

УДК 621.3; 681.3

В.Турченко; Р.Кочан; А.Карачка, канд. техн. наук

Тернопільська академія народного господарства

## ЗАСТОСУВАННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ ПРОГНОЗУВАННЯ ДРЕЙФУ ХАРАКТЕРИСТИК ПЕРЕТВОРЕННЯ СЕНСОРІВ

*Розглянуто застосування набору нейронних мереж з різними властивостями для підвищення точності збору і обробки сенсорних даних шляхом прогнозування дрейфу характеристик перетворення сенсорів. Запропоновано метод прогнозу дрейфу характеристик перетворення сенсорів на ранній стадії їхньої експлуатації, досліджений шляхом імітаційного моделювання для різного виду дрейфів.*

### Умовні позначення

ПДНМ	нейронна мережа, що інтегрує "історичні" дані;
$d_1, \dots, d_n$	криві, що описують "історичні" дані дрейфу характеристик перетворення сенсорів;
$a, b, c$	моменти калібрувань;
$d_i^a, d_i^b, d_i^c$	значення "історичних" даних $d_i, i = 1 \dots n$ у моменти калібрувань;
$d_k^a, d_k^b, d_k^c$	поправка робочого сенсора в моменти калібрувань $a, b, c$ .

Здебільшого похибка кращих сучасних систем збору і обробки сенсорних даних [1,2] є значно меншою від похибки початкового розкиду характеристик перетворення сенсорів [3...5] часом у десятки разів. Крім цього, для більшості сенсорів дрейф характеристик перетворення під час експлуатації сумірний з їх початковим розкидом [6...8]. Підвищити точність збору даних про фізичні величини можна періодичним калібруванням сенсора спеціальним калібратором або його повіркою з допомогою зразкового сенсора на місці експлуатації [9]. Але операції, що реалізують вищевказані методи, досить трудомісткі. Низьку трудомісткість забезпечує прогнозування дрейфу характеристик перетворення сенсорів. Однак прогноз згідно середнього дрейфу (отриманого у результаті дослідження контрольних сенсорів в умовах, аналогічних умовам експлуатації або в результаті їх калібрувань під час експлуатації) має низьку надійність і не враховує індивідуальних особливостей дрейфу [10]. Трудомісткість забезпечення заданої точності можна знизити прогнозуванням дрейфу характеристик перетворення сенсорів під час міжкалібрувального інтервалу (збільшуючи цим сам міжкалібрувальний інтервал і зменшуючи загальну кількість калібрувань). Значне збільшення міжкалібрувального інтервалу можливе тільки при високоякісному прогнозі. Для цього найбільш ефективним є використання методів штучного інтелекту, зокрема апарату штучних нейронних мереж [11].

Якість навчання нейронних мереж значно залежить від обсягу навчальної вибірки [12]. Це обумовлює основну суперечність, що виникає при використанні нейронних мереж для корекції дрейфу характеристик перетворення сенсорів [11]. Якісне навчання нейронної мережі дозволяє різко знизити похибку прогнозу і настільки збільшити міжкалібрувальний інтервал, що одержана в результаті калібрувань кількість даних буде недостатньою для якісного навчання нейронної мережі. Крім цього, на початку експлуатації, дані для навчання нейронної мережі відсутні. Для усунення цієї суперечності (штучного збільшення кількості точок навчання прогнозуючої нейронної мережі на початку експлуатації сенсора) пропонується використовувати "історичні" дані, тобто дані про дрейф характеристик перетворення однотипних сенсорів в аналогічних умовах експлуатації, одержаних в результаті їхньої повірки або калібрування. Очевидно, що найякісніший прогноз певного сенсора забезпечується навчанням прогнозуючої нейронної мережі на реальних значеннях дрейфу, одержаних

у результаті калібрувань власне цього сенсора. Тому в процесі експлуатації сенсора кількість реальних даних збільшується, і вони мають витіснити "історичні" дані.

