

УДК 615.47:616-072.7

ТЕКСТУРНЫЕ СТАТИСТИЧЕСКИЕ ПРИЗНАКИ УЛЬТРАЗВУКОВОГО ИЗОБРАЖЕНИЯ УЗЛОВЫХ ОБРАЗОВАНИЙ ЩИТОВИДНОЙ ЖЕЛЕЗЫ В ОЦЕНКЕ СТАТУСА ЗЛОКАЧЕСТВЕННОСТИ

© 2025 г. А. В. Манаев^{a, b, *}, А. А. Трухин^{a, b}, С. М. Захарова^{a, b},
Е. А. Трошина^{a, b}, Н. Г. Мокрышева^a, А. А. Гармаш^b

^aНациональный медицинский исследовательский центр эндокринологии МЗ РФ, Москва, 117292 Россия

^bНациональный исследовательский ядерный университет “МИФИ”, Москва, 115409 Россия

*E-mail: a.manaew2016@yandex.ru

Поступила в редакцию 30.05.2023 г.

После доработки 31.05.2023 г.

Принята к публикации 14.06.2023 г.

В работе представлены результаты исследования возможности применения статистических текстурных признаков для классификации изображений ультразвуковой диагностики узловых образований щитовидной железы. Ультразвуковая диагностика обладает значительным потенциалом количественной диагностики. Новые информационные технологии позволяют выделять характеристики, дополняющие классические методы анализа изображений в медицине.

Ключевые слова: эндокринология, текстурный статистический анализ, радиомика, ультразвуковое исследование, узловые образования

DOI: 10.56304/S2079562924050300

ВВЕДЕНИЕ

Узловые образования щитовидной железы (ЩЖ) — часто встречающаяся патология, распространенность составляет 19–35% по данным ультразвуковой диагностики, 8–65% по данным аутопсии [1]. На сегодняшний день ультразвуковое исследование (УЗИ) обеспечивает высокое пространственное разрешение и предоставляет диагностически полезную информацию, доступную на всех уровнях оказания медицинской помощи за счет небольшой стоимости, отсутствия ионизирующего излучения и компактности оборудования. Однако, как и всякий диагностический метод, УЗИ обладает своим недостатком. Значительная подверженность результатов исследования субъективным интерпретациям, что особенно характерно для неопытных специалистов, при этом сообщается о вариабельности чувствительности от 40.3 до 100% и специфичности от 50 до 100% [2].

В то же время пункционная биопсия является наиболее точным дооперационным методом классификации узлового образования, однако она является травматичной для ЩЖ. В литературе представлено, что использование систем поддержки принятия решений может сократить количество процедур тонкоигльной аспирационной пункци-

онной биопсии на 26.7% и количество пропущенных злокачественных новообразований на 1.9% [3].

В настоящее время получение различных признаков медицинских изображений с целью их анализа и классификации, представляющее собой суть радиомики, является перспективным направлением в диагностике [4, 5].

Целью работы является анализ прогностической ценности статистических текстурных признаков ультразвуковых изображений узловых образований щитовидной железы при оценке злокачественности.

МАТЕРИАЛЫ И МЕТОДЫ

Объекты исследования — пациенты с узловыми образованиями, подтвержденным статусом злокачественности и доброкачественности, проходившие ультразвуковое исследование щитовидной железы в ФГБУ “НМИЦ эндокринологии” Минздрава России.

Объем выборки составил 125 узловых образований (доброкачественные — 65, злокачественные — 60). Ультразвуковое исследование проводилось в продольной и поперечной проекциях с использованием двух аппаратов: полностью цифрового многоцелевого УЗИ-аппарата экспертного класса GE Voluson E8 и портативного цифро-

вого многоцелевого УЗИ-аппарата высокого класса GE Logiq E. Для доброкачественных узлов 33 кинопетли (36%) получено с аппарата GE Voluson E8, 58 (64%) — с аппарата GE Logiq E. Для злокачественных узлов 28 кинопетель (27%) получено с аппарата GE Voluson E8, 76 (73%) — с аппарата GE Logiq E. В данном исследовании рассматривались кинопетли, а не статичные изображения, для получения большей информации о структуре узлового образования.

