

УДК 004.891.3

П.М. Радюк, А.В. Бармак, Ю.В. Крак

ИНФОРМАЦИОННАЯ ТЕХНОЛОГИЯ РАННЕЙ ДИАГНОСТИКИ ПНЕВМОНИИ С ИСПОЛЬЗОВАНИЕМ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ

Ключевые слова: ранняя диагностика, пневмония, сверточная нейронная сеть, выделение признаков, рентгеновский снимок грудной клетки, визуальный анализ, карты активации классов.

Введение

В настоящее время пневмония — одно из наиболее серьезных легочных заболеваний во всем мире. Согласно данным Всемирной организации здравоохранения ежегодно сообщается почти о двух миллионах смертей от пневмонии [1]. Тяжелая пандемия коронавируса COVID-19 с начала 2020 года еще больше усилила летальный исход легочных заболеваний. Численные клинические исследования подтвердили, что инфекция COVID-19 вызывает тяжелую форму пневмонии у большого количества людей [2]. В то же время бактериальные и вирусные патогены вызывают разные формы пневмонии, что требует различных подходов к лечению. И хотя бактериальная пневмония немедленно лечится антибиотиками, вирусный тип этого заболевания требует экстренной вспомогательной помощи, что делает критически важной своевременную и точную диагностику заболевания [3].

Определим, что результат диагностирования пневмонии на рентгенограммах возможен в трех основных состояниях: абсолютно здоровые легкие без видимых проявлений заболевания, однозначно пневмония с яркими проявлениями на картинке и промежуточное состояние, при котором признаки пневмонии представлены нечетко [4, 5]. При этом рентген грудной клетки можно делать в профилактических целях или при первых подозрениях на раннее проявление вирусного заболевания.

В основном выявить пневмонию на начальных этапах развития можно, сравнивая снимки, сделанные с интервалом 1–2 дня [6]. Однако существенным недостатком рентгенограмм, как средства ранней диагностики вирусной пневмонии, является ограниченная цветовая гамма, состоящая из различных оттенков серого. Кроме того, в связи с высокой интенсивностью длины белой волны на фотопленке жидкость в легких на стадии прилива достаточно сложно идентифицировать как плотную и твердую ткань [7]. Поэтому профилактические действия по выявлению вирусной пневмонии осложняются ограниченной цветовой гаммой рентгенограмм, и, как следствие, слабым выражением признаков заболевания на снимке. Другим серьезным затруднением выявления пневмонии на ранней стадии является человеческий фактор. Радиологи должны обладать обширным опытом и четким зрением, чтобы различить неоднородное цветовое распределение воздуха в лег-

ких. В соответствии с опытом специалистов в радиологии [8, 9] как ложноположительные, так и ложноотрицательные диагнозы могут нанести значительный вред здоровью человека.

Принимая во внимание сказанное выше, возникает необходимость использования вычислительных методов для разработки систем автоматизированной диагностики (САД) на ранней стадии пневмонии. Внедрение САД может значительно увеличить шансы на постановку правильного диагноза и, как следствие, улучшить профилактические мероприятия и дальнейшее лечение. Итак, в данной работе предлагается информационная технология для выявления и интерпретации признаков ранней стадии вирусной пневмонии на рентгеновском изображении грудной клетки.

Обзор существующих методов цифровой диагностики пневмонии

Обычно САД служат дополнительным инструментом при принятии клинических решений на основе исследования достаточности информации [10] и ее помехоустойчивости [11]. Они сочетают элементы компьютерного зрения (КЗ) и систем искусственного интеллекта с рентгенологической обработкой изображений для выявления закономерностей на изображениях [12]. Современные САД обнаруживают и описывают специфические признаки пневмонии на изображении, основываясь на методах машинного обучения (МО) [13]. В последние годы большую популярность приобрели методы выявления и классификации характеристических признаков с использованием гиперплоскостной классификации [14] и глубокого обучения (ГО), в частности сверточных нейронных сетей (СНС) [15].

За последние несколько лет задачи визуальной интерпретации цифровой медицинской диагностики успешно решаются методами ГО, в частности, с помощью СНС. Так, в работе [17] представлена модифицированная сеть VGG19 [18], цель которой — выявлять область интереса (ОИ) на основе градиента для пространственной локализации пневмонии. Авторам удалось достичь точности обнаружения пневмонии в 63,3 %. В работе [18] применяется градиентный метод визуализации в сочетании с тепловыми картами для локализации ОИ и соответственно — идентификации пневмонии. В [19] авторы сфокусировались на визуализации процесса выявления легочного заболевания, применив карты активации классов (КАК), что позволило успешно интерпретировать результаты САД.

Другим подходом к визуализации и интерпретации ГО является применение полносвязных остаточных СНС, в частности Inception [20]. Так, в работе [21] предложено использовать остаточную сеть типа [20] с ядрами свертки размером $3 \times 3 \times 3$ для сегментирования органов брюшной полости на объемных снимках компьютерной томографии. В исследовании [22] предложено САД на основании MobileNet2V2 [23] для выявления вирусной пневмонии, вызванной COVID-19. Хотя авторы этой работы используют остаточную локализацию для локализации аномальных зон на рентгеновских изображениях, вопрос интерпретации результатов диагностики остается нераскрытым.

Несмотря на значительный успех технологий ГО в различных задачах КЗ, отсутствие понятной интерпретации результатов диагностики не дает СНС проявить весь свой потенциал в области анализа медицинских изображений. Также недостаточно изучено поведение моделей СНС, что ограничивает их использование в повседневной клинической практике [16]. В настоящее время нет четкого понимания того, какие именно признаки пневмонии на рентгеновском снимке указывают модели СНС о наличии заболевания. Соответственно не понятно, как проектировать эффективную топологию СНС для индивидуального диагностирования ранней пневмонии.

