

УДК 620.179

І. Б. Івасенко

КЛАСИФІКАЦІЯ ЛОКАЛІЗОВАНИХ ДЕФЕКТІВ ЗВАРНИХ ШВІВ НА РЕНТГЕНІВСЬКИХ ЗОБРАЖЕННЯХ ТРУБ

New relevant features are proposed for defect classification on joint weld on scanned X-ray films of tubes. A multi-layer perceptron neural network was trained for classification of porosity and slag inclusions.

Запропоновано нові інформативні ознаки для класифікації дефектів у зоні зварного шва на сканованих рентгенівських зображеннях труб. Проведено навчання тришарового перцептронну для розпізнавання сферичних пор та шлаків.

Задачею радіографічного контролю зварних швів труб є детектування і класифікація дефектів на плівці зварного шва [2]. Основними причинами утворення дефектів є порушення технології складання, зварювання, застосування невідповідних матеріалів, неправильний вибір режимів зварювання, низька кваліфікація зварника. Дефектами прийнято називати відхилення від норм, передбачених стандартами і технічними умовами на зварні з'єднання.

Всі типи дефектів зварних з'єднань можна поділити на чотири групи: за розміщенням, формою, розмірами і кількістю. За розміщенням розрізняють дефекти зовнішні, внутрішні і наскрізні. За формою компактні і протяжні, плоскі і об'ємні, гострі (з надрізом) і округлі (без надрізу). За розмірами – малі, середні і великі. За кількістю – одиничні і групові (ланцюжки, скупчення). До зовнішніх дефектів відносяться порушення форми, розмірів і зовнішнього виду швів: нерівномірна ширина шва по його довжині, нерівномірна висота шва, нерівномірні катети кутових швів, підрізи, напливи, пропали, незаварені кратери. Утворення внутрішніх дефектів при зварюванні пов'язано з металургійними, термічними і гідродинамічними явищами, що відбуваються у процесі формуванні зварного шва. До внутрішніх дефектів відносяться тріщини, непровари, пори та шлакові включення.

Дослідження на цю тему можна поділити на групи за метою роботи: виділення інформативних ознак [9, 11, 12, 15] та класифікація знайдених дефектів [7, 8, 10, 13, 16, 17, 19].

Якобсен використовував декілька ознак для розпізнавання тріщини, підрізу та відсутності дефекту [6]. Пернер дослідила методи класифікації, зокрема нейронні мережі та дерева рішень. Її система розпізнавала тріщини, підрізи та відсутність дефекту [14]. Фехер представив метод класифікації пор, підрізів та непроварів за допомогою правил [5]. Проте цей метод не може класифікувати малі дефекти, що слабо відрізняються від фону. Аокі та Суга використали 10 параметрів, щоб охарактеризувати дефекти та класифікували їх за п'ятьма класами за допомогою нейронної мережі [4]. Навчання проводилося лише на 35 дефектах а тестування на 27. Ванг та Ліао використовували 108 дефектів для навчання і 12 – для тестування класифікації шести можливих дефектів [18]. Сільва також використовував нейронну мережу для класифікації дефектів з навчанням на 50 дефектах [17]. Ін та Тіан вибрали 13 ознак для класифікації дефектів за допомогою нейронної мережі [19].

Метою роботи є дослідження відомих та вибір нових інформативних ознак для розпізнавання дефектів зварних швів труб двох класів: сферичних пор та шлаків (рис. 1).

© І. Б. Івасенко, 2009




Рис. 1. Зображення сферичних пор (ряд 1) та шлаків (ряд 2).




Рис. 2. Ілюстрація геометричних параметрів.

Після локалізації дефектів визначаємо їх геометричні та текстурні параметри: площу ($Area$), периметр (P), велику та малу вісь апроксимованого еліпса ($MajorAL$ та $MinorAL$), ширину та висоту описаного прямокутника (W та L), максимальний діаметр (D_{max}) та радіус (R_{max}) вписаного кола, дисперсію, середньоквадратичне відхилення, абсолютне відхилення, контрастність (рис. 2). Далі обчислюємо такі параметри:

1. Анізотрія. Ця величина є пропорційною видовженості об'єкта.

$$Ani = \frac{MajorAL}{MinorAL}.$$

2. Компактність. Коли об'єкт круглий, то ця величина прямує до 1.

$$Comp = \frac{4\pi Area}{P^2}.$$

3. Ректангулярність. Коли об'єкт – прямокутник, то ця величина прямує до 1.

$$Rect = \frac{Area}{WBB \times HBB}.$$

4. Дисперсія об'єкта. $VarOb = \frac{1}{Area - 1} \sum_{g(i,j) \in O} (g(i,j) - \bar{g})^2$, де $g(i,j)$ – функція інтенсивності зображення; \bar{g} – середнє значення функції інтенсивності зображення.