Проведено исследование ряда признаков ультразвукового изображения, полученных с помощью матрицы пространственной смежности (МПС) оттенков серого — статистического метода анализа текстуры второго порядка. МПС — это матрица, в которой элемент $p(i, j)$ на пересечении i -ой строки и j -го столбца равен количеству соседних пикселей с яркостью i и j исходного изображения (считаем, что нумерация строк и столбцов МПС начинается с 0). При построении МПС в качестве смежных элементов рассмотрены элементы, которые находятся на расстоянии одного пикселя от рассматриваемого пикселя под углами 0, 45, 90 и 135 градусов от горизонтальной оси. При исследовании использовались 16 текстурных признаков, описанных далее.

Введем следующие обозначения: $p(i, j)$ — элемент нормированной МПС; N — количество градаций серого изображения (256); $p_x(i) = \sum_{j=0}^{N-1} p(i, j)$ — сумма элементов i -ой строки МПС; $p_y(j) = \sum_{i=0}^{N-1} p(i, j)$ — сумма элементов j -ого столбца МПС; $p_{x+y}(k) = \left(\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} p(i, j) \right)_{i+j=k}$, $k = 0, 1, \dots, 2N - 2$; $p_{x-y}(k) = \left(\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} p(i, j) \right)_{i-j=k}$, $k = 0, 1, \dots, N - 1$; $\mu_x = \sum_{i=0}^{N-1} i \cdot p_x(i)$; $\mu_y = \sum_{j=0}^{N-1} j \cdot p_y(j)$; $\sigma_x = \sum_{i=0}^{N-1} (i - \mu_x)^2 \cdot p_x(i)$; $\sigma_y = \sum_{j=0}^{N-1} (j - \mu_y)^2 \cdot p_y(j)$. Тогда текстурные признаки изображений вычисляются по следующим формулам, приведенным в табл. 1.

Все статистические текстурные признаки второго порядка можно разделить на 3 группы. Первая группа — “группа контраста”, вычисление которых заключается в присваивании определенно-го весового коэффициента элементам МПС в зависимости от удаления от главной диагонали МПС (к этой группе относятся признаки 4, 6, 7). Ко второй группе относятся признаки, связанные с упорядоченностью распределения пикселей серошкального изображения УЗИ, они отражают степень регулярности (упорядоченности) различий в значениях яркости пикселей (признаки 2, 3, 5, 10, 11). К третьей группе относятся признаки,

связанные с описательной статистикой МПС (признаки 1, 8, 9, 12, 13, 14, 15, 16) [6].

Все кинопетли подверглись процедуре сегментации, заключающейся в оконтуривании в ручном режиме областей, соответствующих узловым образованиям на изображениях в В-режиме, а текстурные признаки вычислялись на основе очерченной зоны интереса. Для некоторых признаков в качестве параметров изображения использовался натуральный логарифм от их значений с целью получения наиболее выраженного различия в распределениях для злокачественных и доброкачественных узловых образований.

При статистической обработке полученных данных в качестве критерия нормальности распределения использовался критерий Лиллиефорса, для оценки различий между двумя независимыми выборками по величине текстурных признаков — критерий Манна–Уитни–Вилкоксона. Выполнение корреляционного анализа осуществлялось на основе вычисления коэффициента ранговой корреляции Спирмена. Определение количественной взаимосвязи между исследуемыми признаками и дихотомической переменной “злокачественность”/“доброкачественность” выполнялось с помощью метода логистического регрессионного анализа.

РЕЗУЛЬТАТЫ

Для исследуемой выборки узловых образований вычислены статистические текстурные признаки согласно выражениям 1–16 в разделе “Методы и материалы”. С помощью пакета прикладных программ MATLAB выполнен тест Лиллиефорса на нормальность распределения для выборок значений статистических текстурных признаков 1–16 для злокачественных и доброкачественных узловых образований. Результатом является принятие нулевой гипотезы о принадлежности выборки к нормальному распределению для SE в случае доброкачественных узлов ($p = 0.12$), для ln(SV) в случае злокачественных узлов ($p = 0.17$), и отклонение нулевой гипотезы с уровнем значимости 5% для всех остальных признаков изображения для злокачественных и доброкачественных узлов.

