

Повышение эффективности анализа КТ-изображений с помощью новых текстурных радиомических признаков

Ф. Шариати¹, В.А. Павлов¹

¹ Санкт-Петербургский политехнический университет Петра Великого (СПбПУ),
195251, Россия, Санкт-Петербург, ул. Политехническая, д. 29

Аннотация

В статье рассматривается развитие методов извлечения признаков из медицинских изображений для улучшения диагностики и анализа данных в онкологии. Представлены три новых радиомических признака для анализа КТ-изображений легких: адаптивный контраст текстуры, направленная однородность текстуры и совместная встречаемость текстурных переходов. Эти признаки специально разработаны для улучшения анализа КТ-изображений легких, что может оказать значительное влияние на точность диагностики и распознавание мутаций EGFR. В статье подробно описаны методы и алгоритмы, использованные для создания и тестирования этих признаков, а также представлены результаты, демонстрирующие улучшение показателей Accuracy и Precision на 4 % для задачи обнаружения мутаций EGFR по сравнению с традиционными методами. Это исследование подчеркивает потенциал интеграции новых радиомических признаков в клиническую практику для более точной и эффективной диагностики рака легких.

Ключевые слова: радиомические признаки, КТ-изображения, классификация.

Цитирование: Шариати, Ф. Повышение эффективности анализа КТ-изображений с помощью новых текстурных радиомических признаков / Ф. Шариати, В.А. Павлов // Компьютерная оптика. – 2025. – Т. 49, № 5. – С. 811-817. – DOI: 10.18287/2412-6179-CO-1581.

Citation: Shariaty F, Pavlov VA. Improving the efficiency of CT image analysis using new texture radiomics features. Computer Optics 2025; 49(5): 811-817. DOI: 10.18287/2412-6179-CO-1581.

Введение

В современном мире обработка и анализ изображений занимают центральное место во многих областях науки и технологий. Способность точно интерпретировать изображения имеет особенно критическое значение в медицинской визуализации, где она может напрямую влиять на диагностические возможности. Развитие новых методов извлечения признаков не только способствует повышению точности анализа, но и открывает новые возможности для ранней диагностики и персонализированного подхода в лечении [1].

В области медицинской визуализации широко применяются различные традиционные методы извлечения признаков, включая текстурный анализ [2, 3], методы глубокого обучения [4, 5], компьютерное зрение [6] и др. Эти методы играют важную роль в выявлении сложных шаблонов и аномалий на медицинских изображениях, что способствует улучшению диагностики и лечения [7].

Текстурный анализ включает в себя изучение структуры текстуры изображения для идентификации различных патологических состояний. Используемые подходы, такие как анализ матрицы распределения совпадений интенсивности (*gray-level co-occurrence matrix*, *GLCM*) [8] и анализ текстурных признаков на основе вейвлет-преобразований, позволяют количественно оценивать изменения в текстуре, характерные

для определённых заболеваний, например, для различных типов опухолей [9].

Глубокое обучение, в частности, использование сверточных нейронных сетей (СНС), улучшило обработку медицинских изображений, предоставляя возможности для автоматического выявления диагностически важных признаков из сырых данных. Эти методы способны обнаруживать сложные взаимосвязи в данных, которые трудно или невозможно выявить с помощью традиционных подходов. Однако обучение таких моделей требует больших объемов размеченных данных и значительных вычислительных ресурсов [10].

Компьютерное зрение обеспечивает возможности для автоматизированной интерпретации изображений с помощью алгоритмов, которые могут имитировать зрительное восприятие человека. Эти технологии включают методы сегментации, регистрации изображений и количественного анализа, что позволяет точно измерять морфологические характеристики и изменения, связанные с заболеваниями. Несмотря на широкое применение, компьютерное зрение может столкнуться с трудностями при обработке изображений с высокой степенью гетерогенности, как это часто бывает в случаях сложных медицинских состояний, где стандартные алгоритмы могут не учитывать все клинические особенности.

В данной работе предложены новые методы извлечения признаков из изображений, которые были разра-

ботаны для улучшения анализа и интерпретации медицинских данных: адаптивный контраст текстуры (*Adaptive Texture Contrast, ATC*), направленная однородность текстуры (*Directional Texture Uniformity, DTU*) и совместная встречаемость текстурных переходов (*Co-occurrence of Texture Transitions, CTT*). Эти признаки были применены к КТ-изображениям легких для демонстрации их потенциала в выявлении заболеваний. Основное внимание в статье уделено анализу производительности предложенных признаков по сравнению с существующими методами, что позволяет оценить их преимущества и области применения не только в медицине, но и в других сферах, где требуется анализ изображений.

