

Гибридная нейронная сеть для классификации маммографических изображений¹

А.Ю. Маковецкий*, В.И. Кобер**, С.М. Воронин*, А.В. Воронин*,
В.Н. Карнаузов**, М.Г. Мозеров**

* Челябинский государственный университет, Челябинск, Россия

** Институт проблем передачи информации, Российская академия наук, Москва, Россия

Поступила в редколлегию 19.10.2023

Аннотация—Важным этапом решения задачи классификации и сегментации 2D-изображений является извлечение локальных геометрических особенностей. Сверточные нейронные сети в последние годы широко используются для решения задач в этой области. Обычно окрестность каждого пикселя изображения используется для сбора локальной геометрической информации. Сверточная нейронная сеть используется для извлечения основных геометрических особенностей окрестности. В этой статье мы предлагаем нейронную сеть на основе конкатенации дескрипторов двух известных нейронных сетей для решения задачи извлечения локальных геометрических особенностей маммографических изображений. Для повышения точности классификации маммограмм используется фильтрация признаков на основе вычисления совместной информации. Результаты компьютерного моделирования представлены для иллюстрации эффективности предлагаемого метода.

КЛЮЧЕВЫЕ СЛОВА: Сверточная нейронная сеть, сегментация, классификация, совместная информация

DOI: 10.53921/18195822_2023_23_4_415

1. ВВЕДЕНИЕ

Раннее выявление рака молочной железы с помощью рентгеновских изображений требует работы квалифицированных врачей-рентгенологов. Нехватка высококвалифицированных рентгенологов может потребовать выполнения более сложной и трудоемкой процедуры диагностики на основе биопсии молочной железы [1, 2, 3]. Таким образом, существует необходимость в автоматизированных методах оценки скрининговых маммограмм [4]. В последние годы нейросетевые алгоритмы произвели революцию в интерпретации диагностических изображений [5]. Сверточные нейронные сети (CNN) являются наиболее распространенным типом сетей для анализа 2D изображений [6]. По сравнению с традиционными методами скрининга, компьютерные диагностические системы, использующие CNN, обеспечивают более точную классификацию изображений [7]. CNN широко используется для обнаружения рака молочной железы при различных типах визуализации рака молочной железы, таких как УЗИ, магнитно-резонансная томография (МРТ) и рентгенография. В работе [8] предложена гибридная CNN система, основанная на ультразвуковых изображениях для диагностики рака молочной железы путем извлечения функций из Alexnet, MobilenetV2 и Resnet50, а затем, после их объединения, отбора признаков. Метод использовался для выбора лучших признаков. Эта система использовала алгоритмы машинного обучения для векторной машины (SVM) и метода k-ближайших соседей (k-NN) в качестве классификатора [9]. Метод сегментации изображений используется

¹ Работа выполнена при частичной поддержке Российского научного фонда (грант 22-19-20071).

для разделения изображений груди на подобласти, за которыми следует метод распознавания объектов, который использует методы извлечения, отбора и классификации признаков для автоматического обнаружения субрегионов, связанных с раком молочной железы. В статье [10] предложен метод сегментации рака молочной железы с использованием семантической классификации и объединения фрагментов. Подход включает в себя обрезку интересующей области, ее улучшение с помощью фильтров и методов кластеризации, извлечение признаков и классификацию с помощью нейронной сети и классификатора k-NN.

В наборе данных DDSM используются [11] предварительно обученные модели CNN, InceptionV3 и ResNet50, чтобы различать доброкачественные и злокачественные маммограммы, были использованы методы transfer learning, предварительной обработки и увеличения данных для компенсации ограниченности данных. В статье [12] авторы использовали модель CNN, которая комбинирует признаки нескольких представлений, сделанных с разных позиций. В [13] предложена методология обнаружения BC с использованием набора данных изображений CBIS-DDSM. Была выполнена предварительная обработка изображения с последующим извлечением признаков с использованием нескольких CNN. модели (AlexNet, VGG16, ResNet, GoogLeNet и InceptionResNet). Извлеченные признаки оценивались с помощью нейросетевого классификатора с точностью 88%.

В данной работе предлагается нейронная сеть, основанная на известных сетях AlexNet и ResNet18 [14, 15]. Мы объединяем дескрипторы, сформированные обеими сетями, и используем классификацию, применяя объединенный дескриптор. В предлагаемой статье используется набор данных изображений рака молочной железы CBIS-DDSM [16], из которых содержит 2138 обучающих изображений и 327 тестовых изображений. Предлагаемая сеть ищет признаки, различающие доброкачественные и злокачественные маммограммы и имеет два выходных класса. Для повышения точности распознавания используется фильтрация признаков, основанная на вычислении совместной информации [17]. Компьютерное моделирование иллюстрирует работу предложенного алгоритма.