Постановка задачи

В настоящей работе предлагается информационная технология для реализации индивидуального подхода диагностики пневмонии на ранней стадии. Основная идея технологии заключается в следующем: создание модели классификации, которая сможет выявлять слабовыраженные признаки ранней пневмонии на рентгеновском снимке; реализация метода визуального анализа для интерпретации результатов классификации. Для достижения цели необходимо выполнить следующие задачи.

1. Создание модели классификации на основании СНС для извлечения признаков ранней пневмонии.
2. Обоснование и реализация метода визуального анализа для интерпретации результатов классификации.
3. Оценивание информационной технологии по количественным и качественным признакам.
4. Сравнение полученных результатов с современными методами для тестирования технологии на практическую полезность и эффективность в области анализа медицинских изображений.

Модель классификации в виде топологии сверточной нейронной сети

Для того чтобы сохранить необходимую информацию о текстурных признаках пневмонии и одновременно не усложнить модель большим количеством сверточных слоев, в данной работе предлагается трехслойная СНС с расширенными свертками. Схема топологии СНС представлена на рис. 1.

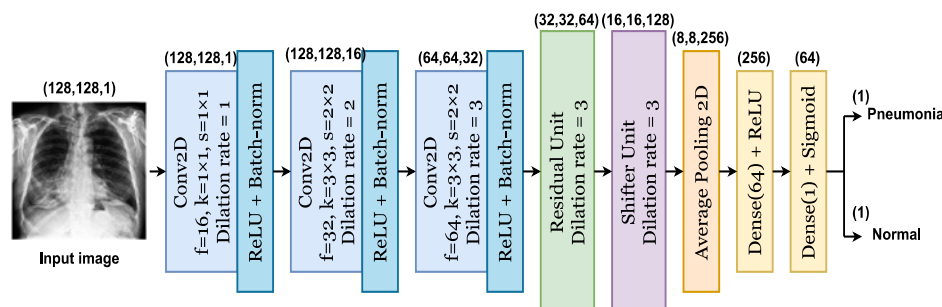


Рис. 1

Сверточная топология построена на основе нейронной сети с остаточными блоками. В данном случае остаток — это разница между фактическим наблюдаемым значением и расчетным. Идея заключается в том, чтобы настроить СНС на изучение незначительных изменений, изъятых остаточной частью сверточного слоя. Так, на вход сеть получает блок изображений размером 128×128 пикселей после предварительной обработки и сворачивается последовательно с трех сверточных слоев. В то же время сверточные фильтры содержат ядра размером 3×3 . Таким образом обеспечиваются малые размеры нейронов относительно общей области восприятия входного сигнала. Соответственно, это дает возможность охватить локальные текстурные признаки пневмонии.

Ниже детализируем топологию на рис. 1 с помощью общепринятых математических выражений [24].

Двумерный сверточный шар (Conv2D) имеет вид

$$a^{[l]} = \left[\text{ReLU}^{[l]}(\text{conv}(a^{[l-1]}, K^{(1)})), \text{ReLU}^{[l]}(\text{conv}(a^{[l-1]}, K^{(2)})), \dots \right]$$

$$\dots, \text{ReLU}^{[l]} \left(\text{conv}(a^{[l-1]}, K^{(n_C^{[l]})}) \right) \Bigg],$$

$$\text{conv} \left(a^{[l-1]}, K^{(n_C^{[l]})} \right)_{x,y} = \text{ReLU}^{[l]} \left(\sum_{i=1}^{n_H^{[l-1]}} \sum_{j=1}^{n_W^{[l-1]}} \sum_{k=1}^{n_C^{[l-1]}} K_{i,j,k}^{(n_C^{[l]})} a_{x+i-1,y+j-1,k}^{[l-1]} + b_n^{[l]} \right),$$

$$a^{[l]} : n_H^{[l]}, n_W^{[l]}, n_C^{[l]}.$$
(1)

Функция активации ReLU имеет вид

$$\text{ReLU} = \max \{0, x\}.$$
(2)

За активацией сверточного слоя следует пакетная нормализация (Batch-norm)

$$z_{i,j,k,c} = \text{BatchNorm}_{\gamma_c \beta_c}(x_{i,j,k,c}) = \gamma_c \hat{x}_{i,j,k,c} + \beta_c,$$

$$\hat{x}_{i,j,k,c} = \frac{x_{i,j,k,c} - \mu_{B,c}}{\sqrt{\sigma_{B,c}^2 + \varepsilon}}.$$
(3)

После сверточных слоев следует остаточный слой (Residual Unit):

$$z_j^{[i]} = \sum_{l=1}^{n_{i-1}} w_{j,l}^{[i]} a_l^{[i-1]} + b_j^{[i]} \rightarrow$$

$$\rightarrow a_j^{[i]} = \text{ReLU}^{[i]} \left(z_j^{[i]} + a_j^{[i-2]} \right).$$
(4)

Далее определен остаточный слой переключения (Shifter Unit):

$$z_j^{[i]} = \sum_{l=1}^{n_{i-1}} w_{j,l}^{[i]} a_l^{[i-1]} + b_j^{[i]} \rightarrow$$

$$\rightarrow a_j^{[i]} = \text{ReLU}^{[i]} \left(z_j^{[i]} + \mathbf{W}_s a^{[i-2]} \right),$$

$$\mathbf{W}_s : n^{[i]} \times n^{[i-2]}.$$
(5)

После остаточных слоев следует усредненный подвыборочный слой (Average Pooling 2D):

$$a_{x,y,z}^{[l]} = \text{avgpool} \left(a^{[l-1]} \right)_{x,y,z} = \varphi^{[l]} \left(\left(a_{x+i-1,y+i-1,z}^{[l-1]} \right)_{(i,j) \in [1,2,\dots,f^{[l]}]^2} \right).$$
(6)

