

УДК 004.93

**В. А. Емельянов**, канд. техн. наук

## МОДЕЛИРОВАНИЕ НЕЙРОННЫХ СЕТЕЙ РАСПОЗНАВАНИЯ МЕТАЛЛОГРАФИЧЕСКИХ ИЗОБРАЖЕНИЙ ДЛЯ ДИАГНОСТИКИ СОСТОЯНИЯ СТАЛЕЙ

**Аннотация.** Проанализирована проблема автоматизации технической диагностики состояния сталей. Описана актуальность разработки новых методов и средств автоматизированной диагностики состояния сталей. Предложен алгоритм предварительной обработки металлографических изображений. Разработаны нейронные сети распознавания металлографических изображений на основе MLP и RBF парадигм. Приведены результаты моделирования нейронных сетей распознавания металлографических изображений для диагностики состояния сталей.

**Ключевые слова:** нейронные сети, распознавание изображений, изображение микроструктуры стали, металлографический анализ

**V. A. Iemelianov**, PhD.

## NEURAL NETWORKS MODELING FOR METALLOGRAPHIC IMAGE RECOGNITION TO DIAGNOSE STEELS CONDITION

**Abstract.** The problem of the steel technical diagnostic automation was analyzed. The urgency to develop new methods and means of automated diagnostics steels is shown. The algorithm of metallographic images pre-processing was proposed. The neural network structures of the metallographic images recognition, which based on RBF and MLP paradigms, were developed. The neural network modeling results of the metallographic image recognition for diagnosis the steel technical conditions are shown.

**Keywords:** neural networks, image recognition, steel microstructure image, metallographic analysis

**В. О. Ємельянов**, канд. техн. наук

## МОДЕЛЮВАННЯ НЕЙРОННИХ МЕРЕЖ РОЗПІЗНАВАННЯ МЕТАЛОГРАФІЧНИХ ЗОБРАЖЕНЬ ДЛЯ ДІАГНОСТИКИ СТАНУ СТАЛЕЙ

**Анотація.** Проаналізовано проблему автоматизації технічної діагностики стану сталей. Описана актуальність розробки нових методів і засобів автоматизованої діагностики стану сталей. Запропоновано алгоритм попередньої обробки металографічних зображень. Розроблено нейронні мережі розпізнавання металографічних зображень на основі MLP і RBF парадигм. Наведено результати моделювання нейронних мереж розпізнавання металографічних зображень для діагностики стану сталей.

**Ключові слова:** нейронні мережі, розпізнавання зображень, зображення микроструктури сталі, металографічний аналіз

### Введение

Современное состояние промышленности передовых стран во многом зависит не только от ассортимента выпускаемой продукции, но и от показателей ее качества. В производственном цикле необходимо как можно раньше выявить появление брака и произвести коррекцию технологического процесса.

Глобализация технической диагностики предусматривает увеличение количества диагностических операций и технологий для контроля качества и технического состояния сплавов и изделий для достижения технологической безопасности, которая в свою очередь требует разработки технических средств и информационных технологий.

Высокотехнологичные предприятия в целях выявления брака и повышения качества изделий предприятия постоянно увеличивают объемы операций технической диагностики изделий. Для решения проблемы технической диагностики металлов, в частности сталей, используются объективные физические методы контроля состояния изделия, такие как методы неразрушающего контроля и металлографический анализ [1 – 3]. Суть металлографического анализа сводится к диагностике состояния стали на основе распознавания изображений их микроструктур.

### Постановка задачи

Среди наиболее значительных работ в области автоматизации металлографического анализа можно выделить работы отечественных ученых А.С. Яковлева, М.С. Филинова, А.А. Чубова, а также работы зарубежных ученых, результаты, работы которых

изложены в [2, 4, 5]. Кроме того, автоматизацией металлографического анализа в настоящее время занимается ряд зарубежных и отечественных фирм: "SIAMS", "Video-Test" (Спб:Питер), "VisionPE" [6 – 8]. Следует отметить высокий уровень автоматизации металлографического анализа программных разработок, представленных данными фирмами, особенно в части распознавания изображений микроструктур металлов разных марок.

Однако в этих работах не решены вопросы комплексной автоматизированной диагностики состояния сплавов по всем характеристикам (химический состав, структура, свойства), а рассмотренные в них методы позволяют проводить лишь количественный металлографический анализ. Кроме того, большинство существующих решений в данной области ориентированы на определенные виды металлов и не обеспечивает обучения системы диагностике новых марок металлов. Таким образом, актуальной является задача разработки новых алгоритмических и инструментальных средств автоматизированного металлографического анализа с возможностью их обучения диагностике новых марок металлов.