Цель данного исследования заключается в разработке новых радиомических признаков и оценке их эффективности при классификации узлов в легких на КТ-изображениях. Этот подход направлен на повышение точности обнаружения мутаций *EGFR* (*рецептора эпидермального фактора роста, Epidermal growth factor receptor*), что должно улучшить точность диагностики и способствовать разработке более эффективных стратегий лечения.

Методология

В этом исследовании представлены три новых радиомических признака на основе текстур, направленных на повышение диагностической точности обнаружения мутаций *EGFR* в легочных узлах. Эти признаки предназначены для захвата сложных текстур и геометрических свойств, указывающих на генетические мутации. На рис. 1 представлена диаграмма извлечения признаков радиомики.




Рис. 1. Извлечение признаков радиомики

В исследовании использовался радиогеномный набор данных (NSCLC) [11, 12], полученный от 211

пациентов, содержащий такие данные, как изображения компьютерной томографии (КТ) легких, семантические аннотации опухолей на КТ-изображениях и данные о мутациях генов.

На рис. 2 представлена блок-схема процесса преобработки изображений, извлечения признаков и объединения признаков и классификация.




Рис. 2. Блок-схема процесса преобработки изображений, извлечения признаков и классификации

Ниже будут подробно описаны концептуальная основа, процесс расчета и метод проверки каждого признака.

Адаптивная контрастность текстур (Adaptive Texture Contrast, ATC). Возникновение концепции *ATC* заключается в эмпирическом наблюдении, что патологические ткани обычно демонстрируют различные текстурные паттерны, которые различаются по контрасту в разных масштабах. Эти закономерности играют важную роль в дифференциации нормальных и патологических состояний тканей, включая выявление важнейших генетических мутаций, таких как *EGFR*.

Вычисление *ATC* организовано посредством трехстороннего процесса, включающего преобразование в частотную область, изоляцию доминирующих текстур и расчет контраста.

1. Преобразование Фурье. Первый шаг включает преобразование изображения из пространственной области в частотную с помощью преобразования Фурье:

$$F(u, v) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) e^{-j2\pi(ux+vy)} dx dy,$$

где $f(x, y)$ – интенсивность изображения в пространственной области в координатах (x, y) ; $F(u, v)$ – комплексный аналог частотной области на частотах (u, v) ; u и v обозначают пространственные частоты вдоль горизонтальной и вертикальной осей соответственно.

Преобразование в частотную область позволяет анализировать особенности текстур и работать с ними на основе их частотных характеристик. Доминирующие частоты, которые представляют собой важные текстурные паттерны в выделенной области интереса, можно выделить и проанализировать дальше, что облегчает детальное понимание текстурных свойств, которые имеют решающее значение для таких приложений, как обнаружение мутаций *EGFR* в узлах легких.

2. Идентификация и изоляция доминирующей частоты. После преобразования изображения в частотную область выполняется определение и выделение

доминирующих частот. На этом этапе используется метод определения порога по спектру величины $M(u, v)$, выраженный как:

$$M(u, v) = \sqrt{\operatorname{Re}(F(u, v))^2 + \operatorname{Im}(F(u, v))^2},$$

где $M(u, v)$ количественно определяет величину частотной составляющей в точке (u, v) ; $\operatorname{Re}(F(u, v))$ и $\operatorname{Im}(F(u, v))$ обозначают вещественную и мнимую составляющие $F(u, v)$ соответственно.

Затем применяется полосовой фильтр, чтобы сохранить только частоты в пределах указанного диапазона, отмеченные заранее заданным порогом, таким образом изолируя интересующие текстуры. Используя этот спектр величин, метод включает использование подхода определения порога для различения доминирующих и недоминирующих частот. Частоты, превышающие определенный порог, считаются доминантными и, как предполагается, содержат важную информацию о текстурных паттернах, имеющих отношение к обнаружению мутаций *EGFR*.

3. Расчет контраста. Целью вычислений АТС является оценка контраста между изолированными текстурными узорами. Это достигается за счет установленных показателей контрастности, таких как контраст Майкельсона [13], определяемый как:

$$C = \frac{L_{\max} - L_{\min}}{L_{\max} + L_{\min}},$$

где C – значение контрастности; $L_{\max}$ и $L_{\min}$ относятся к максимальной и минимальной яркости, наблюдаемой в пределах области интереса соответственно.

Эти значения яркости получаются на основе уровней интенсивности, выделенных полосовым фильтром с упором на текстуры, коррелирующие с доминирующими частотами. Этот подход помогает дифференцировать нормальное и патологическое состояние тканей, подчеркивая контрастные изменения, присущие различным текстурам. Такая количественная оценка различий в контрастности может помочь повысить диагностическую точность обнаружения мутаций *EGFR* в узлах легких, поскольку она использует эмпирическое наблюдение о том, что патологическая ткань часто демонстрирует уникальные паттерны контрастной текстуры в разных масштабах.