Предпоследний полносвязный слой с функцией активации ReLU (Dense(64) + ReLU) определен так:

$$z_j^{[i]} = \sum_{l=1}^{n_{i-1}} w_{j,l}^{[i]} \cdot a_l^{[i-1]} + b_j^{[i]} \rightarrow$$

$$\rightarrow a_j^{[i]} = \text{ReLU}^{[i]} \left(z_j^{[i]} \right).$$
(7)

Последний полносвязный слой классификации с функцией сигмовидной активации (Dense(1) + Sigmoid) имеет вид

$$a_j^{[i]} = \frac{1}{1 + e^{-a_j^{[i-1]}}}.$$
(8)

Топология сети, представленная на рис. 1, может обеспечить постоянное разрешение сети и минимальные потери разрешения пространства изображений. Расширенное ядро свертки может поддерживать увеличение области восприятия ядра без увеличения количества параметров ядра и позволяет избежать чрезмерных потерь разрешения карт признаков.

Ниже приводятся результаты вычислительных экспериментов, подтверждающие эффективность предлагаемой информационной технологии на основании модифицированной СНС из рис. 1.

Предварительная обработка данных и извлечение признаков

Прежде всего заметим, что последующие обозначения операций преобразования данных не пересекаются с формулами (1)–(8).

Размер исходных изображений изменяется в учебном наборе данных до 128×128 пикселей, чтобы определить наиболее подходящую ОИ с особенностями пневмонии на ранней стадии. Для задачи классификации пневмонии ОИ интерпретируется как бледная масса жидкости в зараженном легком. Эта бледная зона на рентгенограмме может быть извлечена с помощью распределения смежности, т.е. так называемой квадратной полутоновой матрицей смежности (ПМС) [25]. Матрица смежности определяется следующим образом:

$$C_M = \sum_{i=1}^k \sum_{j=1}^k \begin{cases} 1, & \text{если } I(i, j) = k \text{ и } I(i + D_x, m + D_y) = k, \\ 0, & \text{если } I(i, j) \neq k \text{ и } I(i + D_x, m + D_y) \neq k. \end{cases} \quad (9)$$

Использование ПМС дало возможность измерить текстурный оттенок изображений. Следуя рекомендациям из [25], создано несколько ПМС, обернув исходную ПМС под углами 0° , 45° , 90° и 135° , и распределено по всему изображению, чтобы обеспечить критическую оценку различных функций. В этом исследовании целевые признаки ранней пневмонии определены текстурными функциями Хаара [26] и извлекаются предлагаемой СНС из рис. 1. Заметим, что признаки Хаара обозначают связь между соседними пикселями на изображении с точки зрения влияния их интенсивности, что является важной особенностью для обнаружения ранней пневмонии, поскольку целевые рентгенограммы определяются ограниченным цветовым спектром.

Ниже представлены набор текстурных признаков Хаара, которые исследовались для выявления цветковых признаков ранней пневмонии на рентгенограмме.

1. Обозначим однородность изображения, определяющую сходство между пикселями, как

$$F_1 = \sum_{i=0}^N \sum_{j=0}^N \frac{p(i, j)}{1 + (i + j)^2}, \quad (10)$$

где N — размерность s , $p(i, j)$ — положение матричного элемента (i, j) на координатной плоскости, т.е. вероятность того, что пиксел i прилегает к пикселу j .

2. Контрастность — разница между максимальными и минимальными значениями пикселей

$$F_2 = \sum_{m=0}^{N-1} m^2 \sum_{i=0}^N \sum_{j=0}^N p(i, j), \quad (11)$$

где $m = |i - j|$.

3. Корреляция — зависимости оттенков серого матричного элемента (i, j)

$$F_3 = \sum_{i=1}^N \sum_{j=1}^N \frac{p(i, j) \cdot (i - \mu_i) \cdot (j - \mu_j)}{\sigma_i \sigma_j}, \quad (12)$$

где μ_i и μ_j — среднее функций плотности вероятности пикселей i и j соответственно, σ_i и σ_j — стандартное отклонение функций плотности вероятности пикселей i и j соответственно.

4. Квадратное отклонение от среднего или дисперсия

$$F_4 = \sum_{i=1}^N \sum_{j=1}^N (i - \mu)^2 p(i, j). \quad (13)$$

5. Момент обратных различий

$$F_5 = \sum_i \sum_j \frac{p(i, j)}{1 + (i - j)^2}. \quad (14)$$

6. Сумма всех средних значений для изображения

$$F_6 = \sum_{i=2}^{2N} i p_{a+b}(i), \quad (15)$$

где a и b — строки и столбцы в GLCM.

7. Сума дисперсии

$$F_7 = \sum_{i=2}^{2N} (i - F_6)^2 p_{a+b}(i). \quad (16)$$

8. Энтропия матричного элемента (i, j)

$$F_8 = - \sum_{i=1}^N \sum_{j=1}^N p(i, j) \ln(p(i, j)). \quad (17)$$

9. Сумма энтропии — общий объем информации, закодированной для изображения

$$F_9 = - \sum_{i=2}^{2N} p_{a+b}(i) \ln(p_{a+b}(i)). \quad (18)$$

10. Разница различной дисперсии изображения

$$F_{10} = \sum_{i=0}^N (i - \mu)^2 p_{a-b}(i). \quad (19)$$

11. Разница энтропии на основе (10)

$$F_{11} = - \sum_{i=0}^N -p_{a-b}(i) \ln(p_{a-b}(i)). \quad (20)$$

Далее функции (10)–(20) сравниваются между обычными изображениями и изображениями пневмонии и их различия оцениваются. В результате вычислительных экспериментов три текстурные функции, а именно дисперсия F_4 (14), сумма средних значений F_6 (16) и сумма дисперсии F_7 (17), показали наиболее значительную разницу в значениях между изображениями здорового человека и

изображений с болезнями легких [27]. Следовательно, функции F_4 , F_6 и F_7 выбраны в качестве основных вычислительных признаков ранней пневмонии и использовались в дальнейшем для визуальной интерпретации диагностики легочного заболевания на ранних стадиях.