Статья организована следующим образом. В разделе 2 приведена формулировка задачи и описана архитектура нейронной сети. В разделе 3 представлен описан алгоритм фильтрации признаков. В разделе 4 представлены результаты компьютерного моделирования. Раздел 5 содержит заключение.

2. АРХИТЕКТУРА НЕЙРОННОЙ СЕТИ

Входные данные сети представляют собой изображение маммографии в оттенках серого. Выходные данные представляют собой вектор, состоящий из двух элементов. Элементы представляют собой вероятности для двух классов. Предлагаемая сеть использует модифицированные версии двух известных нейронных сетей ResNet18 [15] и AlexNet [14]. Мы используем вариант ResNet18 с исключенным из сети последним классифицирующим слоем. Вместо этого в сеть включается полносвязный слой. На Рис. 1 показан использованный вариант архитектуры нейронной сети ResNet18. Все слои используют функцию активации ReLU, кроме слоя MaxPool2D. Также мы используем вариант нейронной сети AlexNet с исключенным из сети последним классифицирующим слоем. Вместо этого в сеть включается полносвязный слой. На Рис. 2 показан использованный вариант архитектуры нейронной сети AlexNet. Все слои используют функцию активации ReLU, кроме слоев MaxPool2D. Предлагаемая нейронная сеть представляет собой объединение двух описанных сетей. Предлагаемая сеть основана на объединении признаков, полученных из двух описанных сетей. Мы используем два вектора дескрипторов размером 128 из обеих подсетей, объединяем их и формируем линейный слой с функцией активации Softmax. Количество выходных классов равно двум. На Рис. 3 показана предлагаемая архитектура нейронной сети. В базе есть изображения разных размеров,




Рис. 1. Схема сети ResNet18.




Рис. 2. Схема сети AlexNet.

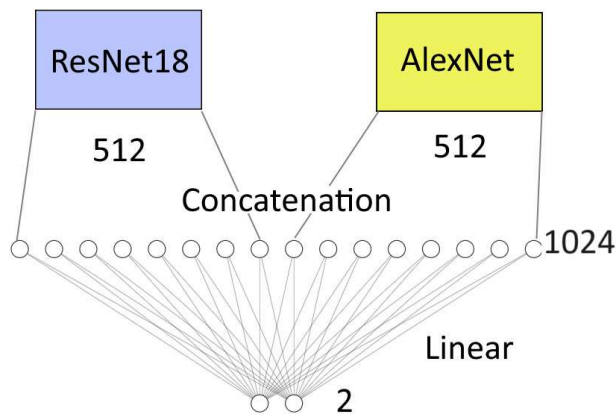


Рис. 3. Схема предлагаемой сети.

например 6601x3826. Мы изменяем размер изображения до квадрата 6601x6601 с помощью функции OpenCV “cvtColor”. После этого производится масштабирование изображения до размера 128x128. Число обучаемых весов полученной сети равно 68753986. В качестве Функции ошибки используется кросс-энтропия. Используется алгоритм Адам с параметром скорости обучения 0,001. Мы используем набор данных изображений рака молочной железы CBIS-DDSM [16] для обучения и тестирования сети. В предлагаемой статье используются только изображения из базы данных CBIS-DDSM, помеченные как “доброкачественные” и “злокачественные”. Часть “Full Mammogram Images” базы данных CBIS-DDSM содержит 2138 обучающих изображений и 327 тестовых изображений. Мы используем 280 тестовых изображений с одинаковым количеством изображений, принадлежащих обоим классам. Для обучения

сети данные изображения дополняются изменениями яркости и контрастности, а также геометрическими преобразованиями. Используются функция PyTorch “ColorJitter” с параметрами (0.1,0.1) и функция “RandomAffine” с параметрами (35, (0.1, 0.1), (0.9, 1.1)). Сеть обучалась 30 эпох.

3. ФИЛЬТРАЦИЯ ПРИЗНАКОВ

Используемый метод отбора неинформативных признаков в объединенном дескрипторе использует метод вычисления совместной информации, описанный в статье [17]. Предположим, что даны изображения, принадлежавшие двум классам. Количество элементов в каждом классе равно $\frac{N}{2}$. Каждому изображению сопоставляется дескриптор длины L , полученный конкатенацией дескрипторов, сформированных двумя нейронными сетями. Обозначим через V_1 вектор, элементами которого являются векторы $v_i, i = 1, \dots, L$. Каждый из векторов v_i содержит $\frac{N}{2}$ элементов, которые являются i -ми компонентами каждого из $\frac{N}{2}$ дескрипторов первого класса. Таким образом, можно считать, что вектор V_1 содержит L точек размерности $\frac{N}{2}$. Аналогично, вектор V_2 содержит L точек размерности $\frac{N}{2}$. Разделим Векторы V_1 и V_2 на подвекторы длины l ,