Направленная однородность текстуры (Directional Texture Uniformity, DTU). DTU предназначен для количественной оценки однородности текстурных рисунков в определенных направлениях в области интереса. Этот показатель особенно полезен для анализа патологических тканей, которые часто демонстрируют анизотропные (зависимые от направления) текстуры. Основная гипотеза утверждает, что однородность или изменчивость текстуры в определенных направлениях может указывать на биологические состояния, такие как мутации *EGFR* в узлах легких.

Процесс извлечения признаков DTU можно разбить на два основных этапа: применение направленных фильтров для выделения определенных ориентаций текстур и вычисление меры однородности для этих текстур.

1. Применение направленных фильтров. Направленные фильтры, такие как фильтры Габора [14], используются для улучшения текстур в заранее определенных направлениях. Фильтр Габора – это линейный фильтр, используемый для анализа текстур, который, по сути, улавливает частотный состав в определенных ориентациях. Отклик фильтра Габора, примененного к изображению, можно определить, как:

$$G(x, y, \lambda, \theta, \psi, \sigma, \gamma) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \cos\left(2\pi \frac{x'}{\lambda} + \psi\right),$$

$$x' = x \cos \theta + y \sin \theta,$$

$$y' = -x \sin \theta + y \cos \theta,$$

где λ – длина волны множителя-косинуса; θ – представляет ориентацию нормали к параллельным полосам функции Габора; ψ – сдвиг фазы; σ – стандартное отклонение гауссовой огибающей; γ – пространственное соотношение сторон, которое определяет эллиптичность функции Габора.

Использование фильтров Габора позволяет выделять определенные текстуры в заданных направлениях изображения, что особенно ценно для анализа патологических тканей, которые могут демонстрировать анизотропные текстурные узоры. Выделив эти текстуры, можно более точно проанализировать и количественно оценить однородность текстур в областях изображения, что открывает новые перспективы и аналитические инструменты для обнаружения биологических состояний, таких как мутации *EGFR* в узлах легких.

2. Расчет однородности. После применения направленного фильтра следующим шагом будет вычисление однородности отфильтрованного изображения. Однородность можно оценить с помощью показателей энтропии или дисперсии. Энтропия измеряет случайность в распределении значений отфильтрованного изображения и может быть рассчитана как:

$$H = -\sum p(i) \log_2 p(i),$$

где H – энтропия, $p(i)$ – вероятность уровня интенсивности i в отфильтрованном изображении. Эта формула определяет количество информации или беспорядка: более высокие значения указывают на меньшую однородность.

Аналогично, дисперсия измеряет дисперсию значений интенсивности в отфильтрованном изображении:

$$\operatorname{Var} = \sum (i - \mu)^2 p(i),$$

где μ – средняя интенсивность отфильтрованного изображения.

Путем расчета энтропии или дисперсии можно количественно оценить однородность текстуры, выделяющейся в определенном направлении. Это дает представление об анализе патологических тканей, которые могут демонстрировать анизотропные структуры текстуры, особенно в биологических условиях, таких как мутации *EGFR* в узлах легких, где однородность или изменчивость этих текстур может быть показательным признаком.

Совместная встречаемость текстурных переходов (Co-occurrence of Texture Transitions, CTT). В рамках повышения диагностической точности обнаружения мутаций *EGFR* в узлах легких представлен новый текстурный признак, «совместная встречаемость текстурных переходов» (CTT). Этот признак предназначен для количественной оценки пространственных отношений между различными текстурами, подчеркивая переходы между этими текстурами в области интереса. Опираясь на *GLCM*, CTT смещает фокус с изменений уровня серого на переходы текстурных узоров, предлагая детальное представление о сложности и разнообразии текстур.

Целью CTT является уловить тонкости эволюции текстуры на медицинских изображениях, анализируя, как различные текстуры взаимодействуют в пространстве. В отличие от традиционного *GLCM*, который оценивает пространственные зависимости на уровне серого, CTT углубляется в область текстурных переходов, обеспечивая понимание базовой структуры ткани и потенциально выявляя маркеры, указывающие на патологические изменения.