Визуальный анализ посредством отличительной локализации

В настоящей работе применяется стратегия визуального анализа изображений под названием взвешенный КАК. Этот метод представляет ОИ на уровне класса, который считается наиболее значимым для правильного прогнозирования для всех входов, принадлежащих данному классу. Градиентно-взвешенный КАК [28] (ГКАК) — это строгое обобщение КАК, которое может применяться ко всем существующим СНС. ГКАК формирует взвешенную сумму всех карт объектов в глубоком сверточном слое для ожидаемого класса c :

$$\text{ГКАК}_c(x, y) = \text{ReLU} \left(\sum_{m=1}^M B_m^c g_m(x, y) \right), \quad (21)$$

где $g_m(x, y)$ — m -я карта активации признаков на плоскости (x, y) , M — общее количество КАК.

Нелинейность ReLU применяется для снижения влияния негативных весов на класс c ; предполагается, что пиксели с отрицательными весами относятся к другим классам.

Значение B_m^c получают путем вычисления градиента оценки прогнозирования относительно m -й карты признаков:

$$B_m^c = \sum_{x,y} \frac{\partial S_c}{\partial g_m(x, y)}. \quad (22)$$

Имеем, что средняя градация КАК для класса c исчисляется суммированием результатов ГКАК:

$$\text{summ_ГКАК}_c(x, y) = \sum_{k=1}^K (\text{ГКАК}_c^k(x, y)), \quad (23)$$

где $\text{ГКАК}_c^k(x, y)$ обозначает ГКАК для k -го изображения в ожидаемом классе c , K — общее количество изображений на выходе подвыборочного слоя.

Подход (21)–(23) может определить ОИ, улучшить интерпретацию внутренних представлений и объяснить предсказания модели.

Тренировочный набор данных и критерии оценки

Для экспериментальной проверки предлагаемого подхода использован малый набор рентгеновских снимков под названием CheXpert [29]. Он содержит 3 458 рентгенограмм грудной клетки размером 320×320 пикселей, полученных от 524 пациентов. Весь набор разбит на две категории: рентгеновские снимки с легкими в нормальном состоянии и снимки легких, отмеченные пневмонией. Кроме того, набор изначально разделен на учебную, тестовую выборки, содержащие 70 и 30% всех изображений соответственно.

Рассмотрим количество реальных положительных (Р) и реальных отрицательных случаев (N) в наборе данных CheXpert. Далее распределим результаты классификации: истинные положительные (ТР), истинные отрицательные (ТN),

ложные положительные (FP) и ложные отрицательные (FN) случаи [29–33]. Оценим эффективность предложенного подхода классификации по нескольким статистическим показателям, а именно, долю правильных обозначений классификатора, точность и полноту классификации, а также ошибки классификации первого и второго рода.

Долю правильных обозначений (ACC) определим так:

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} . \quad (24)$$

Точность (Precision) классификации

$$Precision = \frac{TP}{TP + FP} . \quad (25)$$

Полнота (Recall) классификации

$$Recall = \frac{TP}{TP + FN} . \quad (26)$$

Оценки ошибок первого (FPR) и второго рода (FNR) примем по таким формулам:

$$FPR = \frac{FP}{FP + TN} , \quad (27)$$

$$FNR = \frac{FN}{TP + FN} . \quad (28)$$

Помимо критериев (24)–(28), модель классификации оценено по времени обучения нейронной сети, выраженное в часах работы вычислительного процессора.

Программный код и полные результаты вычислительных экспериментов открыты на репозитории GitHub и доступны по ссылке [34].

Основные экспериментальные результаты

Эффективность работы построенной нейронной сети сравнивается с передовыми решениями в области анализа медицинских изображений — нейронных сетей VGG19 [18], Inception-v4 [20] и MobileNetV2 [23]. На рис. 2 представлены матрицы ошибок, полученные в результате вычислительных экспериментов над моделями VGG (рис. 2, а), Inception (рис. 2, б), MobileNet (рис. 2, в) и предложенной топологии из рис. 1 (рис. 2, г).

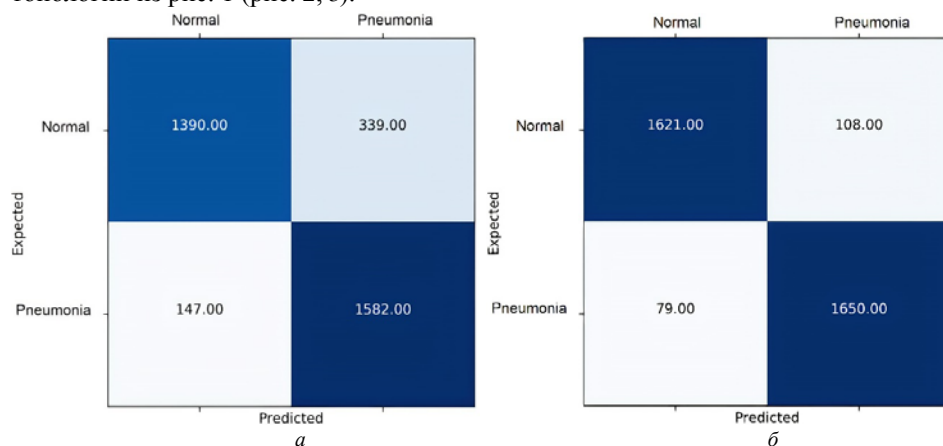
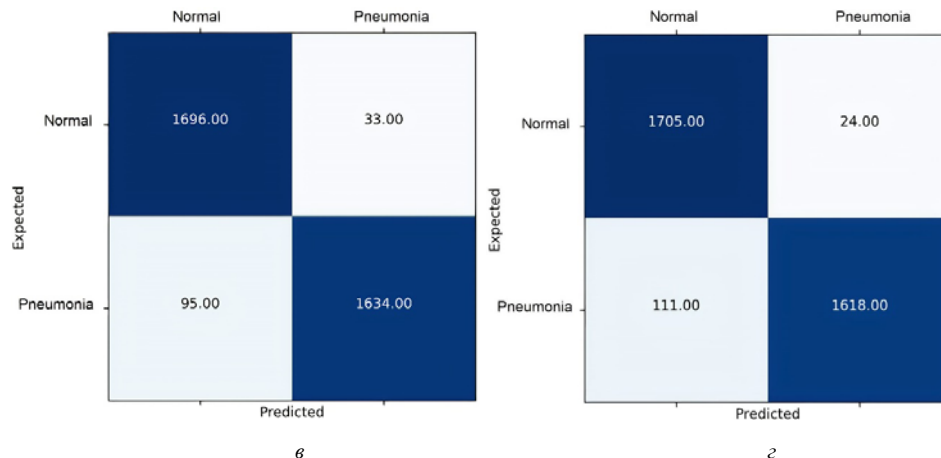