Метод прогнозу має адекватно поєднувати загальні тенденції дрейфу характеристик перетворення сенсорів даного типу в даних умовах експлуатації з індивідуальними особливостями дрейфу прогнозованого сенсора. Загальні тенденції дрейфу характеризуються "історичними" даними, а індивідуальні особливості прогнозованого сенсора можна врахувати за результатами його перших калібрувань. Цей процес можна назвати інтеграцією "історичних" даних. Для такої інтеграції пропонується використати набір інтегруючих "історичні" дані нейронних мереж (ПДНМ). Нехай "історичні" дані дрейфу характеристик перетворення сенсорів описуються кривими  $d_1 \dots d_n$  (рис. 1), які в моменти калібрувань  $a, b, c$  дорівнюють  $d_i^a, d_i^b, d_i^c, i = \overline{1, n}$ . Використання реальних даних (результатів калібрувань чи перевірок конкретних сенсорів у певних заданих умовах експлуатації) не дозволяє повною мірою оцінити запропонований метод. Тому експериментальні дослідження доцільно виконати, використовуючи математичні моделі (гіпотетичні дані [11]) дрейфу характеристики перетворення сенсора. Дрейф характеристики перетворення сенсора (див. рис. 1.) вимірюється умовними одиницями (за віссю ординат) в залежності від відносного часу експлуатації сенсора (за віссю абсцис).




Рис. 1. "Історичні" дані про дрейф характеристики перетворення сенсорів.

Перше калібрування нового сенсора (в момент 0) дозволяє скорегувати початковий розкид характеристики його перетворення. Друге калібрування в момент  $a$  дозволяє одержати реальне значення дрейфу  $d_k^a$ . Метою використання "історичних" даних є прогнозування ряду точок  $d_k^b, d_k^c$  і т.д., які відповідали б значенням дрейфу сенсора в моменти наступних калібрувань на точці  $d_k^a$ . Завдання ПДНМ – спрогнозувати точку  $d_k^b$  за точками  $d_k^a$  і  $d_i^a, i = \overline{1, n}$ , наступну точку  $d_k^c$  за точками  $d_k^b$  і  $d_i^b, i = \overline{1, n}$  і т.д. Тому кількість наявних точок калібрувань "історичних" даних визначає кількість варіантів ПДНМ, а кількість кривих "історичних" даних визначає кількість нейронів вхідного рівня ПДНМ.

Для навчання ПДНМ навчальну вибірку необхідно сформувати наступним чином:

1. Одну з кривих дрейфу характеристик перетворення сенсора  $d_i$  вважаємо реальною,

всі інші  $d_j$ ,  $j = \overline{1, i-1}$ ,  $j = \overline{i+1, n}$  - "історичними" даними. Таким чином, в момент  $a$  реальні дані імітуються  $d_i^a$ , а у момент  $b$  -  $d_i^b$ .

2. Визначаємо абсолютні відхилення в моменти  $a$  точки  $d_i^a$  від всіх інших  $d_j^a$   
 $\Delta ij = |d_i^a - d_j^a|$ , де  $i = \overline{1, n}$ ,  $j = \overline{1, i-1}$ ,  $j = \overline{i+1, n}$ .
3. Сортуємо всі одержані на кроці 2 абсолютні відхилення за зменшенням, знаходимо максимальне  $\Delta ij^{\max} = \max \Delta ij$  і мінімальне значення  $\Delta ij^{\min} = \min \Delta ij$ .
4. Формуємо множину векторів навчання шляхом розміщення значень  $d_j^a$  за спаданням.

Для інтеграції даних використано моделі однорівневого та багаторівневого перцептронів (рис. 2а і рис. 2б відповідно). Однорівневий перцептрон складається з одного нейрона, який перетворює інформацію та вхідного рівня нейронів, що виконують розподільні функції. Вихідне значення однорівневого перцептрона

$$y_o = \sum_{i=1}^N x_i w_i - T_o,$$

де  $x_i$  - вхідні значення нейронної мережі,  $w_i$  - вагові коефіцієнти (синапси) входів нейрону, що перетворює інформацію,  $T_o$  - поріг (зміщення) нейрона. При навчанні однорівневого перцептрона використано правило навчання Відроу-Хоффа [13], детально алгоритм навчання розглянуто в [11, 14]. Багаторівневий перцептрон складається з трьох рівнів нейронів: вхідного, схованого та вихідного. Схований та вихідний рівні обробляють інформацію, вхідний рівень нейронів є розподільним. Вихідне значення багаторівневого перцептрона

$$y_o = F_o \left( \sum_{j=1}^M w_{jo} \cdot F_h \left( \sum_{i=1}^N x_i w_{ij} - T_{hj} \right) - T_o \right),$$

де  $F_o(x)$  та  $F_h(x)$  - функції активації (перетворення) нейронів вихідного і схованого рівня відповідно;  $w_{jo}$  - синапси між 1.. $M$  нейронами схованого рівня і вихідним нейроном;  $x_i$  - вхідні значення нейронної мережі;  $w_{ij}$  - синапси входів нейронів схованого рівня (між розподільним і схованим рівнем);  $T_{hj}$  - пороги нейронів схованого рівня;  $T_o$  - поріг вихідного нейрона. Для навчання багаторівневого перцептрона використано алгоритм зворотного поширення помилки [15] з адаптивним кроком навчання, що детально розглянуто у [16].