Вычисление CTT включает в себя несколько ключевых шагов, каждый из которых способствует извлечению этого расширенного признака:

1. Идентификация текстуры. Первый шаг в вычислении CTT включает в себя различие между текстурами в пределах области интереса. Эта дифференциация достигается за счет подхода кластеризации, при котором дескрипторы текстур, такие как локальные бинарные шаблоны (*Local Binary Patterns, LBP*), служат основой для группировки похожих текстур. Оператор *LBP* является дескриптором текстуры и определяется для каждого пикселя путем сравнения его с соседями:

$$LBP(x_c, y_c) = \sum_{p=0}^{P-1} s(i_p - i_c) 2^p,$$

где i_c – интенсивность центрального пикселя, i_p – интенсивности окружающих пикселей P в круговой окрестности, а s – знаковая функция:

$$s(x) = \begin{cases} 1, & \text{если } x \geq 0 \\ 0, & \text{иначе} \end{cases}.$$

Затем к значениям *LBP* применяется кластеризация, такая как метод K -средних, для выявления различных текстурных шаблонов в области интереса. Этот

шаг имеет решающее значение для понимания сложности и эволюции текстуры медицинских изображений, поскольку он позволяет количественно оценить пространственные отношения между различными текстурами, что может быть особенно полезно для обнаружения биомаркеров, таких как мутации *EGFR* в узлах легких.

2. Генерация матрицы перехода текстур (Texture Transition Matrix, TTM). После идентификации уникальных текстурных шаблонов строится TTM, отражающая концепцию *GLCM*, но фокусирующаяся на текстурных переходах. Каждый элемент в этой матрице количественно определяет частоту переходов между рисунком текстуры и рисунком текстуры с учетом заданного расстояния и направления. Формулировка TTM позволяет исследовать совпадения текстурных рисунков, подчеркивая пространственное взаимодействие текстур в пределах области интереса.

3. Статистический анализ TTM. Последний шаг включает в себя вычисление статистических показателей TTM для извлечения значимых признаков, отражающих переходы текстур. Обычно используемые статистические данные включают контраст, корреляцию и энергию, которые определяются следующим образом:

- контраст: измеряет контраст интенсивности между пикселем и его соседом по всему изображению.

$$Contrast = \sum_{i,j} (i - j)^2 TTM(i, j),$$

- корреляция: оценивает степень корреляции пикселя со своим соседом по всему изображению.

$$Correlation = \sum_{i,j} \frac{(i - \mu_i)(j - \mu_j) TTM(i, j)}{\sigma_i \sigma_j},$$

- энергия: сумма квадратов элементов в TTM, указывающая на однородность текстуры.

$$Energy = \sum_{i,j} TTM(i, j)^2,$$

где μ_i , μ_j – средние значения, а σ_i , σ_j – стандартные отклонения сумм строк и столбцов TTM соответственно.

Энергетические метрики полезны для выявления однородных текстурных рисунков на изображениях, поскольку высокие значения энергии обычно указывают на более высокую согласованность текстуры, что полезно для различения состояний тканей с различными характеристиками текстуры.

Для сравнения и анализа предложенных признаков был также подготовлен базовый набор признаков, которых содержит следующие признаки:

- признаки интенсивности (средняя интенсивность, стандартное отклонение, асимметрия, эксцесс);
- признаки, основанные на форме (объем, площадь поверхности, сферичность, компактность),

- текстурные признаки (основаны на признаках Харалика, которые описывают текстуру изображения на основе матрицы распределения совпадений интенсивности (gray-level co-occurrence matrix, GLCM) и включают такие метрики, как энтропия, контрастность, однородность, корреляция).

Результаты

Одним из важнейших направлений в медицинской визуализации является классификация опухолевых узелков в легких, особенно с точки зрения определения наличия мутаций в гене *EGFR*. Мутации *EGFR* часто связаны с немелкоклеточным раком легких (НМРЛ) и могут существенно влиять на выбор терапии. Традиционно для выявления таких мутаций используются радиомические признаки, извлекаемые из КТ-изображений, которые включают различные аспекты данных изображения, такие как форма, интенсивность и текстура. Эти признаки позволяют выполнить количественный анализ структурных и текстурных характеристик узелков, что имеет критическое значение для точной диагностики и персонализации лечения. В данном исследовании предпринята попытка улучшить точность классификации узелков в легких посредством внедрения новых радиомических признаков, что может обеспечить более четкое различие между классами *Mutant* и *Wildtype* для мутаций *EGFR*, повысить точность диагностики и улучшить стратегии лечения.

Классификация легочных узелков на *Mutant* и *Wildtype* *EGFR* на основе КТ первоначально проводилась с использованием традиционных радиомических методов. Основная цель заключалась в том, чтобы определить способность этих радиомических признаков обнаруживать мутации в узелках легких. В ходе экспериментов был обучен и протестирован классификатор на основе метода опорных векторов (*Support Vector Machine, SVM*) с «Радиальной базисной функцией» в качестве ядра. Набор данных был разделён на обучающий (1492 примера – 80 % от общего набора) и тестовый (373 примера – 20 % от общего набора). Обучение проводилось в среде Matlab на вычислительной платформе с процессором Intel Core i7 3.70 ГГц и 32 ГБ ОЗУ.