5. Дисперсія фрагмента зображення. $VarFr = \frac{1}{AreaF - 1} \sum_{g(i,j) \in F} (g(i,j) - \bar{g})^2$,

де $AreaF$ – площа фрагмента зображення.

6. Середньоквадратичне відхилення об'єкта.

$$\sigma_O = \sqrt{\frac{1}{Area - 1} \sum_{g(i,j) \in O} (g(i,j) - \bar{g})^2}.$$

7. Середньо-квадратичне відхилення фрагменту зображення.

$$\sigma_F = \sqrt{\frac{1}{AreaF-1} \sum_{g(i,j) \in F} (g(i,j) - \bar{g})^2}.$$

8. Абсолютне відхилення об'єкта. $AdevO = \frac{1}{Area} \sum_{g(i,j) \in O} |g(i,j) - \bar{g}|.$

9. Абсолютне відхилення фрагмента зображення.

$$AdevF = \frac{1}{AreaF} \sum_{g(i,j) \in F} |g(i,j) - \bar{g}|.$$

10. Асиметрія. $Skev = \frac{1}{Area} \sum_{g(i,j) \in O} \left(\frac{g(i,j) - \bar{g}}{\sigma_O} \right)^3.$

11. Експес. $Kurt = \left\{ \frac{1}{Area} \sum_{g(i,j) \in O} \left(\frac{g(i,j) - \bar{g}}{\sigma_O} \right)^4 \right\}.$

12. Індекс видовженості. $I_a = \pi \times D_{\max}^2 / (4Area).$

13. Індекс девіації до вписаного кола. $I_r = 1 - \pi R_{\max}^2 / Area.$

14. Видовженість. $Elong = \frac{L}{W}.$

Для локалізації та сегментації дефектів застосовано алгоритм, який використовує багатомасштабну функцію інформативності для локалізації об'єктів та подальшої сегментації виділеної області [3]. Вибір областей уваги здійснюється за допомогою локальної функції зображення, що приймає більші значення в точках, що належать об'єкту, ніж в точках фону. Розглянемо область об'єкту $O(i, j)$, яка є структурним елементом круглої форми, з центром в точці (i, j) і область $B(i, j)$, яка є фоном навколо об'єкта. Спочатку для кожного вікна обчислюємо робастні оцінки функції інтенсивності зображення області об'єкту $G_O^k(i, j)$ та фону $G_B^k(i, j)$ для всіх значень параметру масштабу k . Для зменшення обчислювальної складності вибрано кусково-постійну модель функції інтенсивності зображення. Робастна оцінка інтенсивності θ для області, що складається з n пікселів вибирається як найкраща оцінка по всіх можливих підвибірках довжиною $(n+1)/2$:

$$\theta = \arg \min_{\theta_c} \{d(\xi_c, \theta_c); c = 1, \dots, C_n^{(n+1)/2}\},$$

де θ_c – коефіцієнт регресії, що відповідає підмножині ξ_c ; $d(\cdot)$ – функція похибки коефіцієнтів поліноміальної регресії.

Для класифікації локалізованих дефектів застосували штучну нейронну мережу, а саме, тришаровий перцептрон з алгоритмом зворотного поширення. Вектор вхідних ознак охоплює чотирнадцять елементів. Всі інформативні ознаки були пронормовані. Приховані шари складаються з 15–27 елементів. Навчання проводили на 80 дефектах, тестування – на 30 випадково вибраних дефектах, що належать двох класів: сферична пора та шлак. Експериментальні дослідження виявили, що найбільша середня (за 10-ма експериментами) ймовірність правильної класифікації (86%) досягається при використанні 23 нейронів у прихованих шарах (таблиця 1).