Кожен окремий варіант ПДНМ навчається окремо. Після навчання на вхід першого варіанту ПДНМ надходить значення дрейфу  $d_k^a$  (результат калібрування сенсора). Перший варіант ПДНМ прогнозує значення дрейфу  $d_k^b$  для моменту наступного калібрування. Значення  $d_k^b$  є вхідним для другого варіанту ПДНМ для здійснення прогнозу  $d_k^c$  і т.д. Таким чином, вже в момент другого калібрування сенсора можна одержати прогноз значення його дрейфу в точках, які відповідають моментам калібрування сенсорів, що входять в "історичні" дані. Цей прогноз враховує загальні тенденції дрейфу характеристик перетворення сенсорів даного типу й індивідуальні особливості дрейфу конкретного сенсора.

Однак кількість одержаних в результаті використання всіх варіантів ПДНМ значень дрейфу відповідає кількості точок калібрування сенсорів, що утворюють "історичні" дані. Звичайно, ця кількість ще не достатня для якісного навчання прогнозуючої нейронної мережі. Для додаткового збільшення кількості даних навчання прогнозуючої нейронної мережі доцільно використати ще одну нейронну мережу – апроксимаційну. Вона навчається на результатах прогнозу, одержаних з допомогою ПДНМ при кроці навчання, який відповідає крокові калібрування сенсорів, що входять

в "історичні" дані. При її використанні крок зменшується, що забезпечує одержання достатньої для навчання прогнозуючої нейронної мережі кількості даних.




Рис. 2. Структура інтегруючої "історичні" дані нейронної мережі:  
(а) - однорівневий перцептрон; (б) - багаторівневий перцептрон.

Похибка прогнозу дрейфу характеристик перетворення сенсорів з допомогою запропонованого методу має три складові: (i) похибка інтегрування "історичних" даних; (ii) похибка апроксимації результатів інтеграції дрейфу в точках калібрування сенсора; (iii) похибка прогнозування результатів апроксимації на майбутній час експлуатації сенсора. Похибка інтеграції "історичних" даних є похибкою прогнозу дрейфу  $d_k^b, d_k^c$  і т.д. у наступних точках калібрування  $b, c, \dots, n$  за результатами другого калібрування в момент часу  $a$  (див.рис.1). Експериментальні дослідження проводилися шляхом імітаційного моделювання на комп'ютері Pentium-II-350. Як "історичні" дані використовувалися математичні залежності, що моделюють різні види можливого дрейфу характеристик перетворення сенсорів. Для кожного виду дрейфу формувалися 10 кривих даних дрейфу. В процесі дослідження кожна з 10 кривих вважається реальним дрейфом сенсора, а решта - служать для формування навчальних вибірок ПДНМ. Таким чином, на 10 кривих одержуємо 10 залежностей похибок інтеграції "історичних" даних. Оскільки на момент інтеграції даних дрейфу перше і друге калібрування вже проведені, то доцільним є дослідження похибки інтеграції, починаючи з моменту третього калібрування.

На рис. 3 подано перший набір кривих дрейфу характеристик перетворення сенсорів, що моделюють дрейф "з насиченням" (швидкість дрейфу протягом часу експлуатації зменшується). Дрейф такого виду досить простий, і для інтеграції даних можна використати модель однорівневого перцептрону з лінійною функцією активації нейрона. Для 10 досліджуваних кривих використано 9 входовий однорівневий перцептрон (див. рис. 2а). При дослідженнях середньоквадратична помилка навчання становила  $10^{-5}$ , тривалість навчання для кожної кривої не перевищила 3 сек. Максимальна і середня відносні похибки інтеграції даних не перевищували 7% і 3% відповідно (рис. 4.).