В табл. 1 представлены результаты классификации на базовом наборе признаков и на наборе, в состав которого входят предложенные признаки.

Табл. 1. Результаты классификации легочных узелков

Метрика	Обучающий набор		Тестовый набор	
	До	После	До	После
Accuracy (%)	89	93	88	92
Precision (%)	88	93	91	95

Предложенные признаки были разработаны для выявления сложных текстурных структур и изменений внутри легочных узелков, потенциально указывающих на лежащие в их основе генетические мутации. После

включения этих новых признаков в существующий набор признаков радиомики наблюдалось значительное улучшение эффективности классификации. В частности, добавление *ATC*, *DTU* и *CTT* привело к среднему увеличению точности прогнозирования статуса мутации *EGFR* примерно на 4 %. Это улучшение подчеркивает ключевую роль предложенной информации о текстуре в характеристике и дифференциации узелков.

Для дальнейшей проверки вклада и важности предложенных признаков в исследовании использовался алгоритм отбора признаков *mRMR* (*minimum Redundancy Maximum Relevance*, минимальная избыточность – максимальная релевантность) [15]. Алгоритм *mRMR* эффективен при выявлении подмножества признаков, которые в совокупности демонстрируют наибольшую релевантность целевой переменной, сохраняя при этом минимальную избыточность между собой. Как видно на рис. 3, анализ *mRMR* показывает, что признаки *ATC*, *DTU* и *CTT* занимают первые места в рейтинге с оценками 0,8, 0,79 и 0,74 соответственно. Это подчеркивает их ключевую роль в модели классификации. Этот результат не только подтверждает полезность предложенных признаков для повышения точности прогнозирования, но также подчеркивает их внутреннюю способность собирать важную диагностическую информацию, которая тесно связана со статусом мутации *EGFR*.




Рис. 3. Результаты анализа *mRMR*

Наблюдаемое улучшение производительности и анализ *mRMR* в совокупности свидетельствуют о потенциале включения новых предложенных текстурных признаков в радиомический анализ для классификации узелков в легких. Эффективно используя эти признаки, предлагаемая методология обеспечивает более детальное и всестороннее понимание микроокружения опухоли, тем самым способствуя повышению точности диагностики и персонализированным стратегиям лечения пациентов с раком легких. Эти результаты свидетельствуют о необходимости дальнейшего изучения и интеграции инновационных признаков радиомики в стремлении повысить точность прогнозирования генетических мутаций и характеристики рака.

Обсуждение

Для сравнения результатов были выбраны работы [2], [16], [17], [18] и [19], которые использовали различные подходы для прогнозирования мутаций *EGFR* и *KRAS* на основе анализа КТ-изображений.

В исследовании [16] была разработана модель глубокого обучения под названием Mut-SeResNet, которая использовалась для предсказания мультигенных мутаций, включая EGFR и KRAS, на КТ-изображениях рака легких. Модель достигла точности 88,3 % для мутаций EGFR. В [2] предложена модель, основанная на глубоком обучении, которая сочетает в себе радиомику и методы глубокого обучения для прогнозирования статуса мутации EGFR у пациентов с немелкоклеточным раком легких (НМРЛ). Эта модель достигла точности 88 %, что подчеркивает эффективность использования семантических признаков в сочетании с радиомикой для улучшения точности предсказаний.

В исследовании [17] был применен метод трехмерной радиомики, основанный на машинном обучении, для одновременного предсказания нескольких мутаций, включая EGFR, KRAS, ERBB2 и TP53. В данной работе точность предсказания мутаций EGFR составила 75 %, а KRAS – 70 %. В исследовании [18] использовалась многоканальная многозадачная модель глубокого обучения для предсказания мутаций EGFR и KRAS на КТ-изображениях. Точность предсказания мутаций EGFR составила 79 %, а KRAS – 72 %. Наконец, в работе [19] применялись методы радиомики, основанные на машинном обучении, для предсказания мутаций EGFR и KRAS с точностью 83 % и 86 % соответственно.

Предложенные новые радиомические признаки (ATC, DTU и CTT) позволили достичь точность 92 % для предсказания мутаций EGFR. Этот результат подчеркивает эффективность использования предложенных текстурных признаков для анализа КТ-изображений легких.

В табл. 2 представлено сравнение точностей различных методов предсказания мутаций EGFR и KRAS.

