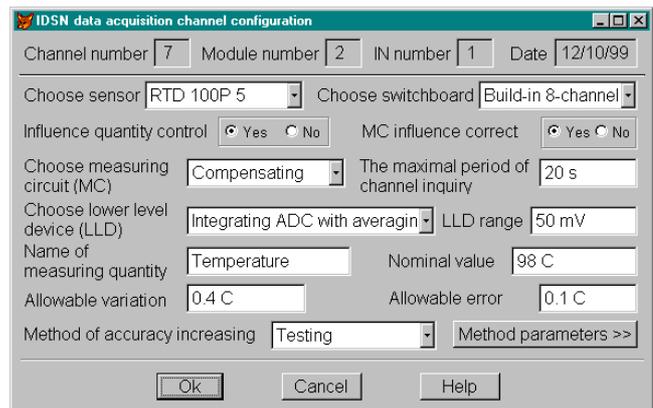


Рисунок 8 – Диалоговое окно конфигурации канала сбора данных ИДСС.

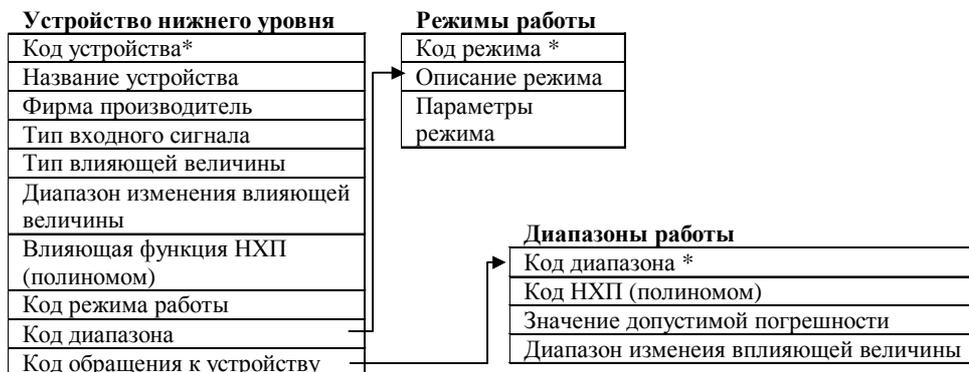


Рисунок 7 – Пример организации одного из файлов базы данных ИДСС.

Таблица 1 – Время обучения для 10 ПНС при последовательном (—) и параллельном обучении (=).

НС	1	2	3	4	5	6	7	8	9	10
—	10,1	3,9	1,2	6,8	1,4	3,9	3,7	0,8	1,8	5,4
=	32,7	26,8	15	45,2	20,9	8,7	30,1	7	20,8	38,4

обучалась ПНС (10 входных нейронов, 10 скрытых нейронов с сигмоидной функцией активации и одним выходным линейным нейроном) до среднеквадратической ошибки обучения $7.8E-8$. Погрешность прогноза ПНС не превысила 11%. Таким образом, использование предлагаемого метода повышения точности позволяет увеличить межкалибровочный интервал в 10 раз при суммарной относительной погрешности 23%.

Для оценки эффективности использования вычислительных ресурсов центрального компьютера обучение нейронных сетей проводилось последовательно и параллельно во времени. В качестве ЦК использовался компьютер с одним процессором Celeron™400. Для 10 ПНС при последовательном обучении время обучения каждой не превышало 11 минут, а суммарное время обучения составляло 39 минут (см. таблицу 1). При параллельном обучении (все 10 нейронных сетей стартовали практически в один момент времени) время обучения каждой увеличилось, и максимальное время не превышало 46 минут.

Как видно из табл. 1, в случае использования в качестве ЦК однопроцессорного компьютера (в большинстве промышленных решений) эффективное использование его вычислительных ресурсов достигается при последовательном обучении НС. Однако потери времени на распараллеливание процесса обучения НС относительно невелики. При этом целесообразно предусмотреть возможность принудительного прерывания процесса обучения НС при нахождении варианта НС с достаточно хорошими параметрами обучения. В этом случае вероятность экономии времени при параллельном обучении НС выше, чем при последовательном обучении.

ВЫВОДЫ

Рассмотренное программное обеспечение верхнего уровня, реализованное по технологии клиент-сервер, обеспечивает: выполнение интеллектуальных функций по отношению к процессу измерения [10]; выполнение процедур повышения точности сбора и обработки данных сенсоров с использованием нейронных сетей; эффективное использование вычислительных ресурсов ЦК в реальном масштабе времени.

БЛАГОДАРНОСТИ

Авторы хотели бы поблагодарить Европейскую организацию ИНТАС, регистрационный номер гранта INTAS-OPEN-97-0606.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. <http://www.fluke.com/products/home.asp?SID=7&AGID=6&PID=5308>.
2. <http://content.honeywell.com/sensing/control/mc/VPR100.stm>.
3. <http://www.dataq.com/di730.htm>.
4. L. Finkelstein, "Measurement and Instrumentation Centre", Measurement, vol. 14, No 1, 1994, pp.23-29.
5. C.Alippi, A.Ferrero, V.Piuri, "Artificial Intelligence for Instruments & Applications", IEEE I&M Magazine, June 1998, pp.9-17.
6. P. Daponte, D. Grimaldi, "Artificial Neural Networks in Measurements", Measurement, vol. 23, 1998, pp.93-115.
7. A.Sachenko, V.Kochan, V.Turchenko, "Intelligent Distributed Sensor Network", Proc. of 15th IEEE IMTC/98, St.Paul, USA, vol.1., 1998, pp.60-66.
8. A.Sachenko, V.Kochan, V.Turchenko, V.Tymchyshyn, N.Vasylykiv, "Intelligent Nodes for Distributed Sensor Network", Proc. of 16th IEEE IMTC/99, Venice, Italy, 1999, pp.1479-1484.
9. Golovko V., Grandinetti L., Kochan V., Laopoulos T., Sachenko A., Turchenko V., "Sensor Signal Processing Using Neural Networks", Proc. of IEEE Region 8 Intern. Conference Africon'99, Cape Town, South Africa, Sep 29-Oct 1, 1999, pp.339-344.
10. V.Golovko, L.Grandinetti, V.Kochan, T.Laopoulos, A.Sachenko, V.Turchenko, V.Tymchyshyn, "Approach of an Intelligent Sensing Instrumentation Structure Development", Proc. of IEEE Int. Workshop on Intelligent Signal Processing, 4-7 Sep 1999, Budapest, Hungary, pp.336-341.
11. Kroese B, An Introduction to Neural Networks, Amsterdam, University of Amsterdam, 1996, 120p.
12. V.Golovko, J.Savitsky, A.Sachenko, V.Kochan, V.Turchenko, T.Laopoulos, L.Grandinetti, "Intelligent System for Prediction of Sensor Drift", Proc. of Inter. Confer. On NN and AI ICCNAI'99, Brest, Belarus, 12-15 Oct 1999, pp.126-135.
13. A.Sachenko, V.Kochan, V.Turchenko, V.Golovko, J.Savitsky, T.Laopoulos, "Method of the training set formation for neural network predicting drift of data acquisition device", Patent of Ukraine, application number 2000010010.