$$V_1 = V_{11}, \dots, V_{1(\frac{L}{l})}, \quad (1)$$

$$V_2 = V_{21}, \dots, V_{2(\frac{L}{l})}. \quad (2)$$

Рассмотрим подвекторы V_{11} и V_{21} . Пусть $N = 2l$, фиксируем значение $i, i = 1, \dots, 2l$. Зададим значение параметра k , как правило, это значение является небольшим натуральным числом. При значении параметра i от 1 до l выбирается соответствующий элемент вектора V_{11} , при значении параметра i от $l+1$ до $2l$ выбирается соответствующий элемент вектора V_{21} .

Для выбранной точки размерности $\frac{N}{2}$ находим k ближайших соседей из того вектора, которому принадлежит точка и вычисляем радиус полученной k -окрестности. Вычислим количество точек из V_{11} и V_{21} попавших в построенную окрестность. Это число обозначим через m_i . Обозначим через I_i следующие выражение

$$I_i = \psi(2l) - \psi(l) + \psi(k) - \psi(m_i), \quad (3)$$

где ψ – дигамма-функция. Вычислим совместную информацию векторов V_{11} и V_{21} как среднее по всем значениям i

$$I(V_{11}, V_{21}) = \psi(2l) - \psi(l) + \psi(k) - \frac{1}{2l} \sum_{i=1}^{2l} \psi(m_i). \quad (4)$$

Аналогичным образом вычисляется совместная информация для остальных пар подвекторов $I(V_{1j}, V_{2j}), j = 2, \dots, \frac{L}{l}$. Мы считаем признаки (V_{1j}, V_{2j}) слабыми, если $I(V_{1j}, V_{2j}) \leq -0,18$ и исключаем соответствующий участок из выходного слоя нейронной сети. Используются следующие значения настраиваемых параметров:

$$L = 1024, l = 8, k = 2. \quad (5)$$

4. КОМПЬЮТЕРНОЕ МОДЕЛИРОВАНИЕ

В этом разделе представлены результаты, полученные на основе набора данных CBIS-DDSM, базы данных изображений рака молочной железы [16]. Предполагаемый результат может принадлежать к следующим типам:

1. Истинно-положительные результаты: случаи, когда прогнозируемый класс и истинный класс позитивны. Это указывает на то, что классификатор точно классифицировал экземпляр с положительным результатом;

2. Ложно-положительные результаты: случаи, когда прогнозируемый класс положительный, а фактический класс отрицательный. Это означает, что классификатор неправильно классифицировал экземпляр с положительной меткой. Например, это может относиться к изображению кальцификации, классифицируемое как злокачественная маммография;

3. Истинно-отрицательные результаты: случаи, когда прогнозируемый класс и фактический класс совпадают с негативным результатом. Это указывает на то, что классификатор правильно классифицировал экземпляр с отрицательной меткой;

4. Ложно-отрицательные результаты: случаи, когда прогнозируемый класс отрицательный, а фактический класс положительный. Это означает, что классификатор неправильно классифицировал экземпляр с отрицательной меткой.

Ниже мы показываем примеры результатов работы нейронной сети всех четырех типов. На Рис. 4 показаны четыре маммограммы с истинно-отрицательными результатами




Рис. 4. Примеры маммограмм с истинно-отрицательными результатами.

На Рис. 5 показаны четыре маммограммы с ложно-положительными-результатами.




Рис. 5. Примеры маммограмм с ложно-положительными результатами.

На Рис. 6 показаны четыре маммограммы с ложно-отрицательными результатами.

На Рис. 7 показаны четыре маммограммы с истинно-положительными результатами.

На Рис. 8 показана матрица истинности для предлагаемой нейронной сети.

На Рис. 9 показана матрица истинности для предлагаемой нейронной сети с фильтрацией признаков.




Рис. 6. Примеры маммограмм с ложно-отрицательными результатами.




Рис. 7. Примеры маммограмм с истинно-положительными результатами.




Рис. 8. Матрица истинности для предлагаемой нейронной сети.




Рис. 9. Матрица истинности для предлагаемой нейронной сети с фильтрацией признаков.

Применение фильтрации признаков повысило точность классификации на 1,5 процента.

5. ЗАКЛЮЧЕНИЕ

В этой статье предложен нейросетевой алгоритм, позволяющий различать доброкачественные и злокачественные маммограммы. Предлагаемая сеть основана на сетях AlexNet и ResNet18 и использует конкатенацию их дескрипторов. Предлагаемая сеть была обучена на наборе данных, содержащем 2138 обучающих изображений. Применение фильтрации признаков позволило увеличить точность классификации маммограмм с помощью нейронной сети.