Табл. 2. Сравнение результатов данного исследования с другими исследованиями

Исследование	Тип мутации	Accuracy (%)
Наша работа	EGFR	92
Mut-SeResNet [16]	EGFR	88
Модель [2]	EGFR	87
Machine Learning-Derived Three-Dimensional Radiomics [17]	EGFR	75
	KRAS	70
Multi-channel multi-task deep learning [18]	EGFR	79
	KRAS	72
Machine Learning-Based Radiomics [19]	EGFR	83
	KRAS	86

Предложенные признаки могут быть адаптированы для анализа КТ- и МРТ-изображений других органов. Например, онкология мозга – область, где текстурные признаки могут способствовать улучшению диагностики опухолей и прогнозированию их агрессивности [20]. В кардиологии текстурные признаки могут помочь в диагностике кардиомиопатий и других заболеваний сердца, анализируя структуру миокарда на МРТ [21]. В диагностике заболеваний печени КТ-

изображения с текстурным анализом могут использоваться для дифференцирования фиброза, цирроза и гепатоцеллюлярной карциномы [22].

Исследования показывают, что методы анализа текстуры КТ-изображений могут достигать высокой точности в различных медицинских приложениях. Например, в диагностике рака печени радиомические признаки достигли точности до 94 % в дифференциации доброкачественных и злокачественных опухолей [23]. В диагностике сердечных заболеваний текстурный анализ МРТ использовался для прогнозирования риска сердечной недостаточности с точностью около 82 % [24]. В области нейрорадиологии, радиомика продемонстрировала потенциал в прогнозировании опухолевой градиции глиобластом, достигая точности более 65 % [25].

Заключение

В работе был предложен и внедрен новый метод извлечения текстурных признаков из медицинских КТ-изображений, ориентированный на обнаружение конкретных типов мутаций. Результаты этой работы подчеркивают возросшую способность этих методов точно идентифицировать мутации и представляют собой важный шаг вперед в области диагностической визуализации. До введения этих признаков точность *Accuracy* и *Precision* находились на уровне 88 % и 91 % соответственно. После внедрения *ATC*, *DTU* и *CTT*, *Accuracy* и *Precision* улучшились до 92 % и 95 % соответственно. Это улучшение подчеркивает важную роль новых текстурных признаков в распознавании патологических изменений в легких.

Таким образом, эти признаки имеют значение для медицинской диагностики и раннего выявления условий, которые могут быть опасны для жизни, если их не определить своевременно. Они значительно способствуют повышению точности и надёжности диагностических процессов, облегчая лучшие исходы для пациентов через более раннее вмешательство и более целенаправленные стратегии лечения.

Благодарности

Исследование выполнено за счет гранта Российского научного фонда № 24-25-00204, <https://rscf.ru/project/24-25-00204/>

References

- [1] Shariaty F, Pavlov VA, Zavjalov SV, Orooji M, Pervunina TM. Application of a texture appearance model for segmentation of lung nodules on computed tomography of the chest. *Journal of the Russian Universities. Radioelectronics* 2022; 25(3): 96-117. DOI: 10.32603/1993-8985-2022-25-3-96-117.
- [2] Mahajan A, Kania V, Agarwal U, Ashtekar R, Shukla S, Patil V. M, Prabhash K. Deep-learning-based predictive imaging biomarker model for EGFR mutation status in non-small cell lung cancer from CT imaging. *Cancers* 2024; 16(6): 1130. DOI:10.3390/cancers16061130.
- [3] Hou J, Shi H, Gao W, Lin P, Li B, Shi Y, Matveeva I, Zakharov V, Bratchenko I. The preliminary study of diabetic retinopathy detection based on intensity parameters with optical coherence tomography angiography. *Computer Optics* 2023; 47(4): 620-626. DOI: 10.18287/2412-6179-CO-1261.