Рис. 2



Из рис. 2, а видим, что модель VGG19 классифицировала правильно 1582 изображения и неправильно — 147 изображений для класса пневмонии; в то же время для класса нормальных образцов VGG19 обозначила 1390 изображения как нормальные и 339 — как пневмонию. Из рис. 2, б видно, что Inception-v4 определила правильно 1650 снимков к классу пневмонии и неправильно — 79 снимков к классу нормального состояния легких; 1621 изображения были правильно отмечены как нормальные и 108 — неправильно как пневмония. Согласно рис. 2, в, MobileNet_v2 классифицировала правильно 1634 изображения как пневмонию и 95 — неправильно, как нормальные снимки легких; так же модель правильно предсказала принадлежность 1696 изображений к классу нормальных образцов, но ошиблась в 33 случаях. Наконец, на рис. 2, г видим, что модель, основанная на нашей архитектуре из рис. 1, правильно отметила 1618 изображений в качестве пневмонии, а 111 со здоровыми легкими неправильно отнесла к классу пневмонии; в то же время 1705 образцов были правильно классифицированы как снимки с нормальными легкими и 24 — неправильно как состояние легких с пневмонией.

Обсуждение полученных результатов

В табл. 1, 2 приведены окончательные результаты вычислительных экспериментов для четырех тестируемых моделей, выраженных в оценках статистических показателей (24)–(28).

Таблица 1

| Модель | ACC | Precision | Recall |
|------------------------|-------|-----------|--------|
| VVG19 [18] | 0,859 | 0,824 | 0,915 |
| Inception-V4 [20] | 0,946 | 0,939 | 0,954 |
| Mobilenetv2 [23] | 0,963 | 0,980 | 0,945 |
| Предлагаемая топология | 0,961 | 0,985 | 0,936 |

Согласно результатам табл. 2 все модели достигли высоких показателей правильных обозначений (ACC), точности (Precision) и полноты (Recall) классификации ($\approx 90\%$). Отметим, что модель VGG19 показала худшую производительность по всем статистическим оценкам. В то же время модель на основании предложенной топологии достигла высоких оценочных показателей, сравнявшись с показателями современных СНС. Так, предложенная в данной работе модель оказалась более эффективной, чем другие классификаторы по показателю точности классификации, достигнув 98,5 %, и сравнима с ними по доли правильных ответов (96,1 %) и полноты классификации (93,6 %).

Таблица 2

| Модель | FPR | FNR | Время, ч |
|------------------------|-------|-------|----------|
| VVG19 [18] | 0,196 | 0,085 | 5,11 |
| Inception-v4 [20] | 0,062 | 0,046 | 5,21 |
| MobileNetV2 [23] | 0,019 | 0,055 | 6,17 |
| Предлагаемая топология | 0,014 | 0,064 | 4,62 |

Из табл. 2 следует, что предложенный подход также имеет относительно низкие ошибки первого (FPR) и второго рода (FNR), показав в конце вычислений 1,4 и 6,4 % соответственно.

Исходя из статистических оценок в табл. 1, 2, можем заключить, что информационная технология на основе предложенной архитектуры из рис. 1 демонстрирует хорошую производительность и может быть реализован в дальнейшем для решения практических задач.

Поскольку предложенная СНС (см. рис. 1) содержит в своей топологии усредненный подвыборочный слой (5), то, согласно экспериментам в [27], такая СНС совместима со свешенными по градиенту картами активации классов. В общем, подход к визуальной интерпретации работы СНС заключается в следующем. Модель получает рентгеновские снимки из учебного набора данных и декодирует предсказания относительно признаков заболевания. Метод ГКАК, который в этой работе определен формулами (21)–(23), формирует тепловые карты в виде двумерных оценочных сеток, что рассчитываются для каждого расположения точек исходного изображения. Пикселы, которым соответствует высокое значение для ожидаемого класса, имеют ярко-красную окраску с четкими цветовыми переходами для различных диапазонов. Сформированные тепловые карты накладываются на исходные изображения для локализации зоны с потенциальными признаками легочного заболевания.

Далее с помощью того же метода ГКАК выявляются текстурные границы легких и на их основании формируются маски легких. В дальнейшем они описывают контуры легких на рентгенограммах для извлечения локализованной зоны с признаками. На рис. 3 представлены результаты визуального анализа рентгеновских снимков с помощью градиентной локализации особенностей на основании карт активации классов.