### Предварительная обработка металлографических изображений

Изображение микроструктуры стали формируется посредством специального металлографического микроскопа, подключенного к компьютеру. Полученное полутоновое изображение микроструктуры сплава  $f(x, y)$  подвергается бинаризации.

Для бинаризации металлографических изображений предлагается использование метода с изменяющим порогом преобразования [9]. Необходимость учитывать найденные пороги для ближайших участков вызвана тем, что необходимо минимизировать возможные ошибки в местах с сильными дефектами изображения микроструктур.

После бинаризации необходимо определить информативные признаки изображения. Как известно [9, 10], с точки зрения распознавания и анализа объектов на изображении наиболее информативными являются не значения яркостей объектов, а

характеристики их границ – контуров. Другими словами, основная информация заключена не в яркости отдельных областей, а в их очертаниях. Таким образом, задача выделения контуров состоит в построении изображения именно границ объектов и очертаний однородных областей. Следовательно, далее производится выделение границ сегментов и определение базовых точек изображения фильтром Превитта (как наиболее помехоустойчивым фильтром согласно [11, 12]) следующим образом.

Задаются маски фильтра Превитта

$$H_x = \begin{pmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{pmatrix}, H_y = \begin{pmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{pmatrix}. \quad (1)$$

Потом следует разбиение изображения на матрицы размером  $3 \times 3$

$$A = \begin{pmatrix} a_1 & a_2 & a_3 \\ a_4 & a_5 & a_6 \\ a_7 & a_8 & a_9 \end{pmatrix}, \quad (2)$$

где  $a_1 \dots a_9$  – показывают уровень серого цвета каждого пикселя в матрице.

Далее производится расчет  $X$  и  $Y$  по формулам

$$\begin{cases} X = -1 \cdot a_1 + 1 \cdot a_3 - 1 \cdot a_4 + 1 \cdot a_6 - 1 \cdot a_7 + 1 \cdot a_9 \\ Y = 1 \cdot a_1 + 1 \cdot a_2 + 1 \cdot a_3 - 1 \cdot a_7 - 1 \cdot a_8 - 1 \cdot a_9 \end{cases}. \quad (3)$$

На завершающем этапе вычисляется градиент Превитта по формуле

$$G_p = \sqrt{X^2 + Y^2}. \quad (4)$$

Базовыми точками будут являться точки границ сегментов, которые необходимы для формирования сегмента на основе отрезков.

Далее определяются базовые точки, а затем сегменты, которые описывают изображение (рис. 1).

Элементы сегмента строятся при помощи гипотенуз треугольников, которые формируются посредством перпендикуляров, опущенных из двух соседних базовых точек, как проиллюстрировано на рис. 1.




Рис. 1. Сегмент анализируемого изображения микроструктуры сплава

Описывается проиллюстрированный сегмент значениями функций  $\sin$  и  $\cos$  углов  $A$  и  $B$ .

Результат предварительной обработки приведен на рис. 2.



Рис. 2. Результат предварительной обработки изображения микроструктуры стали

Далее распознавание предлагается проводить с помощью нейронных сетей, что позволит разрабатываемым средствам придать свойство обучаемости для предоставления возможности диагностики состояния разных марок сталей.

Набор всех значений функций  $\sin(A)$ ,  $\cos(A)$  и градиента Превитта  $Gp$ , которые характеризуют базовые точки изображения и его сегменты, является входным сигналом для моделируемых нейронных сетей.

### Моделирование MLP и RBF нейронных сетей распознавания металлографических изображений

Имитационное моделирование проведено в пакете Statistica Neural Networks (SNN) компании StatSoft, который предоставляет быстрые и эффективные методы нейросетового моделирования и анализа.

Структура MLP нейронной сети определения количественных характеристик сталей, таких как балл зерна [13, 14] приведена на рис. 3.

Предлагается количество нейронов во входном слое принимать равным среднему количеству базовых точек на изображениях микроструктур сталей для данного типа анализа. Величина скрытого слоя вычисляется делением на три количества нейронов входного слоя, поскольку в скрытом слое производится сегментация изображения на основе базовых точек сегментов, т.е. для каждой точки сегмента вычисляется характеризующее её аппроксимируемое значение на основе параметров базовых точек. Размер выходного слоя определяется количеством марок сталей для распознавания.