- [4] Li X, Chi X, Huang P, Liang Q, Liu J. Deep neural network for the prediction of KRAS, NRAS, and BRAF genotypes in left-sided colorectal cancer based on histopathologic images. *Comput Med Imaging Graph* 2024; 115: 102384. DOI: 10.1016/j.compmedimag.2024.102384.
- [5] Shariaty F, Pavlov VA, Fedyashina SV, Serebrennikov NA. Integrating deep learning and explainable AI for non-invasive prediction of EGFR and KRAS mutations in NSCLC: A novel radiogenomic approach. *2024 V Int Conf on Neural Networks and Neurotechnologies (NeuroNT)* 2024: 32-35. DOI: 10.1109/NeuroNT62606.2024.10585441.
- [6] Shariaty F, Mousavi M, Moradi A, Oshnari MN, Navvabi S, Orooji M, Novikov B. Semi-automatic segmentation of COVID-19 infection in lung CT scans. In Book: Velichko E, Kapralova V, Karaseov P, Zavjalov S, Angueira P, Andreev S, eds. *International youth conference on electronics, telecommunications and information technologies: Proceedings of the YETI 2021, St. Petersburg, Russia*. Cham, Switzerland: Springer Nature Switzerland AG; 2022: 67-76. DOI: 10.1007/978-3-030-81119-8_7.
- [7] Pavlov VA, Shariaty F, Orooji M, Velichko EN. Application of deep learning techniques for detection of COVID-19 using lung CT scans: model development and validation. In Book: Velichko E, Kapralova V, Karaseov P, Zavjalov S, Angueira P, Andreev S, eds. *International youth conference on electronics, telecommunications and information technologies: Proceedings of the YETI 2021, St. Petersburg, Russia*. Cham, Switzerland: Springer Nature Switzerland AG; 2022: 85-96. DOI: 10.1007/978-3-030-81119-8_9.
- [8] Haralick R, Shanmugam K, Dinstein I. Textural features for image classification. *IEEE Trans Syst Man Cybern* 1973; 3(6): 610-621. DOI: 10.1109/TSMC.1973.4309314.
- [9] Liu Q, Liu X. Feature extraction of human viruses microscopic images using gray level co-occurrence matrix. *Int Conf on Computer Sciences and Applications* 2013: 619-622. DOI: 10.1109/CSA.2013.149.
- [10] Huang W, et al. Arterial spin labeling images synthesis from sMRI using unbalanced deep discriminant learning. *IEEE T Med Imaging* 2019; 38(10): 2338-2351. DOI: 10.1109/TMI.2019.2906677.
- [11] Bakr S, Gevaert O, Echegaray S, Ayers K, Zhou M, Shafiq M, Zheng H, Benson JA, Zhang W, Leung AN, Kadoch M. A radiogenomic dataset of non-small cell lung cancer. *Sci Data* 2018; 5(1): 180202. DOI: 10.1038/sdata.2018.202.
- [12] NSCLC Radiogenomics. 2024. Source: <<https://www.cancerimagingarchive.net/collection/nsclc-radiogenomics/>>.
- [13] Peli E. Contrast in complex images. *J Opt Soc Am A* 1990; 7(10): 2032-2040. DOI: 10.1364/JOSAA.7.002032.
- [14] Shariaty F, Caiqin H, Pavlov VA, Duan L, Zavjalov SV, Pervunina TM, Ying W. Integrating quantitative and convolutional features to enhance the efficiency of pathology classification in CT imaging. *Computing, Telecommunications and Control* 2023; 16(4): 60-69. DOI: 10.18721/JCSTCS.16406.
- [15] Ding C, Peng H. Minimum redundancy feature selection from microarray gene expression data. *Computational Systems Bioinformatics*. CSB2003. Proceedings of the 2003 IEEE Bioinformatics Conference. CSB2003 2003: 523-528. DOI: 10.1109/CSB.2003.1227396.
- [16] Sun L, Dong Y, Xu S, Feng X, Fan X. Predicting multi-gene mutation based on lung cancer CT images and MutSeResNet. *Appl Sci* 2023; 13(3): 1921. DOI: 10.3390/app13031921.
- [17] Zhang T, Xu Z, Liu G, Jiang B, de Bock GH, Groen HJ, Xie X. Simultaneous identification of EGFR, KRAS, ERBB2, and TP53 mutations in patients with non-small cell lung cancer by machine learning-derived three-dimensional radiomics. *Cancers* 2021; 13(8): 1814. DOI: 10.3390/cancers13081814.
- [18] Dong Y, Hou L, Yang W, Han J, Wang J, Qiang Y, Yang X. Multi-channel multi-task deep learning for predicting EGFR and KRAS mutations of non-small cell lung cancer on CT images. *Quant Imaging Med Surg* 2021; 11(6). DOI: 10.21037/qims-20-600.
- [19] Le NQK, Kha QH, Nguyen VH, Chen YC, Cheng SJ, Chen CY. Machine learning-based radiomics signatures for EGFR and KRAS mutations prediction in non-small-cell lung cancer. *Int J Mol Sci* 2021; 22(17): 9254. DOI: 10.3390/ijms22179254.
- [20] Chaddad A, Desrosiers C, Toews M. Radiomic analysis of multi-contrast brain MRI for the prediction of survival in patients with glioblastoma multiforme. *2016 38th Annual Int Conf of the IEEE Engineering in Medicine and Biology Society (EMBC)* 2016: 4035-4038. DOI: 10.1109/EMBC.2016.7591612.
- [21] Pujadas ER, Raisi-Estabragh Z, Szabo L, McCracken C, Morcillo CI, Campello VM, Martín-Isla C, Atehortua AM, Vago H, Merkely B, Maurovich-Horvat P. Prediction of incident cardiovascular events using machine learning and CMR radiomics. *Eur Radiol* 2023; 33(5): 3488-3500. DOI: 10.1007/s00330-022-09323-z.
- [22] Lubner MG, Smith AD, Sandrasegaran K, Sahani DV, Pickhardt PJ. CT texture analysis: definitions, applications, biologic correlates, and challenges. *Radiographics* 2017; 37(5): 1483-1503. DOI: 10.1148/rg.2017170056.
- [23] Yao Z, Dong Y, Wu G, Zhang Q, Yang D, Yu JH, Wang WP. Preoperative diagnosis and prediction of hepatocellular carcinoma: Radiomics analysis based on multi-modal ultrasound images. *BMC Cancer* 2018; 18: 1089. DOI: 10.1186/s12885-018-5003-4.
- [24] Durmaz ES, Karabacak M, Ozkara BB, Kargin OA, Raimoglu U, Tokdil H, Durmaz E, Adaletli I. Radiomics-based machine learning models in STEMI: a promising tool for the prediction of major adverse cardiac events. *Eur Radiol* 2023; 33(7):4611-20. DOI: 10.1007/s00330-023-09394-6.
- [25] Choi Y, Jang J, Kim BS, Ahn KJ. Pretreatment MR-based radiomics in patients with glioblastoma: A systematic review and meta-analysis of prognostic endpoints. *Eur J Radiol* 2023; 168: 111130. DOI: 10.1016/j.ejrad.2023.111130.

