

Гибридный подход к классификации изображений облачности

А.И. Елизаров^{✉1}, А.В. Шалеев^{1,2}, И.И. Гальцев^{2*}

¹*Институт оптики атмосферы им. В.Е. Зуева СО РАН
634055, г. Томск, пл. Академика Зуева, 1*

²*Национальный исследовательский Томский государственный университет
634050, г. Томск, пр. Ленина, 36*

Поступила в редакцию 04.03.2025;

после доработки 28.03.2025;

принята к печати 31.03.2025

Рассматривается проблема классификации изображений облачности, представляющих собой сложные текстурные структуры с неоднородными характеристиками. Традиционные методы анализа изображений не всегда справляются с классификацией таких изображений, а современные технологии глубокого обучения требуют больших объемов данных и вычислительных ресурсов. Исследование фокусируется на оценке возможности разработки гибридного метода, сочетающего традиционные статистические подходы к описанию текстур и современные технологии глубокого обучения. Предполагалось, что высокоуровневые признаки, которые нейронная сеть выделяет при обучении, могут быть недостаточно чувствительны к тонким локальным различиям облачных образований. Был реализован и проанализирован гибридный подход: перед анализом нейросетью из изображений извлекались низкоуровневые текстурные характеристики. Однако результаты тестирования показали, что такая методика не только не улучшила качество классификации, но и оказалась менее эффективной по точности в сравнении с использованием необработанных изображений. Результаты работы могут быть интересны специалистам в области анализа данных дистанционного зондирования Земли, метеорологии и при разработке новых методов анализа текстурных изображений.

Ключевые слова: классификация изображений, текстурные характеристики, обработка изображений, нейронные сети; image classification, texture characteristics, image processing, neural network.

Введение

В условиях роста объемов данных, в том числе изображений, первоочередной задачей становится структурирование и анализ визуальной информации. Особое место занимают задачи анализа изображений, которые включают два основных направления: сегментацию и классификацию. Эти задачи направлены на выделение значимых областей или объектов на изображении и их последующую категоризацию. Сегментация позволяет разделять изображение на области, соответствующие различным объектам или описываемые определенными характеристиками. Классификация присваивает каждой выделенной области метку, соответствующую определенному классу. Сегментация и классификация дополняют друг друга, обеспечивая комплексный анализ изображений, а в случае, например, семантической сегментации разделение на области происходит на основании предварительной классификации регионов или отдельных пикселей изображения.

В рамках решения задач компьютерного зрения анализ изображения начинается с классификации пиксельных областей изображения на основе их характеристик, таких как цвет, текстура, форма. Задача классификации усложняется, когда объекты имеют неоднородную текстуру (например, изображения с резкими переходами яркости и сложными узорами), варьирующиеся формы и меняющиеся параметры освещения. Точность и надежность анализа изображения напрямую зависят от того, насколько удачно выбраны признаки, описывающие изображение в целом или его отдельные фрагменты (пиксели). Признаки изображений являются основой для решения задач сегментации и классификации [1]. Выбор признаков зависит от конкретной задачи и типа данных. Они могут быть как низкоуровневыми, используемыми для описания характеристик изображения на уровне пикселей или небольших областей, так и высокоуровневыми, отражающими семантические или абстрактные свойства изображения, которые могут быть интерпретированы человеком [2].

В задачах компьютерного зрения одним из характерных признаков считается текстура. Традиционно текстурные признаки относятся к низкоуровневым,

* Алексей Игоревич Елизаров (alex@iao.ru); Артем Викторович Шалеев (sav@iao.ru); Иван Игоревич Гальцев (el.galtsev@gmail.com).

поскольку они описывают базовые локальные свойства изображения, получаемые напрямую из распределения яркости или цвета пикселей (например, с помощью операторов Габора, метода локальных бинарных шаблонов (ЛБШ) и т.п.). Текстуриный анализ широко применяется в задачах обработки изображений, начиная с аэрокосмических и спутниковых снимков и заканчивая биомедицинскими исследованиями. Особо актуально это в метеорологии и климатологии, где необходимо анализировать облачность по спутниковым или наземным снимкам для прогнозирования погоды, мониторинга атмосферы и исследования климатических процессов [3, 4].