Рис. 3. Структура моделируемой MLP нейронной сети

После выбора структуры нейронной сети необходимо ее обучить. Для решения был выбран алгоритм обратного распространения ошибки (back propagation) [15]. Для алгоритма обратного распространения необходимо, чтобы активационная функция была дифференцируема на всем участке. Предлагается использовать сигмоидальную активационную функцию, поскольку она удовлетворяет данному условию [16]:

$$y_i = \frac{1}{1 + e^{-x_i}}. \quad (5)$$

Чтобы измерить качество распознавания, производилось вычисление среднеквадратической ошибки

$$E = \frac{1}{n} \sum_{i=1}^n (y_i - y(k_i))^2, \quad (6)$$

где  $E$  – ошибка распознавания;  $y_i$  – значение  $i$ -го выхода сети при распознавании изображения;  $y(k_i)$  – значение  $i$ -го эталонного выхода сети, которое соответствует классу изображения.




Рис 4. Графики изменения зависимостей ошибок обучения  $E_L$  и распознавания  $E_G$  MLP-сетей

Как видно из рис. 4, с определенного момента значение ошибки распознавания начинает увеличиваться, что объясняется явлением переобучения нейронной сети. Для предотвращения процесса переобучения обучающее множество изображений микроструктур разбито на два множества: обучающее и контрольное. В результате этого на основании графиков изменений ошибок определено оптимальное количество эпох обучения, которое составило 830 для данной

структуры нейронной сети. При этом среднеквадратическая ошибка (СКО)  $E=0,1060348$ .

Обучение нейронной сети производилось на основе эталонных изображений микроструктур металлов, описанных в ГОСТ 5639-82, ГОСТ 1778-70, ГОСТ 8233-56 и др. Обучающая выборка составила 580 изображений микроструктур металлов, при этом из них 290 «корректных» и 290 «некорректных». Под «корректными» понимаются изображения эталонных микроструктур сплавов, а под «некорректными» примеры искаженных шумами изображений эталонов, что как следствие ведет к неправильному распознаванию (классификации) изображения нейронной сетью. Таким образом, нейронная сеть также обучалась неверному распознаванию, т.е. реагированию на некорректные изображения.

В качестве контрольной выборки использовалось 580 изображений микроструктур сплавов из базы данных микроструктур металлов и сплавов [17].

Таким образом, были спроектированы нейронные сети с разными структурами для соответствующих ГОСТов. Например, нейронная сеть для определения балла зерна по ГОСТ 5639-82 имеет структуру 510-170-10, т.е. 510 нейронов во входном слое, 170 в скрытом и 10 в выходном слое.

Во время исследований было отобрано всего 15 MLP нейронных сетей (НС) на основе критерия минимума ошибки в учебной и контрольной выборках.

Кроме MLP сетей, в данном исследовании было отобрано 15 лучших RBF НС (рис. 5). В этих сетях нейроны скрытого слоя реализуют функции, которые радиально изменяются вокруг выбранного центра и принимают ненулевые значения только в окрестности этого центра. Нейрон такой сети имеет  $n$ -мерный вход и  $n$ -мерный вектор весов, т. е. выходом нейрона является значение функции радиального вида от аргумента, равного расстоянию между исходным вектором и вектором весов. Под функцией радиального вида рассматривается простой Гасиан. Выход нейрона определяется формулой

$$\varphi\left(\left\|\overline{xy}\right\|\right), \text{ где } \varphi(x) = \exp(-bx^2), \quad (7)$$

$$0 < \varphi(x) < 1, \forall x \in R.$$

Значения на выходе нейрона тем больше, чем ближе исходный вектор к вектору весов. Если расстояние нулевое, то выход нейрона принимает максимальное значение (единицу).

Полученные результаты моделирования нейронных сетей представлены на рисунках 5 и 6.

Type	Error	Inputs	Hidden
RBF	0.5121263	510	85
RBF	0.5209527	510	85
RBF	0.2053227	510	170
RBF	0.1442291	510	170
RBF	0.3970534	510	85
RBF	0.1323711	510	170
RBF	0.2080733	510	170
RBF	0.2398564	510	102
RBF	0.3041921	510	102
RBF	0.3920584	510	85
RBF	0.3823711	510	102
RBF	0.2080233	510	102
RBF	0.1592564	510	102
RBF	0.2310617	510	102
RBF	0.2030722	510	102

Рис. 5. Список лучших вариантов структурной организации НС на основе RBF

Значения ошибки лучшей RBF-сети 0,1323711 и соответственно 0,1060348 у MLP. Количественные результаты распознавания выборки металлографических изображений сетями MLP и RBF представлены в таблице. Промоделированной MLP-сетью корректно распознано металлографических изображений на несколько процентов больше чем RBF -сетью.