В силу того, что распределение большинства выборок статистических текстурных признаков не является нормальным, сравнение исследуемых выборок на принадлежность к одной или разным генеральным совокупностям должно осуществляться с использованием непараметрических методов анализа данных. С этой целью проведен тест Манна–Уитни–Вилкоксона (табл. 2). В результате принята нулевая гипотеза о принадлежности к распределению с равными медианами для текстурных признаков: ln(SV), DA, ln(PRM). В силу этого различия в распределениях этих признаков для

Таблица 1. Статистические текстурные признаки второго порядка [7]

Признак	Выражение	Номер
Эхогенность	$Echo = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} i^* p(i, j)$	(1)
Энергия	$E = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} p^2(i, j)$	(2)
Энтропия	$S = - \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} p(i, j) \cdot \ln(p(i, j))$	(3)
Локальная однородность	$LU = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \frac{p(i, j)}{1 + (i - j)^2}$	(4)
Максимальная вероятность	$MP = \max_i \max_j p(i, j)$	(5)
След матрицы	$TR = \sum_{i=0}^{N-1} p(i, i)$	(6)
Контраст	$C = \sum_{n=0}^{N-1} n^2 \cdot p_{x-y}(n)$	(7)
Корреляция	$CORR = \frac{\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (i \cdot j) \cdot p(i, j) - \mu_x \cdot \mu_y}{\sigma_x \cdot \sigma_y}$	(8)
Среднее значение суммы	$SA = \sum_{i=2}^{2N} i \cdot p_{x+y}(i)$	(9)
Энтропия суммы	$SE = - \sum_{i=2}^{2N} p_{x+y}(i) \cdot \ln(p_{x+y}(i))$	(10)
Энтропия разности	$DE = - \sum_{i=0}^{N-1} p_{x-y}(i) \cdot \ln(p_{x-y}(i))$	(11)
Отклонение разности	$DV = - \sum_{i=0}^{N-1} (i - DA)^2 \cdot p_{x-y}(i)$	(12)
Информационная мера корреляции	$IMC = \frac{S + \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} p(i, j) \cdot \ln(p_x(i) \cdot p_y(j))}{\max(S_x; S_y)}$ где $S_x = - \sum_{i=0}^{N-1} p_x(i) \cdot \ln(p_x(i)), \quad S_y = - \sum_{i=0}^{N-1} p_y(i) \cdot \ln(p_y(i))$	(13)
Среднее значение разности	$DA = \sum_{i=0}^{N-1} i \cdot p_{x-y}(i)$	(14)
Отклонение суммы	$SV = - \sum_{i=2}^{2N} (i - SA)^2 \cdot p_{x+y}(i)$	(15)
Асимметрия	$PRM = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (i + j - \mu_x - \mu_y)^4 \cdot p(i, j)$	(16)




Рис. 1. ROC-кривая разработанной модели бинарной классификации узловых образований по критерию злокачественности.

злокачественных и доброкачественных узлов не принимаются статистически значимыми (уровень значимости — 5%). Для остальных признаков принята альтернативная гипотеза, в дальнейшем рассматриваются именно эти признаки.

В зависимости от величины абсолютного значения коэффициента, можно ввести несколько типов корреляции: слабая (меньше 0.5), умеренная (от 0.5 до 0.7), высокая (от 0.7 до 0.9) и очень высокая (больше 0.9). Очень высокая степень корреляции наблюдается для пар признаков $\ln(E)$ — S (–0.961), $\ln(E)$ — $\ln(MP)$ (0.904), S — SE (0.952), LU — TR (0.987), LU — DE (–0.942), $\ln(C)$ — $\ln(DV)$ (0.996) и SA — $Echo$ (0.999). Кроме того, высокая степень корреляции характерна для пар $\ln(E)$ — SE (–0.888), TR — DE (–0.893), $\ln(E)$ — LU (0.776), $\ln(E)$ — TR (0.75), S — LU (–0.726), S — $\ln(MP)$ (–0.715), LU — $\ln(MP)$ (0.744), $\ln(MP)$ — SE (–0.779), TR — DE (–0.865), $\ln(1-CORR)$ — IMC (0.795) и $\ln(1-CORR)$ — $\ln(DV)$ (0.701). Для остальных пар корреляция является умеренной или слабой. Близость значений коэффициентов корреляции для пар SA — $Echo$ и $\ln(C)$ — $\ln(DV)$ к единице свидетельствуют о довольно строгой положительной линейной связи, поэтому одновременное использование признаков SA и $Echo$, $\ln(C)$ и $\ln(DV)$ в качестве предикторов не является целесообразным, в качестве предиктора необходимо использовать только один признак из каждой пары, причем за счет сильной корреляции неважно, какой именно. В качестве параметров классификационной модели будем использовать SA и $\ln(DV)$. Относительно других пар сильно коррелирующих признаков утверждение об их незначимости для бинарной классификации не является достаточ-

но аргументированным для отбрасывания из прогностической модели, так как они не являются коррелирующими на 100%. В дальнейшем в качестве предикторов используются признаки: $\ln(E)$, S , LU , $\ln(MP)$, TR , $\ln(1-CORR)$, IMC , $\ln(DV)$, DE , SE , SA .

