

УДК 519.686

## РАСПОЗНАВАНИЕ ПАТОЛОГИЙ ГРУДНОЙ КЛЕТКИ С ПОМОЩЬЮ ПРЕДВАРИТЕЛЬНОГО ОБУЧЕНИЯ НА ОБЩЕДОСТУПНЫХ НАБОРАХ ДАННЫХ

А.И. НАУМОВИЧ

*Белорусский государственный университет, Республика Беларусь**Поступила в редакцию 28 февраля 2022*

**Аннотация.** Рассмотрена проблема распознавания патологий грудной клетки в условиях малых объемов обучающей выборки. Предложен подход к решению задачи, основанный на нейросетевой технологии. Разработана архитектура и способ обучения сети, а также алгоритм преобразования набора данных для обучения.

*Ключевые слова:* сверточная нейронная сеть, распознавание образов, обработка рентгенографических изображений.

### Введение

В условиях пандемии важнейшей задачей врачей является выявление заболеваний легких на ранней стадии их проявления [1–3]. В настоящее время для получения данных о состоянии пациентов с заболеваниями легких используют широкий спектр различных стационарных и мобильных флюорографических аппаратов. Из-за резкого увеличения числа пациентов возрастает нагрузка на врачей-специалистов, поэтому актуальной в такой ситуации становится проблема автоматизации процесса обработки гетерогенных данных.

Для эффективного решения обозначенной проблемы требуется разработать соответствующий набор алгоритмов и на их основе программное обеспечение, автоматизирующее трудоемкие этапы обработки данных [4–5].

### Формализация и постановка задачи

Прежде, чем перейти к постановке задачи, рассмотрим процесс принятия решения при традиционном подходе к проведению скрининга. Как отмечалось выше, он проводится среди широких слоев населения с использованием различного рода стационарного и портативного медицинского оборудования. Полученные в результате разнородные рентгенографические снимки в кратчайшие сроки должны быть обработаны врачами рентгенологами. Поэтому актуальной является задача автоматизации процесса анализа разнородных рентгенографических изображений. Необходимо разработать и реализовать на практике алгоритмы, которые позволят специалисту-рентгенологу уделить максимальное внимание неоднозначным (сложным) случаям течения болезни. Такие алгоритмы должны гарантировать уверенное (предварительное) решение в максимальном количестве случаев. Когда же степень «уверенности» алгоритма в поставленном диагнозе мала, необходимо предоставить ему интерпретацию работы алгоритма. Интерпретация должна дать возможность специалисту быстро определить справедливость или ложность поставленного алгоритмом предварительного диагноза. Наконец, разрабатываемый подход к решению задачи должен быть достаточно производительным применено к большому объему гетерогенных данных.

Для решения обозначенной проблемы широко используются нейросетевые технологии обработки данных. Важным этапом применения таких технологий является обучение нейронной сети. Процесс, как правило, реализуют на общедоступном наборе данных. Затем выполняют так

называемую калибровку нейронной сети на целевом наборе. Наличие размеченного (целевого) набора данных является в некотором смысле недостатком рассматриваемого подхода. Потому что на практике сбор и подготовка размеченных данных (для каждого типа оборудования) является достаточно дорогостоящим процессом. Поэтому актуальной является задача разработки алгоритмов, требующих минимальный объем данных из целевого домена для обучения нейронной сети.

Проведем формализацию и постановку задачи.

Под рентгенографическим изображением (или просто изображением) будем понимать тензор  $x \in [0,1]^{w \times h \times c}$ , где  $[0,1]$  – допустимый диапазон яркости пикселей изображения,  $w$  – ширина изображения,  $h$  – высота изображения, а  $c$  – количество каналов изображения.

Пусть  $X = \{x\}$  – некоторое множество рентгенографических изображений. Пусть также  $P = \{p_1, p_2, \dots, p_k\}$  – множество патологий, которые можно обнаружить на снимках из  $X$  (включая также отсутствие патологии на снимке). Пусть задано множество  $X_0 \subset X$ , такое, что для  $\forall x \in X_0, x \rightarrow y \in P$ , т.е. каждому объекту множества  $X_0$  ставится в соответствие метка патологии из множества  $P$ .