1. Сравнительная таблица результатов распознавания моделированными MLP и RBF сетями

Тип металлографического изображения	Выборка	Корректное распознавание сетями MLP и RBF, %	
		MLP	RBF
Изображения сталей 10XCHД, 20XГСА, 30XГТ для определения балла зерна согласно ГОСТ 5639-82	Учебная	100	100
	Контрольная	95,5	95,1
	Тестовая	98,6	96,5
Изображения сталей 10XCHД, 20XГСА, 30XГТ для определения балла ферритного зерна согласно ASTM E 1382	Учебная	100	100
	Контрольная	94,1	94,5
	Тестовая	97,8	97

Type	Error	Inputs	Hidden
MLP	0.1937201	510	170
MLP	0.1060348	510	170
MLP	0.2842685	510	170
MLP	0.1227490	510	170
MLP	0.4292595	510	85
MLP	0.2037271	510	170
MLP	0.1766348	510	170
MLP	0.2248685	510	102
MLP	0.4297492	510	102
MLP	0.4292590	510	85
MLP	0.4044036	510	102
MLP	0.3947747	510	102
MLP	0.2901744	510	102
MLP	0.3900806	510	85
MLP	0.4173006	510	85

Рис. 6. Список лучших вариантов структурной организации НС на основе MLP

Критерием оценки достоверности распознавания использована статистическая достоверность. Для оценки статистической достоверности была проведена серия экспериментов, что позволило определить количественный показатель достоверности по формуле

$$D = \frac{N}{N_{\Sigma}}, \quad (8)$$

где  $N, N_{\Sigma}$  – количество корректно распознанных изображений и их общее количество соответственно.

## Выводы

На основании изложенного можно сделать следующие выводы.

1. Разработанные архитектуры MLP и RBF позволяют проводить распознавание металлографических изображений сталей с высоким процентом достоверности распознавания (до 97,8 %). Применимость нейронных сетей проверена на основе анализа изображений микроструктур сталей марок 10ХСНД, 20ХГСА, 30ХГТ.

2. В результате моделирования более высокий процент корректного распознавания показали нейронные MLP-сети.

3. Применение нейронных сетей при распознавании металлографических изображений позволяет проводить анализ разных видов марок сталей за счет свойства обучаемости.

## Список использованной литературы

1. Bramfitt B. L., and Bencotter Arlan O. *Metallographer's Guide – Practices and Procedures for Iron and Steels*, (2002), ASM International, 354 p.

2. Богомолова Н. А. *Практическая металлография* / Н. А. Богомолова. – М. : Высшая школа, 1987. – 240 с.

3. Шульте Ю. А. *Комплексный контроль качества конструкционной стали* / Ю. А. Шульте. – К. : Техника, 1986. – 125 с.

4. Hosseini H., Shamaniana M., and Kermanpura A. *Characterization of Microstructures and Mechanical Properties of Inconel 617/310 Stainless Steel Dissimilar Welds*, (2011), *Materials Characterization*, Vol. 62, Issue 4, pp. 425 – 431.

5. Wang Zhiping, Lu Yang, Wu Chenwed, Xu Jianlin, and Yang Xinzhuang. *Castiron Metallographic Structure by Computer Picture Processing System*, (1997), *Journal of Cansu University of Technology*, Vol. E-1, No. 1, pp. 29 – 32.

6. VideoTesT Ltd “Application of Image Analysis Software “VideoTesT – Morphology” in Mycology, Phytopathology and Industrial Microbiology” [Internet Source], available at: <http://www.videotest.ru/en/article/view/48/category/11> (26.08.2007).

7. VisionPE Metlab Corporation. *Image Analysis*, [Internet Source], available at: [http://www.metlabcorp.com/image\\_analysis.html](http://www.metlabcorp.com/image_analysis.html) (31.01.2009).

8. SIAMS: Index of/products/siams700 [Internet source], available at: <http://www.siams.com/products/siams700/> (14.01.2013).

9. Chen C. H., Rau L. F, and Wang P. S. P (eds.). *Handbook of Pattern Recognition and Computer Vision*, (1995), Singapore–New Jersey–London–Hong Kong: World Scientific Publishing Co. Pte. Ltd., 984 p.

10. Pratt W. K. *Digital Image Processing*, 3rd ed., (2001), USA: John Wiley & Sons, 750 p.

11. Gonzalez R. S., and Woods R. E. *Digital image processing*, 2nd ed., (2002), USA, Prentice, 703 p.

12. Емельянов В. А. Нейросетевой метод определения количественных характеристик металлов / В. А. Емельянов // *Радиоелектронні і комп'ютерні системи*. – 2010. – № 4(45). – С. 169 – 173.

13. Гонтовой С. В. Автоматизированная компьютерная система металлографического контроля качества металлов / С. В. Гонтовой, В. А. Емельянов // *Радиоелектронні і комп'ютерні системи*. – 2010. – № 5(46). – С. 197 – 202.