Целью регрессионного анализа является определение количественной взаимосвязи между значениями признаков изображений УЗИ и дихотомической переменной “злокачественность”/“доброкачественность”. Предварительно из исходной выборки кинопетель злокачественных и доброкачественных узлов сформированы обучающая и тестовая выборки (80% материала — обучающая выборка, 20% — тестовая). С помощью пакета прикладных программ MATLAB определены коэффициенты логистической регрессионной модели:

$$\ln\left(\frac{P}{1-P}\right) = z, \quad (17)$$

где $z = a_0 + a_1 \cdot \ln(E) + a_2 \cdot S + a_3 \cdot LU + a_4 \cdot \ln(MP) + a_5 \cdot TR + a_6 \cdot \ln(1 - CORR) + a_7 \cdot IMC + a_8 \cdot \ln(DV) + a_9 \cdot DE + a_{10} \cdot SE + a_{11} \cdot SA$; P — вероятность доброкачественности. Значения коэффициентов приведены в табл. 3.

Отношение шансов для коэффициентов, соответствующих предикторам прогностической модели (то есть для a_1 — a_{11}), показывает, во сколько раз изменится отношение шансов при изменении значения соответствующего предиктора на единицу. Так как доверительные интервалы для отношения шансов всех признаков не пересекают 1, можно утверждать о значимости данного набора предикторов для бинарной классификации “злокачественность”/“доброкачественность”.

Оценкой качества модели может служить площадь под ROC-кривой (рис. 1), которая оказалась равной $AUC = 0.780$, что говорит о хорошем качестве классификационной модели.

Составление классификационной модели подразумевает определение пороговой точки (cut-off point), обеспечивающей одинаковое значение чувствительности и специфичности. Пороговое значение 0.5143 обеспечивает значение чувствительности $Se = 71\%$, специфичности $Sp = 71\%$, прогностической ценности результата “злокачественность” $PPV = 72\%$, прогностической ценности результата “доброкачественность” $NPV = 69\%$, диагностической точности $Acc = 71\%$.

Характеристики узловых образований, которые классифицированы разработанной моделью ложноположительными и ложноотрицательными, представлены в табл. 4.

При сравнении табл. 2 и 4, медианы для ложноположительных признаков больше соответствуют злокачественным узловым образованиям, а для ложноотрицательных — доброкачественным образованиям. Примеры УЗИ изображений представлены на рис. 2. На основе визуального сравнения

Таблица 2. Полученные при выполнении теста Манна–Уитни–Вилкоксона p -значения и 95% доверительные интервалы для медианы

№	Признак	Медиана (95% доверительный интервал)		p -value
		доброкачественные	злокачественные	
1	ln(E)	–5.92 (–5.94; –5.89)	–5.81 (–5.83; –5.79)	<0.001
2	S	6.43 (6.41; 6.44)	6.36 (6.34; 6.39)	<0.001
3	LU	0.326 (0.324; 0.328)	0.335 (0.334; 0.337)	<0.001
4	ln(MP)	–4.23 (–4.25; –4.21)	–4.11 (–4.13; –4.09)	<0.001
5	ln(C)	4.06 (4.04; 4.09)	4.21 (4.18; 4.24)	<0.001
6	TR	0.152 (0.151; 0.153)	0.158 (0.157; 0.160)	<0.001
7	ln(1 – CORR)	–1.81 (–1.84; –1.78)	–1.82 (–1.85; –1.78)	0.010
8	Echo	59.60 (59.04; 60.30)	53.38 (52.95; 53.92)	<0.001
9	IMC	–0.328 (–0.331; –0.325)	–0.337 (–0.339; –0.335)	<0.001
10	ln(DV)	3.83 (3.80; 3.85)	4.01 (3.97; 4.04)	<0.001
11	DE	2.23 (2.22; 2.24)	2.213 (2.205; 2.220)	<0.001
12	SE	4.60 (4.59; 4.62)	4.59 (4.57; 4.60)	0.008
13	SA	120.56 (119.35; 121.78)	107.93 (106.88; 108.98)	<0.001
14	DA	3.50 (3.47; 3.54)	3.54 (3.50; 3.58)	0.273
15	ln(SV)	6.52 (6.49; 6.55)	6.54 (6.51; 6.56)	0.800
16	ln(PRM)	14.38 (14.33; 14.43)	14.43 (14.38; 14.49)	0.649