Изображения облачности представляют собой сложные текстурные структуры, которые делают их идеальным объектом для тестирования методов анализа текстур. Однако проблема использования текстурных особенностей изображений заключается в том, что статистические методы формирования признаков не всегда обеспечивают достаточную точность, а нейросетевые модели требуют значительных объемов данных и вычислительных ресурсов в процессе обучения.

Таким образом, проблема сводится не только к поиску и к выбору признаков, описывающих неоднородную природу облачности (морфологические особенности), но и к разработке метода классификации и оценки его применимости, что и является целью данного исследования.

Материалы и методы

Характерные признаки изображений

При решении задач сегментации или классификации выбор набора признаков обычно определяется тем, какой вид яркостной, цветовой, геометрической, текстурной структуры характерен для анализируемых данных. Характерные признаки изображений — это атрибуты или свойства, которые используются для описания визуальных данных и позволяют различать объекты, области или классы внутри изображений. Как было отмечено ранее, в классических методах описания изображений признаки изображения разделяют на низкоуровневые, среднеуровневые и высокоуровневые [5].

Низкоуровневые признаки — это базовые характеристики, непосредственно извлекаемые из пикселей или отдельных областей изображения (например, яркость, цвет, контраст). Такие признаки являются фундаментом для дальнейшего анализа, поскольку отражают первичные физические свойства изображения без семантической интерпретации. Низкоуровневые признаки чувствительны к локальным изменениям, что позволяет точно фиксировать тонкие переходы и детали, характерные для облачности.

Среднеуровневые признаки представляют собой объединение низкоуровневых характеристик для описания локальных структур (например, границы, особых точек или однородных областей). Однако при их вычислении происходит обобщение информации, что может привести к утрате мелких дета-

лей, необходимых для точного определения принадлежности облачности к определенному классу.

Высокоуровневые признаки представляют собой семантические конструкции, которые отражают комплексные объекты или сцены. Они часто извлекаются с помощью нейронных сетей, где последовательные слои сети преобразуют низкоуровневые данные в абстрактные представления, способные описывать целые объекты или их части.

При извлечении признаков изображений облачности цветовые и краевые характеристики могут оказаться недостаточными по нескольким причинам. Облака не обладают четкой формой, а распределение яркости имеет широкий диапазон. Следовательно, недостаточно полагаться только на цвет, яркость или геометрические формы. Граница облака может быть размытой, поэтому простые детекторы контуров дают много ложных срабатываний. В таких случаях текстурные признаки, описывающие локальные неоднородности, способны лучше отразить детали и переходы внутри облака. В отличие от цветовых характеристик многие текстурные признаки облаков обладают устойчивостью к изменению условий регистрации изображений. В свою очередь, современные нейронные сети демонстрируют высокую эффективность в задачах анализа изображений благодаря «автоматическому» извлечению признаков, устойчивости к изменениям масштаба, освещения и поворотов. Поэтому представляется целесообразным для анализа изображений облачности использовать сочетание текстурных характеристик и методов глубокого обучения. Во многих работах отмечается, что такое сочетание может быть полезно, когда необходимо повысить точность обучения на небольшом наборе данных [6–8]. Предварительно вычисленные текстурные признаки могут способствовать более быстрому обучению нейронной сети за счет использования уже обработанной информации о локальных особенностях изображения.

Методы описания текстур

Для количественного описания текстур разработано множество методов, имеющих свою специфику и области применения. По принципу формирования текстурных признаков методы можно разделить на статистические, спектральные и на основе глубокого обучения.

Статистические методы основываются на вычислении статистических характеристик распределения яркостей пикселей по всему изображению или выбранной области. Они позволяют количественно описать текстуру без явного выделения ее структурных элементов. Эти признаки могут основываться на комбинации цветовой интенсивности в определенных позициях относительно каждой точки изображения. Также можно использовать и статистическое распределение различных геометрических элементов (границы, вершины, фигуры и т.д.), которое позволяет описывать специфические свойства текстуры.