Рис. 3

Рис. 3 демонстрирует сравнение разных этапов визуальной интерпретации диагностики ранней пневмонии с использованием метод ГКАК. На рис. 3, а представлены исходные рентгенограммы, подготовленные для последующей визуальной интерпретации; рис. 3, б демонстрирует ограничительные рамки, локализирующие зоны активации с предполагаемым легочным заболеванием; на рис. 3, в изображены тепловые карты, наложенные на исходные рентгеновские снимки методом ГКАК; рис. 3, г демонстрирует автоматически сегментированные маски легких; на рис. 3, д представлены тепловые карты, наложенные на маски легких методом ГКАК. Из рис. 3 видим, что метод ГКАК обозначает ярко-красным цветом наиболее вероятное расположение особенностей ранней пневмонии на рентгенограмме. Следовательно, полученные тепловые карты на предварительно обработанных изображениях дают возможность идентифицировать визуальные различия в «пневмонических» зонах изображения, и таким образом, позволяют лучше выявлять слабовыраженные признаки ранней пневмонии.

Заключение

В данном исследовании предлагается информационная технология на основе методов глубокого обучения для диагностики ранней пневмонии. В основе технологии — модель классификации для извлечения слабовыраженных признаков ранней вирусной пневмонии и метод отличительной локализации для интерпретации результатов классификации. В качестве модели классификации использована модифицированная сверточная нейронная сеть. Для интерпретации результатов использован метод градиентно-взвешенных карт активации классов, обеспечивающий отличительную локализацию аномальных зон на рентгенограммах, что поможет диагностировать слабовыраженные признаки ранней пневмонии.

В результате вычислительных экспериментов модель классификации достигла сравнимо высоких оценочных показателей. Так, доля правильных обозначений классификатора составила 96,1 %, точность классификации — 98,5 %, и полнота — 93,6 %. При этом ошибки классификации первого и второго рода: 1,4 и 6,4 % соответственно.

Таким образом, согласно результатам исследования предложенная информационная технология может эффективно использоваться для диагностирования при первых подозрениях на раннюю пневмонию.

Дальнейшие исследования в области диагностирования ранней пневмонии будут направлены на увеличения надежности предложенного подхода и расширения охвата исходных данных для практического внедрения информационной технологии.

П.М. Радюк, О.В. Бармак, Ю.В. Крак

ІНФОРМАЦІЙНА ТЕХНОЛОГІЯ РАНОЇ ДІАГНОСТИКИ ПНЕВМОНІЇ З ВИКОРИСТАННЯМ ЗГОРТКОВИХ НЕЙРОННИХ МЕРЕЖ

За останні кілька років пневмонія стала однією з найпоширеніших легеневих захворювань у всьому світі, а її лікування наразі є надзвичайно важливим завданням у клінічній практиці. Медичний досвід довів, що рання діагностика пневмонії є вирішальним чинником її успішного лікування. На сьогодні автоматизований рентгенографічний аналіз грудної клітини визнано найефективнішим підходом у діагностиці легеневих захворювань, зокрема пневмонії. Однак досі не зрозуміло, які пневмонічні ознаки на рентгенівському зображенні авто-

матизований метод діагностики відносить до ранньої стадії захворювання. Крім того, питання інтерпретування результатів цифрової діагностики також не вирішене і потребує подальшого вивчення. Тому в представленій роботі пропонується інформаційна технологія візуального аналізу рентгенівських зображень для інтерпретування результатів цифрової діагностики вірусної пневмонії на ранніх стадіях. Технологія включає модель класифікації, на основі згорткової нейронної мережі, для вилучення нечітких ознак ранньої вірусної пневмонії та модифікований метод відмінної локалізації для пояснення результатів класифікації. Нейронна мережа, що використана в дослідженні, містить ефективну розширену операцію згортки для об'єднання ознак із різних рецептивних полів на зображенні. Запропонований метод інтерпретування полягає в застосуванні зважених градієнтів до карт активації класів. За результатами обчислень використана модель перевершила інші нейронні архітектури за показником precision (98,5 %), але поступилася accuracy (96,1 %) і recall (93,6 %). Крім того, модель продемонструвала порівняно низькі значення помилок першого і другого роду, досягнувши 1,4 і 6,4 % відповідно. Загалом, відповідно до обчислювальних експериментів, запропонована інформаційна технологія може бути ефективним інструментом миттєвої діагностики за першої підозри на пневмонію.

Ключові слова: рання діагностика, пневмонія, згорткова нейронна мережа, вилучення ознак, рентгенівський знімок грудної клітини, візуальний аналіз, мапи активації класів.

P.M. Radiuk, A.V. Barmak, Iu.V. Krak

INFORMATION TECHNOLOGY FOR THE EARLY DIAGNOSIS OF PNEUMONIA USING CONVOLUTIONAL NEURAL NETWORKS

Over the past few years, pneumonia has become one of the most common and severe lung diseases globally, and its treatment is vital nowadays. Clinical practice has proved that early diagnosis of pneumonia is a crucial factor in its successful treatment. An efficient approach to diagnosing pulmonary diseases, including pneumonia, is automated chest X-ray analysis implemented in clinical recommendation systems. However, it is still unclear what features of pneumonia in an X-ray image correspond to the early stage of the disease according to the automated method of diagnosis. The question of interpreting the results of digital diagnostics also remains open and needs further investigation. Therefore, to address an urgent issue of interpretation in digital diagnosis, we propose an information technology for the visual analysis of X-ray images to explain the results of diagnosing pneumonia. The technology comprises a classification model based on a convolutional neural network to extract mild features of early viral pneumonia and a modified method of distinctive localization to interpret the classification results. The neural network used in the study contains an effective dilated convolutional operation to combine features of various receptive fields. Our method of interpretation is based on applying weighted gradients to class activation maps. It distinguishes lung masks in the X-ray image and imposes thermal maps with a color gradient from blue to bright red. The red color corresponds to the most probable location of the pneumonia features in the radiograph. Such a modification provides excellent localization of abnormal areas on radiographs, removing the mild target features of early pneumonia. According to the computational results, our model surpassed other neural architectures in precision (98,5 %) but slightly conceded in classification accuracy (96,1 %) and recall (93,6 %). Moreover, it shows relatively low false positive and false negative rates, with 1,4 and 6,4 %, respectively. Overall, according to computational experiments, the proposed information technology can be an effective tool for instant diagnosis in the first suspicion of pneumonia.