Таблица 3. Коэффициенты логистической регрессии и доверительные интервалы

Коэффициент	Значение (95% доверительный интервал)	Отношение шансов
a_0	–10.37 (–15.93; –4.81)	$3.14 \cdot 10^{-5}$ ($1.21 \cdot 10^{-7}$; $8.15 \cdot 10^{-3}$)
a_1	–4.73 (–5.76; –3.70)	$8.83 \cdot 10^{-3}$ ($3.15 \cdot 10^{-3}$; $2.47 \cdot 10^{-2}$)
a_2	1.34 (0.03; 2.65)	3.82 (1.03; 14.15)
a_3	39.55 (29.62; 49.48)	$1.50 \cdot 10^{17}$ ($7.31 \cdot 10^{12}$; $3.08 \cdot 10^{21}$)
a_4	1.27 (0.94; 1.60)	3.56 (2.56; 4.95)
a_5	–34.86 (–43.61; –26.10)	$7.25 \cdot 10^{-16}$ ($1.15 \cdot 10^{-19}$; $4.62 \cdot 10^{-12}$)
a_6	–1.15 (–1.59; –0.71)	0.32 (0.20; 0.49)
a_7	–22.65 (–28.43; –16.87)	$1.46 \cdot 10^{-10}$ ($4.50 \cdot 10^{-13}$; $4.71 \cdot 10^{-8}$)
a_8	–0.51 (–0.87; –0.15)	0.60 (0.42; 0.86)
a_9	8.52 (7.03; 10.00)	$5.01 \cdot 10^3$ ($1.13 \cdot 10^3$; $2.20 \cdot 10^4$)
a_{10}	–12.58 (–15.02; –10.14)	$3.44 \cdot 10^{-6}$ ($3.00 \cdot 10^{-7}$; $3.95 \cdot 10^{-5}$)
a_{11}	0.025 (0.021; 0.030)	1.03 (1.02; 1.03)

представленных изображений можно сделать вывод, что значительное уменьшение экзогенности, наличие структурных неоднородностей характерны прежде всего для злокачественных образований.

ОБСУЖДЕНИЯ

В предложенной прогностической модели в качестве предикторов рассмотрены признаки, прошедшие тест Манна–Уитни–Вилкоксона с уров-

Таблица 4. Характеристики ложноположительных и ложноотрицательных узлов

Признак	95% доверительный интервал медианы	
	ложноположительные	ложноотрицательные
ln(E)	−5.78 (−5.85; −5.73)	−5.93 (−6.00; −5.86)
S	6.35 (6.26; 6.43)	6.45 (6.39; 6.51)
LU	0.35 (0.34; 0.35)	0.307 (0.303; 0.311)
ln(MP)	−4.04 (−4.13; −3.96)	−4.26 (−4.32; −4.20)
TR	0.166 (0.160; 0.172)	0.140 (0.137; 0.143)
ln(1 − CORR)	−1.83 (−1.89; −1.76)	−1.57 (−1.75; −1.39)
IMC	−0.35 (−0.36; −0.34)	−0.29 (−0.30; −0.28)
ln(DV)	3.89 (3.80; 3.98)	4.05 (3.90; 4.21)
DE	2.17 (2.13; 2.20)	2.31 (2.28; 2.34)
SE	4.63 (4.58; 4.67)	4.57 (4.54; 4.60)
SA	110.09 (104.95; 115.23)	121.19 (118.41; 123.96)

нем значимости 5%, а для признаков с $p > 0.05$ различия в медианах распределений не рассматривались как статистически значимые, и такие признаки были отброшены. Однако, если использовать в качестве предикторов помимо описанных ранее 11 признаков также $\ln(\text{PRM})$,

$\ln(\text{SV})$ и коррелирующий с $\ln(\text{DV})$ признак $\ln(\text{C})$, можно добиться увеличения качества прогностической модели.

$$\ln\left(\frac{P}{1 - P}\right) = z,$$

(18)




Рис. 2. Примеры, соответствующие ложноположительной и ложноотрицательной классификации.