Необходимо построить алгоритм  $A: X_0 \times X \rightarrow P$ , который по входному рентгенографическому изображению распознал бы на нем патологию из множества  $P$ .

Следует заметить, что постановка задачи не предполагает наличие целевого домена данных.

Пусть  $X_D \subset X$  – множество изображений из целевого домена. Наличие меток патологий  $P_D$  для этого набора изображений не уточняется. В таком случае необходимо построить алгоритм  $A: X_0 \times X_D \times X \rightarrow P$ .

По результатам теоретических исследований необходимо разработать архитектуру и состав программного комплекса по распознаванию патологий грудной клетки по рентгенографическим изображениям.

### Алгоритмическое решение задачи

На практике распространены ситуации, когда множество  $X_D$  достаточно мало. В данной статье рассматривается задача, в которой  $|X_D| = 12$ ,  $Y = \{\text{туберкулез, пневмония}\}$ . Рассмотрим решения практической задачи, когда в реальных условиях заданы три снимка с туберкулезом, три снимка с пневмонией, а на остальных снимках патологий не выявлено.

С учетом специфики конкретной прикладной задачи, предлагается подход, основанный на использовании нейросетевой технологии обработки данных [6]. Он состоит из следующих основных шагов:

1. Предварительная обработка снимка.
2. Распознавание наличия любой патологии на снимке  $x$ .
3. Автоматизированное уточнение диагноза для снимков, имеющих патологию.
4. Оценка степени уверенности алгоритма в поставленном предварительном диагнозе.
5. Ручной анализ неоднозначных ситуаций специалистом-рентгенологом.

В силу ограниченности объема статьи предлагается подробнее остановиться на этапах распознавания наличия патологии и уточнения диагноза. Предлагается использовать две различные нейронные сети сверточного типа стандартной архитектуры.

Наибольший интерес представляет подход к обучению этих нейронных сетей. Поскольку выборка  $X_D$  не позволяет обучить их эффективно (из-за малого объема), предлагается использовать общедоступные наборы рентгенографических изображений для обучения нейронных сетей. Статистические свойства общедоступных данных (средняя яркость и дисперсия пикселей) отличаются от целевых. Предлагается процедура обучения и архитектура нейронной сети, позволяющие решить эту проблему.

Процедура обучения нейронной сети представляет собой процесс, состоящий из двух основных этапов.

На первом этапе к общедоступному набору данных применяется преобразование  $G(x)$ . В результате получается новая обучающая выборка, характеристики которой соответствуют целевому набору данных.

На втором этапе, на полученном наборе данных выполняется обучение нейронной сети методом градиентного спуска.

На практике основная сложность заключается в выборе преобразования  $G(x)$ . На основании анализа данных и визуального сравнения изображений предлагается алгоритм построения  $G(x)$ .

Пусть  $x \in X_0, y \in X_D$ . Пусть преобразование  $G$  является композицией преобразований сдвига яркости  $g_1(x, \delta) = x + \delta$  и изменения контраста  $g_2(x, \gamma) = (x - \bar{x}) \cdot \gamma + \bar{x}$ , где  $\bar{x}$  – средняя яркость изображения,  $\gamma, \delta$  – параметры преобразований. Необходимо подобрать в некотором смысле оптимальные значения  $\gamma^*$  и  $\delta^*$  параметров  $\gamma, \delta$ , чтобы статистические характеристики обоих выборок были схожи.

В работе рассматриваются 2 статистики. Средней яркостью выборки  $X$  назовем величину

$$\bar{X} = \frac{1}{Nwh} \sum_{x \in X, i=1, j=1}^{w, h} x_{ij}. \quad \text{Дисперсией выборки } X \text{ будем называть величину}$$

$$DX = \frac{1}{Nwh} \sum_{x \in X, i=1, j=1}^{w, h} (x_{ij} - \bar{X})^2. \quad \text{Подобрать параметры } \gamma, \delta \text{ необходимо так, чтобы}$$

$|\bar{X} - \bar{X}_D| \rightarrow \min$  и  $|DX - DX_D| \rightarrow \min$ . Поскольку задача многокритериальная, введем дополнительный параметр  $\alpha, 0 \leq \alpha \leq 1$  и запишем целевую функцию в виде  $\alpha |\bar{X} - \bar{X}_D| + (1 - \alpha) |DX - DX_D| \rightarrow \min$ .