Сведения об авторах

Шариати Фаридоддин, 1997 года рождения, ассистент, Институт электроники и телекоммуникаций, Санкт-Петербургский политехнический университет Петра Великого (СПбПУ), Санкт-Петербург.
E-mail: Shariaty3@gmail.com. Orcid: 0000-0002-7060-8826

Павлов Виталий Александрович, 1989 года рождения, к.т.н., доцент, Институт электроники и телекоммуникаций, Санкт-Петербургский политехнический университет Петра Великого (СПбПУ), Санкт-Петербург.
E-mail: pavlov_va@spbstu.ru. Orcid: 0000-0003-0726-6613

ГРНТИ: 28.23.15

Поступила в редакцию 27 июня 2024 г. Окончательный вариант – 12 сентября 2024 г.

Improving the efficiency of CT image analysis using new texture radiomics features

F. Shariaty¹, V. A. Pavlov¹

¹ Peter the Great St. Petersburg Polytechnic University,
Polytechnicheskaya 29, St. Petersburg, 195251, Russia

Abstract

This article discusses the development of feature extraction techniques from medical images to improve diagnosis and data analysis in oncology. Three new radiomic features for analyzing lung CT images are presented: adaptive texture contrast (ATC), directional texture uniformity (DTU), and co-occurrence of texture transitions (CTT). These features are specifically designed to improve the analysis of lung CT images, which can have a significant impact on the diagnostic accuracy and recognition of EGFR mutations. This article details the methods and algorithms used to create and test these features, and presents results demonstrating a 4% improvement in Accuracy and Precision for the task of detecting EGFR mutations compared to traditional methods. This study highlights the potential of integrating novel radiomic signatures into clinical practice for more accurate and efficient diagnosis of lung cancer.

Keywords: radiomic features, CT images, classification.

Citation: Shariaty F, Pavlov VA. Improving the efficiency of CT image analysis using new texture radiomics features. *Computer Optics* 2025; 49(5): 811-817. DOI: 10.18287/2412-6179-CO-1581.

Acknowledgements: This research was funded by the Russian Science Foundation (RSF) under grant No. 24-25-00204. <https://rscf.ru/en/project/24-25-00204/>.

Author's information

Faridoddin Shariaty, (b. 1997), Research Assistant, Institute of Electronics and Telecommunications, Peter the Great St. Petersburg Polytechnic University, Saint-Petersburg. E-mail: Shariaty3@gmail.com. Orcid: [0000-0002-7060-8826](https://orcid.org/0000-0002-7060-8826)

Vitalii Pavlov, (b. 1989), Associate professor, Institute of Electronics and Telecommunications, Peter the Great St. Petersburg Polytechnic University, Saint-Petersburg, PhD. E-mail: pavlov_va@spbstu.ru. Orcid: [0000-0003-0726-6613](https://orcid.org/0000-0003-0726-6613)

Received June 27, 2023. The final version – September 12, 2024.