Таблица 5. Коэффициенты логистической регрессии и доверительные интервалы

Коэффициент	Значение (95% доверительный интервал)	Отношение шансов
a_0	-2.09 (-8.57; 4.40)	0.12 ($1.90 \cdot 10^{-4}$; 81.45)
a_1	-3.57 (-4.80; -2.35)	$2.82 \cdot 10^{-2}$ ($8.23 \cdot 10^{-3}$; $9.54 \cdot 10^{-2}$)
a_2	5.73 (3.53; 7.94)	$3.08 \cdot 10^2$ (34.1; $2.81 \cdot 10^3$)
a_3	29.88 (16.07; 43.69)	$9.48 \cdot 10^{12}$ ($9.53 \cdot 10^6$; $9.43 \cdot 10^{18}$)
a_4	1.23 (0.89; 1.58)	3.42 (2.44; 4.85)
a_5	-6.81 (-9.14; -4.48)	$1.10 \cdot 10^{-3}$ ($1.07 \cdot 10^{-4}$; $1.13 \cdot 10^{-2}$)
a_6	-30.14 (-43.99; -16.28)	$8.14 \cdot 10^{-14}$ ($7.86 \cdot 10^{-20}$; $8.51 \cdot 10^{-8}$)
a_7	-7.14 (-9.08; -5.20)	$7.93 \cdot 10^{-4}$ ($1.14 \cdot 10^{-4}$; $5.52 \cdot 10^{-3}$)
a_8	-38.96 (-47.85; -30.08)	$1.20 \cdot 10^{-17}$ ($1.66 \cdot 10^{-21}$; $8.64 \cdot 10^{-14}$)
a_9	9.69 (7.15; 12.23)	$1.62 \cdot 10^4$ ($1.27 \cdot 10^3$; $2.05 \cdot 10^5$)
a_{10}	12.81 (10.89; 14.73)	$3.66 \cdot 10^5$ ($5.36 \cdot 10^4$; $2.50 \cdot 10^6$)
a_{11}	-4.27 (-6.41; -2.12)	$1.40 \cdot 10^{-2}$ ($1.65 \cdot 10^{-3}$; 0.120)
a_{12}	-18.92 (-22.23; -15.60)	$6.07 \cdot 10^{-9}$ ($2.22 \cdot 10^{-10}$; $1.68 \cdot 10^{-7}$)
a_{13}	0.029 (0.024; 0.034)	1.03 (1.02; 1.03)
a_{14}	-0.59 (-0.83; -0.34)	0.554 (0.436; 0.712)

где $z = a_0 + a_1 \cdot \ln(E) + a_2 \cdot S + a_3 \cdot LU + a_4 \cdot \ln(MP) + a_5 \cdot \ln(C) + a_6 \cdot TR + a_7 \cdot \ln(1 - CORR) + a_8 \cdot IMC + a_9 \cdot \ln(DV) + a_{10} \cdot DE + a_{11} \cdot SE + a_{12} \cdot SA + a_{13} \times \ln(SV) + a_{14} \cdot \ln(PRM)$; P – вероятность доброкачественности. Значения коэффициентов приведены в табл. 5.

Для данной комбинации предикторов $AUC = 0.83$, а пороговое значение 0.5133 обеспечивает значение чувствительности $Se = 74\%$, специфичности $Sp = 73\%$, прогностической ценности результата “злокачественность” $PPV = 75\%$, прогностической ценности результата “доброкачественность” $NPV = 72\%$, диагностической точности $Acc = 74\%$. Также отношения шансов для коэффициентов регрессии $a_1 - a_{14}$ не пересекают единицу, что позволяет утверждать о значимости всех признаков. Вероятно, различия в распределениях для злокачественных и доброкачественных узлов для признаков $\ln(PRM)$ и $\ln(SV)$ являются статистически значимыми и при проверке нулевой гипотезы о принадлежности к распределению с равными медианами для текстурных признаков $\ln(SV)$ и $\ln(PRM)$ допущена ошибка второго рода. Кроме того, улучшение качества модели при совместном использовании признаков $\ln(C)$ и $\ln(DV)$, характеризующихся высоким коэффициентом ранговой корреляции Спирмена, можно объяснить тем, что данные признаки не являются коррелирующими на 100%.