Предлагается алгоритм нахождения значений  $\gamma, \delta$ , основанный на переборе допустимых значений аргументов по сетке. Пусть  $\{(\gamma_i, \delta_i)\}$  – множество допустимых значений параметров, а гиперпараметр  $\alpha$  зафиксирован. Пусть  $G(X) = \{y | y = G(x), \forall x \in X\}$ .

Шаг 0. Для множества  $X_D$  вычислить среднее  $\bar{X}$  с дисперсию  $DX_D$ .

Шаг 1. Для каждого набора  $(\gamma_i, \delta_i)$  выполнить шаги 2–4.

Шаг 2. Построить выборку  $G(X)$ . Вычислить ее характеристики  $\bar{X}_G$  и  $DX_G$ .

Шаг 3. Вычислить значение функции  $\alpha |\bar{X}_G - \bar{X}_D| + (1 - \alpha) |DX_G - DX_D|$ .

Шаг 4. Если значение функции – наименьшее среди рассмотренных, то пометить пару  $(\gamma_i, \delta_i)$  как наилучшую на текущий момент. Если все параметры рассмотрены, то закончить выполнение. Иначе перейти к шагу 1, используя следующую пару параметров  $(\gamma_{i+1}, \delta_{i+1})$ .

Основной недостаток алгоритма заключается в его трудоемкости. В ходе выполнения необходимо провести перебор  $\gamma, \delta$ . Кроме того, из-за необходимости дискретизации пространства допустимых значений аргументов возникает возможность пропуска значений параметров, дающих хорошее качество преобразования.

Для преодоления обозначенных проблем использован подход, основанный на методе стохастического градиентного спуска по параметрам  $\gamma, \delta$ . Для простоты вычисления производных функции потерь преобразуем ее к виду  $L(\delta, \gamma) = \alpha (\bar{x} - \bar{y})^2 + (1 - \alpha) (Dx - Dy)^2$ .

После упрощения функция потерь представляется в виде  $L(\delta, \gamma) = \alpha \delta^2 + (1 - \alpha) (1 - \gamma^2)^2 (Dx)^2$ .

Рассмотрим шаги алгоритма градиентного спуска.

Шаг 0. Для начальной инициализации положить  $\gamma^0 = 0, \delta^0 = 0$ .

Шаг 1. Зафиксировать объект  $x \in X, t = t + 1$ .

Шаг 2. Применить преобразование к изображению:  $y = \gamma(x - \bar{x}) + \bar{x} + \delta$ .

Шаг 3. Вычислить частные производные функции потерь по формулам  $\frac{\partial L}{\partial \gamma} = 2\alpha\delta$ ,  
 $\frac{\partial L}{\partial \gamma} = -4\gamma(1-\alpha)(1-\gamma^2)(Dx)^2$ .

Шаг 4. Выполнить шаг алгоритма градиентного спуска по формулам:  $\gamma^{t+1} = \gamma^t - \beta \frac{\partial L}{\partial \gamma}$ ,  
 $\delta^{t+1} = \delta^t - \beta \frac{\partial L}{\partial \delta}$ , где  $\beta$  – шаг обучения.

Шаг 5. Если  $|\gamma^{t+1} - \gamma^t| < \epsilon$  и  $|\delta^{t+1} - \delta^t| < \epsilon$ , то прекратить выполнение и принять  $\gamma^t$  и  $\delta^t$  как искомые значения. Иначе перейти к Шагу 1.

Таким образом, предложен алгоритм построения преобразования  $G$  как композиции преобразований изменения яркости и контраста. Рассмотрим теперь изменения, которые необходимо внести в стандартную архитектуру нейронной сети.