Для підвищення ймовірності правильної класифікації запропоновано такі інформативні ознаки:

15. Контрастність фрагмента зображення [1]

$$CF = \sum_{L=0}^{L_{\max}} |2(L - \bar{L}) + L_{\max} - |2(L - \bar{L}) - L_{\max} || H(L) / 2L_{\max} NM \cdot$$

де L – інтенсивність елементів зображення ($L \in [0, L_{\max}]$); L_{\max} – максимальне значення інтенсивності на зображенні; \bar{L} – середнє значення інтенсивності зображення; $H(L)$ – гістограма розподілу інтенсивностей; N, M – висота та ширина зображення.

Таблиця 1. Ймовірність правильної класифікації на основі 14-ти інформативних ознак

| № експерименту \ К-сть нейронів | 15 | 17 | 19 | 21 | 23 | 25 | 27 |
|---------------------------------|------|-------|------|-------|------|-------|------|
| 1 | 0,75 | 0,9 | 0,75 | 0,7 | 0,9 | 0,85 | 0,8 |
| 2 | 0,9 | 0,9 | 0,75 | 0,8 | 0,95 | 0,85 | 0,75 |
| 3 | 0,65 | 0,8 | 0,85 | 0,95 | 0,8 | 0,75 | 0,8 |
| 4 | 0,8 | 0,7 | 0,85 | 1 | 0,95 | 0,75 | 0,7 |
| 5 | 0,85 | 0,8 | 0,8 | 0,8 | 0,8 | 0,85 | 0,95 |
| 6 | 0,95 | 0,8 | 0,75 | 0,6 | 0,8 | 0,85 | 0,8 |
| 7 | 0,65 | 0,9 | 0,8 | 0,75 | 0,95 | 0,8 | 0,8 |
| 8 | 0,8 | 0,8 | 0,8 | 0,75 | 0,9 | 0,9 | 0,7 |
| 9 | 0,85 | 0,9 | 0,8 | 0,7 | 0,65 | 0,9 | 0,95 |
| 10 | 0,7 | 0,85 | 0,75 | 0,8 | 0,9 | 0,85 | 0,85 |
| Середнє значення | 0,79 | 0,835 | 0,79 | 0,785 | 0,86 | 0,835 | 0,81 |
| Мінімальне значення | 0,65 | 0,7 | 0,75 | 0,6 | 0,65 | 0,75 | 0,7 |
| Максимальне значення | 0,95 | 0,9 | 0,85 | 1 | 0,95 | 0,9 | 0,95 |

16. Контрастність об'єкта

$$CO = \sum_{L=0}^{L_{\max}} |2(L - \bar{L}) + L_{\max} - |2(L - \bar{L}) - L_{\max} || H(L) / (2L_{\max} Area).$$

17. Контрастність контуру об'єкта – середній перепад інтенсивностей в точках контуру зображення.

18. Середньоквадратичне відхилення контрастності контуру об'єкта.

Експериментальні дослідження показали, що найбільша середня (за 10-ма експериментами) ймовірність правильної класифікації (95%) досягається при використанні 21 нейрону у прихованих шарах (таблиця 2).

Таблиця 2 . Ймовірність правильної класифікації на основі 18-ти інформативних ознак

| № експерименту \ К-сть нейронів | 19 | 21 | 23 | 25 | 27 |
|---------------------------------|------|-------|-------|------|-------|
| 1 | 0,85 | 0,95 | 0,85 | 0,95 | 0,85 |
| 2 | 0,85 | 0,8 | 1 | 0,8 | 0,85 |
| 3 | 0,75 | 0,95 | 1 | 0,9 | 0,9 |
| 4 | 0,85 | 1 | 0,95 | 0,9 | 0,95 |
| 5 | 0,9 | 0,75 | 0,9 | 0,95 | 1 |
| 6 | 0,95 | 0,95 | 0,9 | 0,95 | 0,95 |
| 7 | 0,75 | 1 | 0,85 | 0,8 | 0,8 |
| 8 | 0,85 | 0,8 | 0,85 | 0,85 | 0,9 |
| 9 | 0,95 | 0,9 | 0,95 | 0,75 | 1 |
| 10 | 0,9 | 0,95 | 0,9 | 0,85 | 0,85 |
| Середнє значення | 0,86 | 0,905 | 0,915 | 0,87 | 0,905 |
| Мінімальне значення | 0,75 | 0,75 | 0,85 | 0,75 | 0,8 |
| Максимальне значення | 0,95 | 1 | 1 | 0,95 | 1 |

Запропонований метод апробовано на вибірці, що складається з 110 дефектів. За допомогою нових інформативних ознак підвищено ймовірність правильної класифікації від 86 до 95%. Метою подальших досліджень є визначення інформативних ознак для інших класів дефектів.