ЗАКЛЮЧЕНИЕ

Таким образом, проведенное исследование демонстрирует возможность использования текстурных статистических признаков ультразвуковых изображений в качестве предикторов для оценки риска малигнизации узловых образований щитовидной железы. Важно отметить, что проведенное исследование имеет ограничения в связи со следующими обстоятельствами: сегментация узловых образований выполнялась специалистом вручную, что само по себе вносит субъективные интерпретации в результаты исследования; в качестве смежных элементов матрицы пространственной смежности рассматривались элементы на расстоянии 1 пикселя друг от друга без рассмотрения других возможностей; ультразвуковые исследования выполнялись на разных УЗИ-аппаратах. Помимо использованных в данной работе текстурных признаков, для классификации узловых образований также важно рассмотрение геометрических и морфологических характеристик узлов на УЗИ изображениях щитовидной железы. Например, в работе [8] в качестве параметров классификационной модели узловых образований по критерию злокачественности рассматриваются геометрические признаки узлов ЩЖ, содержащиеся в себе информацию о форме узлового образования, его размерах, ориентации относительно аксиальной плоскости, особенностях контура (ровные или неровные) и морфологические признаки, которые определяют структурные эле-

менты узла, такие как площадь, периметр, соотношение сторон и т.д. Разработанная в [8] классификационная модель на базе геометрических и морфологических признаков обеспечивает очень высокую чувствительность и специфичность около 99% (важно отметить, что результаты получены на несбалансированных данных с 17 доброкачественными и 82 злокачественными узлами). Совместное рассмотрение текстурных, геометрических и морфологических признаков в перспективе может привести к еще большему повышению качества диагностики злокачественных узлов и уменьшению затрат на обследование.

БЛАГОДАРНОСТИ

Материал подготовлен по гранту Российского научного фонда в рамках реализации проекта № 22-15-00135 “Научное обоснование, разработка и внедрение новых технологий диагностики коморбидных йододефицитных и аутоиммунных заболеваний щитовидной желе-

зы с использованием возможностей искусственного интеллекта”, при подготовке рукописи авторы сохранили независимость мнений.

СПИСОК ЛИТЕРАТУРЫ/REFERENCES

1. Diana S. // Best Pract. Res. Clin. Endocrinol. Metab. 2008. V. 22 (6). P. 901–911.
2. Kim H.G. et al. // Eur. J. Radiol. 2012. V. 81. P. E352–E356.
3. Peng S. et al. // The Lancet. Digital Health. 2021. V. 3 (4). P. E250–E259.
4. Cao Y. et al. // Cancers. 2021. V. 13 (10). P. 2436.
5. Cleere E.F. et al. // Diagnostics. 2022. V. 12 (4). P. 794.
6. GLCM Texture: A Tutorial v. 3.0 March 2017. / Hall-Beyer Mryka. 2017. <http://hdl.handle.net/1880/51900>.
7. Haralick R.M., Shanmugan K., Dinstein I. // IEEE Trans. Syst. Man Cybern. 1973. V. 3 (6). P. 610–621.
8. Gomes Ataíde E.J. et al. // Sensors. 2020. V. 20 (21). P. 6110.

Textural Statistical Features of Ultrasound Imaging of Thyroid Nodules in the Assessment of Malignancy Status

A. V. Manaev^{1, 2, *}, A. A. Trukhin^{1, 2}, S. M. Zakharova^{1, 2},
E. A. Troshina^{1, 2}, N. G. Mokrysheva¹, and A. A. Garmash²

¹National Medical Research Center of Endocrinology of the Ministry of Health of the Russian Federation, Moscow, 117292 Russia

²National Research Nuclear University MEPhI (Moscow Engineering Physics Institute), Moscow, 115409 Russia

*e-mail: a.manaev2016@yandex.ru

Received May 30, 2023; revised May 31, 2023; accepted June 14, 2023

Abstract—The paper presents the results of a study of the possibility of using textural statistical features to classify images of ultrasound diagnostics of thyroid nodules. Ultrasound diagnostics has a significant potential for quantitative diagnostics. New information technologies allow us to identify characteristics that complement the classical methods of image analysis in medicine.

Keywords: endocrinology, statistical textural analysis, radiomics, ultrasound imaging, thyroid nodules