Key words: early diagnosis, pneumonia, convolutional neural network, feature extraction, chest X-ray, visual analysis, class activation maps.

1. Roth G.A., Abate D., Abate K.H., Abay S.M., Abbafati C., et al. Global, regional, and national age-sex-specific mortality for 282 causes of death in 195 countries and territories, 1980–2017: *A systematic analysis for the Global Burden of Disease Study 2017*. The Lancet. 2018. **392**, N 10159. P. 1736–1788. DOI:10.1016/S0140-6736(18)32203-7.
2. Raghu G., Wilson K.C. COVID–19 interstitial pneumonia: Monitoring the clinical course in survivors. *The Lancet Respiratory Medicine*. 2020. **8**, N 9. P. 839–842. DOI:10.1016/S2213-2600(20)30349-0.
3. Tansarli G.S., Mylonakis E. Systematic review and meta-analysis of the efficacy of short-course antibiotic treatments for community-acquired pneumonia in adults. *Antimicrobial Agents and Chemotherapy*. 2018. **62**, N 9. P. e00635–18. DOI:10.1128/AAC.00635-18.
4. Krak I., Barmak O., Radiuk P. Information technology for early diagnosis of pneumonia on individual radiographs. *Proceedings of the 3rd International Conference on Informatics & Data-Driven Medicine (IDDM–2020)*, Växjö, Sweden, November 19–21, 2020. CEUR Workshop Proceedings. CEUR-WS.org, 2020. P. 11–21.
5. Modi A.R., Kovacs C.S. Hospital-acquired and ventilator-associated pneumonia: Diagnosis, management, and prevention. *Cleveland Clinic Journal of Medicine*. 2020. **87**, N 10. P. 633–639. DOI:10.3949/ccjm.87a.19117.
6. Shen, C., Tan, M., Song, X., Zhang, G., Liang J., Yu H., Wang, Ch. Comparative analysis of early-stage clinical features between COVID–19 and Influenza A H1N1 virus pneumonia. *Frontiers in Public Health*. 2020. **8**, N 206. P. 1–7. DOI:10.3389/fpubh.2020.00206.
7. Morris A.C. Management of pneumonia in intensive care. *Journal of Emergency and Critical Care Medicine*. 2018. **2**, N 2. P. 1–17. DOI:10.21037/jecm.2018.11.06.
8. Rajpurkar, P., Irvin, J., Ball, R.L., Zhu, K., Yang, B. et al. Deep learning for chest radiograph diagnosis: A retrospective comparison of the CheXNeXt algorithm to practicing radiologists. *PLOS Medicine*. 2018. **15**, N 11. P. e1002686. DOI:10.1371/journal.pmed.1002686.
9. Tolkachev A., Sirazitdinov I., Kholiavchenko M., Mustafaev T., Ibragimov B. Deep learning for diagnosis and segmentation of pneumothorax: The results on the Kaggle competition and validation against radiologists. *IEEE Journal of Biomedical and Health Informatics (Early access)*. IEEE Inc., 2020. DOI:10.1109/JBHI.2020.3023476.
10. Hovorushchenko T. Methodology of evaluating the sufficiency of information for software quality assessment according to ISO 25010. *Journal of Information and Organizational Sciences*. 2018. **42**, N 1. P. 63–85. DOI:10.31341/jios.42.1.4.
11. Lysenko S., Savenko O., Bobrovnikova K., Kryshchuk A. Self-adaptive system for the corporate area network resilience in the presence of botnet cyberattacks. *Proceedings of the 25th International Conference on Computer Networks*, CN 2018, Gliwice, Poland, June 19–22, 2018. Communications in Computer and Information Science. Springer International Publishing AG, Cham. **860**. DOI:10.1007/978-3-319-92459-5_31.
12. Li Y., Zhang Z., Dai C., Dong Q., Badrigilan S. Accuracy of deep learning for automated detection of pneumonia using chest X-Ray images: A systematic review and meta-analysis. *Computers in Biology and Medicine*. 2020. **123**. P. 103898. DOI:10.1016/j.compbiomed.2020.103898.
13. Ebiele J., Ansah-Narh T., Djiokap S., Proven-Adzri E., Atemkeng M. Conventional machine learning based on feature engineering for detecting pneumonia from chest X-rays. *Proceedings of ACM Annual Conference of the South African Institute of Computer Scientists and Information Technologists (SAICSIT '20)*, Cape Town, South Africa, Sep 2020. ACM Inc., 2020. **1145**. P. 149–155. DOI:10.1145/3410886.3410898.
14. Barmak A.V., Krak Y.V., Manziuk E.A., Kasianiuk V.S. Information technology of separating hyperplanes synthesis for linear classifiers. *Journal of Automation and Information Sciences*. 2019. **51**, N 5. P. 54–64. DOI:10.1615/JAutomatInfScien.v51.i5.50.
15. Yamashita R., Nishio M., Do R.K.G., Togashi K. Convolutional neural networks: An overview and application in radiology. *Insights into Imaging*. 2018. **9**, N 4. P. 611–629. DOI:10.1007/s13244-018-0639-9.
16. Faes L., Wagner S.K., Fu D.J., Liu X., Korot E. et al. Automated deep learning design for medical image classification by health-care professionals with no coding experience: A feasibility study. *The Lancet Digital Health*. 2019. **1**, N 5. P. e232–e242. DOI:10.1016/S2589-7500(19)30108-6.
17. Wang X., Peng Y., Lu L., Lu Z., Bagheri M. et al. ChestX-Ray8: Hospital-scale chest X-Ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases. *Proceedings of the 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR–2017*, Honolulu, HI, USA, July 21–26, 2017. IEEE Inc., 2017. P. 3462–3471. DOI:10.1109/CVPR.2017.369.

18. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition: *Proceedings of the 3rd International Conference on Learning Representations, ICLR-2015*, San Diego, CA, USA, May 7–9, 2015. ICLR.org., 2015 P. 1–14.
19. Rajaraman S., Candemir S., Kim I., Thoma G., Antani S. et al. Visualization and interpretation of convolutional neural network predictions in detecting pneumonia in pediatric chest radiographs. *Applied Sciences*. 2018. **8**, N 10. P. 1715–1732. DOI:10.3390/app8101715.
20. Szegedy C., Ioffe S., Vanhoucke V., Alemi A. Inception–v4, Inception-ResNet and the impact of residual connections on learning. *Proceedings of the 31 AAAI Conference on Artificial Intelligence, AAAI-2017*, San Francisco, CA, USA, Feb 4–10, 2017. AAAI Press, 2017. P. 4278–4284. DOI:10.5555/3298023.3298188.
21. Radiuk P. Applying 3D U-Net architecture to the task of multi-organ segmentation in computed tomography. *Applied Computer Systems*. 2020. **25**, N 1. P. 43–50. DOI:10.2478/acss-2020-0005.
22. Mahmud T., Rahman M.A., Fattah S.A. CovXNet: A multi-dilation convolutional neural network for automatic COVID–19 and other pneumonia detection from chest X-ray images with transferable multi-receptive feature optimization. *Computers in Biology and Medicine*. 2020. **122**. P. 103869. DOI:10.1016/j.compbiomed.2020.103869.
23. Sandler M., Howard A., Zhu M., Zhmoginov A., Chen L. MobileNetV2: Inverted residuals and linear bottlenecks: *Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, CVPR-2020*, Salt Lake City, UT, USA, June 18–23, 2018. IEEE Inc., 2018. P. 4510–4520. DOI:10.1109/CVPR.2018.00474.
24. Wiatowski T., Bölcskei H. A mathematical theory of deep convolutional neural networks for feature extraction. *IEEE Transactions on Information Theory*. 2018. **64**, N 3. P. 1845–1866. DOI:10.1109/TIT.2017.2776228.
25. Athanasiou L.S., Fotiadis D.I., Michalis L.K. Plaque characterization methods using intravascular ultrasound imaging. *Atherosclerotic Plaque Characterization Methods Based on Coronary Imaging*. Oxford: Academic Press, 2017. P. 71–94. DOI:10.1016/B978-0-12-804734-7.00004-X.
26. Löfstedt T., Brynolfsson P., Asklund T., Nyholm T., Garpebring A. Gray-level invariant Haralick texture features. *PLoS ONE*. 2019. **14**, N 2. P. e0212110. DOI:10.1371/journal.pone.0212110.
27. Vamsha Deepa N., Krishna N., Hemanth Kumar G. Feature extraction and classification of X-Ray lung images using Haralick texture features. *Proceeding of Smart and Innovative Trends in Next Generation Computing Technologies, NGCT-2017*. Singapore, June 09, 2018. Springer Singapore, 2018. **828**. P. 899–907. DOI:10.1007/978-981-10-8660-1_68.
28. Selvaraju R.R., Cogswell M., Das A., Vedantam R., Parikh D., Batra D. Grad-CAM: Visual explanations from deep networks via gradient-based localization. *International Journal of Computer Vision*. 2020. **128**, N 2. P. 336–359. DOI:10.1007/s11263-019-01228-7.
29. Irvin J., Rajpurkar P., Ko M., Yu Y., Ciurea-Illcus S. et al. CheXpert: A large chest radiograph dataset with uncertainty labels and expert comparison: *Proceedings of the 33d AAAI Conference on Artificial Intelligence*. 2019, Honolulu, Hawaii, USA, 27 Jan - 1 Feb 2019. AAAI.org, 2019. P. 590–597. DOI:10.1609/aaai.v33i01.3301590.
30. Manziuk E.A., Barmak A.V., Krak Y.V., Kasianiuk V.S. Definition of information core for documents classification. *Journal of Automation and Information Sciences*. 2018. **50**, N 4. P. 25–34. DOI:10.1615/JAutomatInfScien.v50.i4.30.
31. Krak I.V., Kryvonos I.G., Barmak O.V., Ternov A.S. An approach to the determination of efficient features and synthesis of an optimal band-separating classifier of dactyl elements of sign language. *Cybernetics and Systems Analysis*. 2016. **52**, N 2. P. 173–180. DOI:10.1007/s10559-016-9812-7.
32. Krak I.V., Kudin G.I., Kulyas A.I. Multidimensional scaling by means of pseudoinverse operations. *Cybernetics and Systems Analysis*. 2019. **55**, N 1. P. 22–29. DOI:10.1007/s10559-019-00108-9.
33. Kryvonos I.G., Krak I.V., Barmak O.V., Kulyas A.I. Methods to create systems for the analysis and synthesis of communicative information. *Cybernetics and Systems Analysis*. 2017. **53**, N 6. P. 847–856. DOI:10.1007/s10559-017-9986-7.
34. An approach to early diagnosis of pneumonia on individual radiographs based on the CNN information technology [Electronic resource]. GitHub, Inc. 2020. Resource access mode: <https://github.com/soolstafir/An-Early-Diagnosis-of-Pneumonia-on-Individual-Radiographs>.

Получено 26.01.2021
После доработки 20.04.2021