Пусть  $x$  – объект обучающей выборки,  $F: X \rightarrow R^n$  – сверточная нейронная сеть. Пусть  $\bar{x} = G(x)$  – преобразованный снимок обучающей выборки. Применим нейронную сеть к обоим снимкам:  $y = F(x), \bar{y} = F(\bar{x})$ . Для достижения инвариантности к условиям съемки и параметрам медицинского оборудования, необходимо, чтобы  $L_1 = \|\bar{y} - y\| \rightarrow \min$ . Пусть  $L_2$  – стандартная функция потерь при решении задачи классификации над вектором  $x$ . Тогда для обучения нейронной сети необходимо минимизировать функцию потерь  $L = \alpha L_1 + (1-\alpha)L_2, \alpha \geq 0$ .

### Результаты экспериментов и обсуждение

Работоспособность предложенного подхода была проверена в ходе экспериментальных исследований. В качестве общедоступных наборов данных использованы NIH [7], RSNA [8], VinBigData [9], Shenzhen Tuberculosis Dataset [10]. Для проверки качества обученных моделей архитектуры DenseNet использовалось 12 снимков, полученных с помощью портативного медицинского оборудования.

Результаты тестирования бинарной модели на общедоступных данных представлены в табл. 1.

Табл. 1. Результаты тестирования бинарной модели

Pathology Label	F1 Score
Sick	0,7312
No finding	0,8392

Результаты тестирования уточняющей диагноз модели на общедоступных данных представлены в табл. 2.

Табл. 2. Результаты тестирования уточняющей диагноз модели

Pathology label	F1 Score
Tuberculosis	0,9652
Pneumonia	0,9712
Other	0,9808

Матрица ошибок модели для выборки  $X_0$  представлена в табл. 3.

Табл. 3. Матрица ошибок для целевой выборки

Pathology label	No Finding	Tuberculosis	Pneumonia
No Finding	5	1	0
Tuberculosis	0	3	0
Pneumonia	1	0	2

## Заключение

В работе предложен подход к распознаванию патологий легких, который представлен в виде последовательности шагов предварительной обработки снимка, распознавания наличия патологии и уточнения диагноза. Предложен подход к обучению нейронной сети (при малых объемах целевой выборки), основанный на подборе параметров композиции преобразований изображений.

На основе предложенных подходов и алгоритмов разработан соответствующий программный комплекс по распознаванию болезней легких. Результаты проведенных экспериментов свидетельствуют о работоспособности предложенного подхода.

## CHEST PATHOLOGIES RECOGNITION USING PRE-TRAINING ON PUBLIC DATASETS

A.I. NAUMOVICH

**Abstract.** The problem of chest pathologies recognition in then conditions of insufficient size of the training dataset is considered. An approach to solving the problem based on neural network technology is proposed. The architecture and method of network training have been developed, as well as an algorithm for converting the dataset for training purposes.

*Keywords:* convolutional neural network, pattern recognition, X-Ray image processing.

## Список литературы

1. Yao J [et. al.] Computer-aided diagnosis of pulmonary infections using texture analysis and support vector machine classification. Academic Radiology, 2011.
2. Park S. [et. al.] // arXiv preprint arXiv, 2021.
3. CheXpert: A Large Chest X-Ray Dataset and Competition [Электронный ресурс]. URL: <https://stanfordmlgroup.github.io/competitions/chexpert/>.
4. Andrew Naumovich /Andrew Naumovich // Research Papers Collection "Open Semantic Technologies for Intelligent Systems ", Issue 5, 2021, P. 233–237.
5. Krasnoproshin V., Naumovich A. // Proceedings of the 15-th International Conference "Pattern Recognition and Information Processing". 2021. P 43–46.
6. Краснопрошин В.В., Головки В.А. Нейросетевые технологии обработки данных. Минск, 2017.
7. NIH Chest X-ray dataset [Электронный ресурс]. URL: <https://cloud.google.com/healthcare-api/docs/resources/public-datasets/nih-chest>.
8. RSNA Pneumonia Detection Challenge [Электронный ресурс]. URL: <https://www.kaggle.com/c/rsna-pneumonia-detection-challenge>.
9. VinBigData Chest X-ray Abnomalities Detection [Электронный ресурс]. URL: <https://www.kaggle.com/c/vinbigdata-chest-xray-abnormalities-detection>.
10. Tuberculosis Chest X-rays (Shenzhen) [Электронный ресурс]. URL: <https://www.kaggle.com/raddar/tuberculosis-chest-xrays-shenzhen>.