СПИСОК ЛИТЕРАТУРЫ

1. Du-Crow, E. Computer-Aided Detection in Mammography // The University of Manchester (United Kingdom) (2022).
2. Evans, A., Trimboli, R., Athanasiou, A., Balleyguier, C., Baltzer, P., Bick, U., Camps Herrero, J., Clauser, P., Colin, C., Cornford, E. and Fallenberg EM. Breast ultrasound: recommendations for information to women and referring physicians by the European Society of Breast Imaging // Insights into imaging. 9(449),61 (2018).
3. Schueller, G., Schueller-Weidekamm, C. and Helbich T. Accuracy of ultrasound-guided, large-core needle breast biopsy // European radiology, 18, 1761-73 (2008).
4. Agarwal, S., Yadav, A., Dinesh, V., Vatsav, K., Prakash K and, Jaiswal S., By artificial intelligence algorithms and machine learning models to diagnosis cancer. // Materials Today: Proceedings, (2021);
5. Bai, J., Posner, R., Wang, T., Yang C. and Nabavi S. Applying deep learning in digital breast tomosynthesis for automatic breast cancer detection // A review. Medical image analysis, 71, 102049 (2021).

6. Li, Z., Liu, F., Yang, W., Peng, S. and Zhou, J. A survey of convolutional neural networks: analysis, applications, and prospects // *IEEE Transactions on neural networks and learning systems*, (2021).
7. Zuluaga-Gomez, J., Al Masry, Z., Benaggoune, K., Meraghni, S. and Zerhouni, N. A CNN-based methodology for breast cancer diagnosis using thermal images // *Computer Methods in Biomechanics and Biomedical Engineering: Imaging and Visualization*, 9(2), 131-45 (2021).
8. Erođlu, Y., Yildirim, M. and Cinar, A. Convolutional Neural Networks based classification of breast ultrasonography images by hybrid method with respect to benign, malignant, and normal using mRMR // *Computers in biology and medicine*, 1(133), 104407 (2021).
9. Huang, Q., Yang, F., Liu, L. and Li, X. Automatic segmentation of breast lesions for interaction in ultrasonic computer-aided diagnosis // *Information Sciences*. 1(314), 293-310 (2015).
10. Huang, Q., Huang, Y., Luo, Y., Yuan, F and, Li, X. Segmentation of breast ultrasound image with semantic classification of superpixels // *Medical Image Analysis*, 1(61), 10165 (2020).
11. Rahman, A., Belhaouari, S., Bouzerdoum, A., Baali. H., Alam, T. and Eldaraa, A. Breast mass tumor classification using deep learning // *IEEE (ICIoT)* 411, 271-276 (2020).
12. Sun, L., Wang, J., Hu, Z., Xu, Y. and Cui, Z. Multi-view convolutional neural networks for mammographic image classification // *IEEE Access*, 3(7), 126273-82 (2019).
13. Heravi, E., Aghdam, H. and Puig, D. Classification of Foods Using Spatial Pyramid Convolutional Neural Network // *InCCIA*, 163-168 (2016).
14. Krizhevsky, A., Sutskever, I. and Hinton, G. Imagenet classification with deep convolutional neural networks // *Communications of the ACM*, 60(6), 84-90 (2017)
15. He, K., Zhang, X., Ren, S. and Sun, J. Deep residual learning for image recognition // *In Proceedings of the IEEE Conference on computer vision and pattern recognition*, 770-778, (2016).
16. Lee, R., Gimenez, F., Hoogi, A. et al. A curated mammography data set for use in computer-aided detection and diagnosis research. // *Sci Data*, 4, 170177 (2017).
17. Ross BC. Mutual information between discrete and continuous data sets. *PloS one*. 2014 Feb 19;9(2):e87357.

Hybrid neural network for mammography image classification

A. Makovetskii, V. Kober, S. Voronin, A. Voronin, V.Karnaukhov, M.Mozerov

An important step in solving the problem of classification and segmentation of 2D images is the extraction of local geometric features. Convolutional neural networks have been widely used in recent years to solve problems in this field. Typically, the neighborhood of each pixel in an image is used to collect local geometric information. A convolutional neural network is used to extract the underlying geometric features of the neighborhood. In this paper, we propose a neural network based on descriptor cocatenation of two well-known neural networks to solve the problem of extracting local geometric features of mammographic images. To improve the accuracy of mammogram classification, feature filtering is used based on the calculation of joint information. Computer simulation results are presented to illustrate the performance of the proposed method.

KEYWORDS: Convolutional neural network, segmentation, classification, jmutual information.