Первоначальное развитие методов анализа текстуры связано с работой Р. Харалика [9], где предложена матрица совместной встречаемости (или

матрица смежности) для количественного описания структурных особенностей изображений. Этот метод позволяет оценить, как часто пары пикселей с определенными значениями интенсивности встречаются в заданном пространственном отношении. На основе этой матрицы вычисляются различные текстурные признаки, такие как контраст, однородность, энергия и энтропия. Этот метод учитывает пространственные зависимости между пикселями, что делает его эффективным для описания сложных текстур. Сильными сторонами этого подхода считаются его хорошая интерпретируемость, гибкость и высокая результативность при анализе текстур с повторяющимися структурами. Поскольку рассчитываемая матрица смежности основана на отношениях между пикселями, она менее чувствительна к глобальным изменениям яркости или контраста, что важно для анализа облачных изображений [10, 11]. К слабым сторонам можно отнести высокую вычислительную сложность, чувствительность к параметрам, необходимость предварительного квантования значений яркости, ограниченную устойчивость к шуму, изменению масштаба и ориентации текстур.

Другой подход — метод локальных бинарных шаблонов, основанный на применении к изображению простого оконного оператора для сравнения интенсивности центрального пикселя с его соседями (рис. 1, а) [12]. Некоторые бинарные коды, называемые равномерными ЛБШ, содержат больше информации, чем другие. Равномерные ЛБШ позволяют обнаруживать важные локальные особенности на изображении, такие как концы линий, грани, углы и пятна (рис. 1, б) [13]. Результаты вычисления ЛБШ в виде бинарных чисел могут быть сгруппированы в так называемую гистограмму пространственных разностей, которая может использоваться как вектор признаков, описывающих текстурные особенности изображения. Результат вычисления признаков можно представить и в виде изображения, когда выполняется преобразование бинарного кода в интенсивность с помощью матрицы бинарного кода (рис. 1, в).

К достоинствам метода относятся простота вычислений, возможность локального анализа текстуры, инвариантность к изменению освещения. Подход хорош для изображений с явными текстурными структурами (например, рельеф, растительность). К недостаткам можно отнести чувствительность к шуму, особенно на краях и в однородных областях, ограниченность в выделении сложных и глобальных текстур, недостаточная эффективность для гладких областей изображения [14, 15].

В работе [16] был предложен метод измерения энергии текстур по различным направлениям и пространственным частотам в пределах окна фиксированного размера. Для выделения различных текстурных свойств предложен базовый набор векторов на основе различных комбинаций, который формирует двумерные маски (фильтры). Таким образом можно генерировать матрицы, чувствительные к таким характеристикам текстуры, как




Рис. 1. Формирование ЛБШ: пороговая бинаризация (а), типовые локальные структуры (б), формирование двоичного ЛБШ-кода и его перевод в десятичное представление (в)

гладкость, края, рябь, волнистость, частота повторяемости. Каждая маска применяется к изображению с помощью свертки. В результате получаются новые изображения, подчеркивающие различные текстурные характеристики. Метод прост в реализации, обладает низкими вычислительными затратами, позволяет выделять текстуры с четкими направлениями (горизонтальные, вертикальные и диагональные). Но ограниченная инвариантность к изменениям масштаба и ориентации делает метод менее подходящим для сложных сценариев, например дистанционного зондирования, где объекты сильно варьируются по размеру и форме.

Спектральные методы анализа текстуры основаны на анализе частотных компонентов изображения. Эти методы базируются на преобразовании Фурье и его модификациях и позволяют выделять элементы, которые трудно обнаружить в пространственной области. Основными методами спектрального анализа текстуры являются Фурье-преобразование, вейвлет, фильтры Габора [17–22]. Спектральные методы хорошо справляются с выявлением регулярных и периодических структур, таких как текстуры тканей, плитки, сеток или волновых структур. Методы позволяют анализировать текстуру на разных уровнях детализации, что делает их полезными для анализа сложных элементов с вариативной структурой [23–25]. Спектральные методы часто чувствительны к шумам в изображении, что критично в ситуациях, когда рассматриваемый фрагмент имеет слабо выраженные частотные компоненты. Это приводит к проблемам при работе и в ситуациях с недостаточным освещением, когда объекты имеют слабо выраженные контуры.