На рис. 5 подано другий набір кривих, що моделюють дрейф "з прискоренням" (швидкість дрейфу протягом часу експлуатації збільшується). Для інтеграції даних такого дрейфу використано нейронну мережу, аналогічну попередній. Середньоквадратична помилка навчання становила  $10^{-6}$ , середня тривалість процесу навчання для кожної кривої не перевищувала 12 секунд. Максимальна і середня відносні похибки інтеграції даних не перевищували 25% і 8% відповідно (рис. 6.).

На рис. 7 подано третій набір кривих, які моделюють комбінацію двох попередніх видів дрейфів (для одної частини сенсорів швидкість дрейфу збільшується, а для іншої – зменшується). Такий вид дрейфу для більшості сенсорів не є характерним, однак доцільно дослідити можливості методу також і для таких даних. У цьому

випадку модель однорівневого персептрона не дає прийнятних результатів. При експериментах використано модель трирівневого персептрона (див. рис. 26). Вхідний (розподільний) рівень включав 9 нейронів, схований рівень – 9 нейронів (з сигмоїдною функцією активації), вихідний рівень складався з одного лінійного нейрона. Процес навчання ПДНМ для комбінованого дрейфу характеризувався нестабільністю, деякі ПДНМ поводитися по-різному. Тому навчання кожної нейронної мережі обмежувалося значенням середньоквадратичної помилки  $10^{-4}$  і кількістю епох 30000. Слід відзначити, що кращу збіжність виявив алгоритм багатократного поширення помилки [16]. Середня тривалість процесу навчання для кожної кривої не перевищувала 100 сек. Максимальна і середня відносні похибки інтеграції даних не перевищували 52% і 30% відповідно (рис. 8).

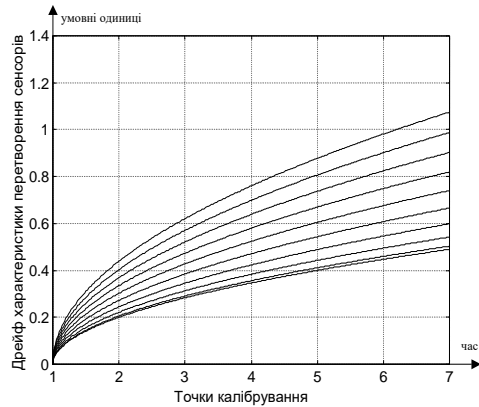


Рис. 3. Набір гіпотетичних даних про дрейф "з насиченням".

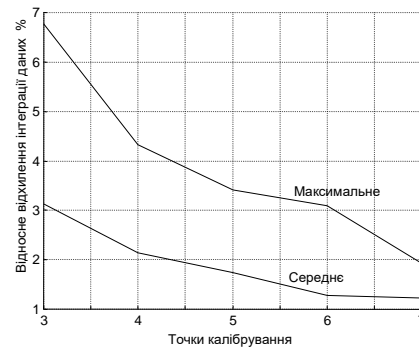


Рис. 4. Відносні відхилення інтеграції даних дрейфу "з насиченням".




Рис. 5. Набір гіпотетичних даних про дрейф "з прискоренням".

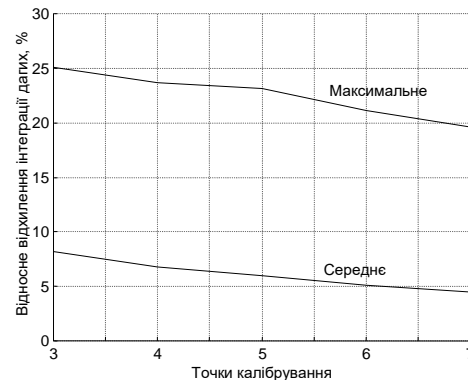


Рис. 6. Відносні відхилення інтеграції дрейфу "з прискоренням".

На рис. 9 подано четвертий набір кривих, аналогічний попередньому, але зі збільшеними швидкостями дрейфу. Цей вид дрейфу досліджувався для визначення границь можливостей запропонованого методу. Для інтеграції даних такого дрейфу використана модель трирівневого персептрону, аналогічна описаній вище. Процес навчання кожної ПДНМ обмежувався значенням середньоквадратичної помилки  $10^{-5}$  і кількістю епох 40000. Середня тривалість навчання для кожної кривої не перевищувала 190 сек. Максимальна і середня відносні похибки інтеграції даних для третьої точки калібрування не перевищували 70% і 50% відповідно (рис. 10). Для наступних точок калібрування ці значення зменшуються, але значні похибки інтеграції на початку експлуатації визначають обмеження запропонованого методу.