14. Werbos P. J. *Backpropagation and Neurocontrol: A Review and Prospectus*, (1989), *Proc. of International Joint Conf. On Neural Networks*. – Washington, DC., Vol. 1, pp. 209 – 216.

15. Suzuki Kenji. *Artificial Neural Networks: Architectures and Applications*, (2013), InTech, 256 p.

16. База данных микроструктур металлов и сплавов [Электронный ресурс] – Режим доступа: <http://www.microstructure.ru/rudbview>. (31.01.2007).

Получено 03.10.2013

## References

1. Bramfitt B.L., and Bencotter A. (2002), *Metallographer's Guide – Practices and Procedures for Iron and Steels*, ASM International, USA (In English).

2. Bogomolova N.A. *Prakticheskaia metallografiia* [Practice Metallography], (1987), *High School Publ.*, Moscow, Russian Federation (In Russian).
3. Shulte Yu.A. *Kompleksnyi kontrol kachestva konstrukcionnykh stali* [Comprehensive Quality Control of the Constructional Steel], (1986), Kiev, Ukraine, *Technics Publ.* (In Russian).
4. Hosseini H., Shamaniana M., and Kermapura A., (2011), Characterization of Microstructures and Mechanical Properties of Inconel 617/310 Stainless Steel Dissimilar Welds, *Materials Characterization Journal*, Vol. 62, Issue 4, pp. 425 – 431 (In English).
5. Wang Z., Lu Y., Wu C., Xu J., and Yang X. (1997), Castiron Metallographic Structure by Computer Picture Processing System, *Journal of Cansu University of Technology*, Vol. E-1, No.1, pp. 29 – 32 (In English).
6. VideoTesT Ltd., (2007), “Application of Image Analysis Software “VideoTesT–Morphology” in Mycology, Physiopathology and Industrial Microbiology” (in English), available at: <http://www.videotest.ru/en/article/view/48/category/11> (accessed 26 August 2007).
7. VisionPE (2009), VisionPE Metlab Corporation. Image Analysis, (In English), available at: [http://www.metlabcorp.com/image\\_analysis.html](http://www.metlabcorp.com/image_analysis.html) (accessed 31 January 2009).
8. SIAMS (2013), Index of /products/siams700, (In Russian), available at: <http://www.siams.com/products/siams700> (accessed 14 January 2013).
9. Chen C.H., Rau L.F., and Wang P.S. (1995), Handbook of Pattern Recognition and Computer Vision, *World Scientific Publishing Co. Pte. Ltd.*, Singapore–NewJersey–London–Hong Kong (In English).
10. Pratt W.K. *Digital Image Processing*, 3rd ed., (2001), John Wiley & Sons, USA (In English).
11. Gonzalez R.S., and Woods R.E. *Digital Image Processing*, 2nd ed., (2002), *Prentice, USA* (In English).
12. Iemelianov V. *Neirosetevoi metod opredeleniia kolichestvennykh kharakteristik metallov* [Neural Method for Determining the Quantity Characteristics of Metals], (2010), *Radioelectronic and Computer Systems Journal Publ.*, Vol. 4(45), pp.169 – 173 (In Russian).
13. Gontovoi S.V., and Iemelianov V. *Avtomatizirovannaia komputernaia sistema metallograficheskogo kontroliia kachestva metallov* [Automated Computer System of Metallographic Checking of Metals Quality], (2010), *Radioelectronic and Computer Systems Journal Publ.*, Vol. 5(46), pp. 197 – 202 (In Russian).
14. Werbos P.J. *Backpropagation and Neurocontrol: A Review and Prospectus*, (1989), *Proc. of International Joint Conf. On Neural Networks*, Washington, DC Vol. 1, pp. 209 – 216 (In English).
15. Suzuki K. *Artificial Neural Networks: Architectures and Applications*, (2013), *InTech*, Winchester, Hampshire, 256 p. (In English).
16. *Metals database Baza dannykh mikrostruktur metallov i splavov* [Metals and Alloys Microstructures Database] (In Russian), available at: <http://www.microstructure.ru/rud-bvview> (accessed 31 January 2007).



Емельянов  
Виталий Александрович,  
к.т.н., доц. кафедры ин-  
формационных техноло-  
гий и систем Севасто-  
польского ин-та банков-  
ского дела, Ун-та банков-  
ского дела нац. банка  
Украины, ул.Парковая, 6,  
г. Севастополь, 99057,  
тел. (0692) 53-96-11  
e-mail:  
v.yemelyanov@gmail.com