1. Воробель Р. А. Сприйняття сюжетних зображень та кількісна оцінка їх контрасту на основі лінійного опису визначення контрастності елементів // Доп. НАН України. – 1998. – № 9. – С. 103–108.
2. ГОСТ 7512–82 Контроль неразрушающий. Соединения сварные. Радиграфический метод.
3. Івасенко І. Б. Алгоритм локалізації та сегментації об'єктів у радіографічних зображеннях на основі функції інформативності // Відбір і обробка інформації. – 2002. – № 16. – С. 83–86.
4. Aoki K., Suga Y. Application of artificial neural network to discrimination of defect type in automatic radiographic testing of welds // ISIJ International. – 1999. – **39**, № 10. – P. 1081–1087.
5. Feher Z. Computer aided processing of industrial radiographs // Periodica Polytechnica Ser. El. Eng. – 2001. – **44**, №3–4. – P. 241–248.
6. Jacobsen C. and Zscherpel U. Automated evaluation of digitized radiograph with neuronal methods // Proc. Computed Tomography for Industrial Application and Image Processing in Radiology. – 1999. – P. 141–152.
7. Liao T. W. Classification of weld flaws with imbalanced class data // Expert Systems with Applications: An International Journal – 2008. – **35**, № 3. – P. 1041–1052.
8. Lim T. Y., Ratnam M. M. and Khalid M. A. Automatic classification of weld defects using simulated data and an MLP neural network // Insight. – 2007. – **49**, № 3. – P. 154–159.
9. Mery D., Berti M. A. Automatic detection of welding defects using texture features // Insight. – 2003. – **45**, № 10. – P. 676–681.
10. Mitchell H. B. Pattern recognition using type-II fuzzy sets // Information Sciences–Informatics and Computer Science: An International Journal. – 2005. – **170**, № 2–4. – P. 409–418.
11. Statistical tools for weld defect evaluation in radiographic testing / N. Nacereddine, L. Hamami, M. Tridi, N. Oucief // Proc. 9th European Conf. in Non Destructive testing, ECNDT. – 2006.
12. Classification of welding defects in radiographs using traversal profiles to the weld seam / G. X. Padua, R. R. Silva, M. H. S. Siqueira, J. M. A. Rebello, L. P. Caloba // 16th World Conf. on nondestructive testing. – Montreal: WCNDT, 2004. – P. 90–91.
13. Detection and classification of weld defects in radiographic images: Part III – phenomenological analysis / G. X. Pádua, R. Silva, D. Mery, M. H. S. Siqueira, J. M. A. Rebello, L. P. Caloba // Materials Evaluation. – 2008. – 66(2). – P. 145–149.
14. Perner P., Zscherpel U., Jacobsen C. A comparison between neural network and decision trees based on data from industrial radiographic testing // Pattern Recognition Letters. – 2001. – **22**. – P. 47–54.
15. A Novel Tool For Automated Evaluation Of Radiographic Weld Images / C. Rajagopalan, B. Venkatraman, T. Jayakumar, P. Kalyanasundaram, R. Baldev // Proc. 16th World Conf. on NDT. – 2004.
16. Pattern Recognition of Weld Defects Detected by Radiography Test / R. R. Silva, L. P. Calôba, M. H. S. Siqueira, J. M. A. Rebello // NDT & E International. – 2004. – 37(6). – P. 461–470.
17. Estimated accuracy of classification of defects detected in welded joints by radiographic tests / R. R. Silva, M. H. S. Siqueira, M. P. V. Souza, J. M. A. Rebello, L. P. Calôba. – NDT & E International, UK, 2005. – **38**. – P. 335–343.
18. Wang G., Liao T. W. Automatic identification of different types of welding defects in radiographic images // NDT&E International. – 2002. – **35**. – P. 519–528.
19. Yin Y., Tian G. Y. Feature Extraction and Optimisation for X-ray Weld Image Classification // Proc. 17th World Conf. on Nondestructive Testing. – 2008.
20. Defect Identification and Classification for Digital X-Ray Images / Y. Yin, G. Y. Tian, G. F. Yin, A. M. Luo // E-Engineering and Digital Enterprise Technology. – 2008. – № 3. – P. 543–547.