Далі результати інтеграції "історичних" даних апроксимуються додатковою апроксимаційною нейронною мережею. Для цього використана модель трирівневого персептрона з одним вхідним нейроном, 5 схованими нейронами (з сигмоїдною функцією активації) і одним лінійним вихідним нейроном. При навчанні була досягнута середньоквадратична помилка  $2.4 \cdot 10^{-7}$ . Дослідження на поданих вище результатах

інтеграції виявили, що відносна похибка апроксимації значно нижча від похибки інтеграції [14]. Так, наприклад, для дрейфу "з насиченням" максимальна відносна похибка апроксимації у точках калібрувань 3...7 не перевищувала 2% (рис. 11). Результат апроксимації мав 25 точок, на яких навчалася прогноуюча нейронна мережа. Як прогноуюча використана рекурентна нейронна мережа з 10 вхідними нейронами, 10 схованими нейронами (з сигмоїдною функцією активації) і одним вихідним лінійним нейроном [14]. Максимальна відносна похибка прогнозування для середньоквадратичної помилки навчання  $10^{-7}$  не перевищувала 11% (рис. 12).

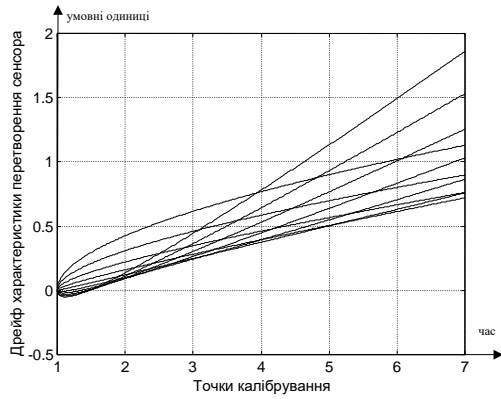


Рис. 7. набір гіпотетичних даних про комбінований дрейф.




Рис. 8. Відносні відхилення інтеграції комбінованого дрейфу.




Рис. 9. набір гіпотетичних даних про комбінований дрейф з збільшеною швидкістю.




Рис. 10. Відносні відхилення інтеграції комбінованого дрейфу із збільшеною швидкістю.

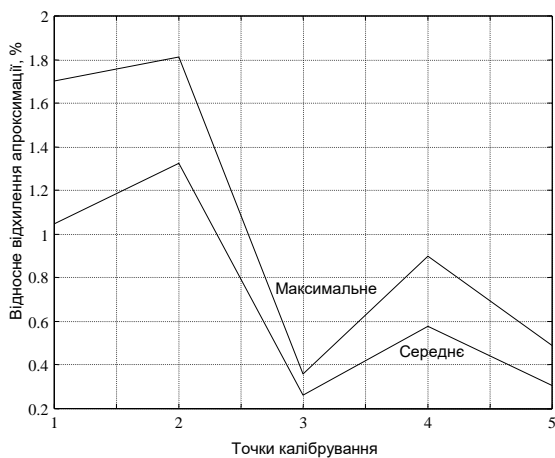


Рис. 11. Результати апроксимації дрейфу характеристик перетворення сенсорів.

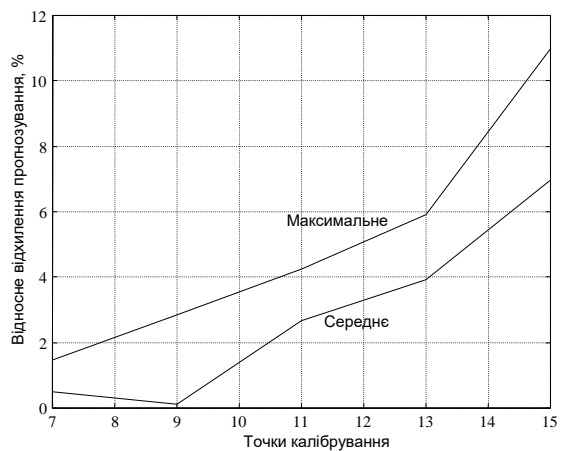


Рис. 12. Результати прогнозу дрейфу характеристик перетворення сенсорів.

Таким чином, запропонований метод прогнозу дрейфу характеристик перетворення сенсорів дозволяє значно збільшити міжкалібрувальний інтервал при одночасному підвищенні у декілька разів точності збору даних про фізичну величину.

Його використання особливо ефективно на ранній стадії експлуатації сенсорів. Похибка збору даних знижується за рахунок самоадаптації каналу збору і обробки сенсорних даних до процесу дрейфу характеристик перетворення сенсорів. Самоадаптація забезпечується взаємодією нейронних мереж з різними властивостями. Цей метод можна успішно використати в інтелектуальних дистрибутивних ієрархічних системах [17, 18], в яких навчання нейронних мереж ведеться на верхньому рівні, а прогнозування – на нижніх рівнях.

*The proposed method of conversion characteristics prediction of sensor drift allows providing error reduction of physical quantity measurement in intelligent systems by self-adaptation. The self-adaptation is provided by interaction of neural networks with various properties. The proposed method allows successfully to predict various kinds of conversion characteristics of sensor drift and to reduce sensor errors on early stage of their exploitation. This method successfully can be used in intelligent distributed systems, where neural network training is performed on the higher system's level and properly prediction is performed on the lower level.*

Автори висловлюють подяку за підтримку Європейській організації ІНТАС, реєстраційний номер гранту INTAS-OPEN-97-0606.

#### Література

1. www.fluke.com/products/data\_acquisition/hydra/home.asp?SID=7&AGID=0&PID=5308
2. www.thermo-electra.com
3. DIN IEC 751
4. DIN IEC 584-2
5. DIN 43710
6. www.sensym.com
7. Левин И.Я., Рогельберг И.Л. Исследование сплавов для термопар // Сб. тр. института Гипроцветметобработка. - М.: Металлургия, 1971. Вып.32. - 93 с.
8. Саченко А.А. Мильченко В.Ю. Чырка М.И. Экспериментальные исследования нестабильности градуировочных характеристик термоэлектрических преобразователей градуировки хромель алюмель // "Измерительная техника". – 1985. - N 10. - С. 28-29
9. J. Brignell. "Digital compensation of sensors", Scientific Instruments, 1987, №9, - P. 1097-1102.
10. Саченко А.С. Разработка методов повышения точности и создание систем прецизионного измерения температур в промышленных технологиях. -Дисертация на соискание степени д.т.н. - Ленинград, 1988. - 417с.
11. Golovko V., Grandinetti L., Kochan V., Laopoulos T., Sachenko A., Turchenko V. Sensor Signal Processing Using Neural Networks // Proc. IEEE Region 8 Intern. Conf. Africon'99. - Cape Town (South Africa). – 1999. - P. 339-344.
12. Kroese B. An Introduction to Neural Networks. - Amsterdam: University of Amsterdam. - 1996. - 120 p.
13. Widrow B., Hoff M. Adaptive Switching Circuits // In 1960 IRE WESCON Conversion Record. – DUNNO. – 1960. - P. 96-104.
14. A.Sachenko, V.Kochan, V.Turchenko, V.Golovko, J.Savitsky, A.Dunets, T. Laopoulos. Sensor Errors Prediction Using Neural Networks // Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks (IJCNN'2000). - Como (Italy). - 2000. - Vol. IV, P. 441-446.
15. Rumelhart D., Hinton G., Williams R. Learning representation by backpropagation errors // Nature. – 1986. – No 323. – P. 533-536.
16. V.Golovko, J.Savitsky, A.Sachenko, V.Kochan, V.Turchenko, T.Laopoulos, L.Grandinetti. Intelligent System for Prediction of Sensor Drift // Proc. Intern. Conf. Neural Networks and Artificial Intelligence (ICNNAI'99). – Brest (Belarus). – 1999. – P. 126-135.
17. A.Sachenko, V.Kochan, V.Turchenko, T.Laopoulos, V.Golovko, L.Grandinetti. Features of Intelligent Distributed Sensor Network Higher Level Development // Proceedings of 17th IEEE Instrumentation and Measurement Technology Conference (IMTC/2000). – Baltimore (USA). – 2000. - P. 335-340.
18. V.Golovko, L.Grandinetti, V.Kochan, T.Laopoulos, A.Sachenko, V.Turchenko, V.Tymchyshyn. Approach of an Intelligent Sensing Instrumentation Structure Development // Proc. IEEE Intern. Workshop on Intelligent Signal Processing (WISP'99). – Budapest (Hungary). – 1999. – P. 336-341.

Одержано 14.08.2000 р.