С развитием сверточных нейронных сетей (СНС) появились автоматизированные подходы к извлечению признаков из изображений, способные выявлять

как низкоуровневые (границы, углы), так и высокоуровневые особенности (сложные формы и контексты). Архитектуры, такие как ResNet, VGG16 и U-Net, показали высокую точность и надежность при решении задач сегментации и классификации изображений [26–30]. Современные архитектуры сетей и подходы к обучению (например, аугментация данных) обеспечивают устойчивость к поворотам, изменениям масштаба и освещения. Однако такой подход требует значительных вычислительных ресурсов и достаточного объема обучающих данных, что делает его крайне непривлекательным для применения. Кроме того, результаты обучения часто трудно интерпретировать, что особенно важно в задачах, где требуется объяснить, почему сеть приняла то или иное решение.

Анализируя преимущества и недостатки методов описания текстуры изображений, можно сделать вывод, что универсального подхода не существует. Для устранения недостатков и усиления преимущества отдельных методов целесообразно комбинировать различные подходы. В ряде источников предлагаются гибридные подходы, предусматривающие предварительную обработку изображений с использованием классических (статистических или спектральных) методов с последующим применением сверточных нейронных сетей. Такие подходы сочетают интерпретируемость и вычислительную эффективность традиционных алгоритмов с адаптивностью и мощностью глубоких моделей. Мы предлагаем гибридный подход, объединяющий технологии глубокого обучения и классические методы извлечения признаков.

Гибридный подход

Как было отмечено ранее, облачность характеризуется сложной текстурой, проявляющейся в плавных градиентах или резких перепадах яркости и разнообразии структурных элементов. Это делает изображения облаков хорошим тестовым набором для проверки способности алгоритма классификации различать текстурные области. Разные типы облаков имеют уникальные текстурные и морфологические признаки. Это позволяет протестировать устойчивость подхода к изменениям текстур и форм в пределах одной сцены. На изображениях облаков часто присутствуют смешанные текстуры, например пересечение кучевых и перистых облаков, что дает возможность проверить, как гибридный подход справляется с разделением сложных граничных областей.

Для классификации изображений облачности использовалась СНС, гиперпараметры которой изменялись по результатам верификации на наборе данных. Для формирования базы изображений для обучения и тестирования сети из открытых источников в Интернете было собрано 1751 изображение облачности различного разрешения. Это количество оказалось недостаточным, поэтому размер базы изображений был увеличен до 44824 путем зеркального отображения и поворота исходных снимков. Сформированная база содержит 10 раз-

личных морфологических классов облаков согласно Международной классификации облачности [31]: слоистые (Stratus (*St*)), кучевые (Cumulus (*Cu*)), слоисто-кучевые (Stratocumulus (*Sc*)), кучево-дождевые (Cumulonimbus (*Cb*)), слоисто-дождевые (Nimbostratus (*Ns*)), высокослоистые (Altostratus (*As*)), высококучевые (Alto cumulus (*Ac*)), перистые (Cirrus (*Ci*)), перисто-слоистые (Cirrostratus (*Cs*)), перисто-кучевые (Cirro cumulus (*Cc*)).

В исследовании использовались обучающие и тестовые выборки, составленные из изображений, собранных из открытых источников сети Интернет, которые, как правило, представляют собой снимки облачности, размеченные экспертами по классам. Однако получение достоверно размеченных данных на сегодняшний день представляет существенную сложность. При детальном рассмотрении известные наборы данных, такие как GRSCD (Ground based Remote Sensing Cloud Database) [32] или CCSN (Cirrus Cumulus Stratus Nimbus Database) [33], содержат ошибки. Например, некоторые изображения ввиду их низкого качества непригодны для надежной классификации, а другие содержат лишь небольшие фрагменты облачности, что также затрудняет классификацию. Остальные доступные наборы данных, например база данных изображений [34], хотя и отличаются существенным объемом, не содержат разметку по классам.

По итогам тестирования различных топологий СНС была подобрана конфигурация из восьми сверточных слоев, четырех слоев пулинга, пяти слоев регуляризации (dropout), двух полносвязных слоев и выходного слоя. Первый уровень представляет собой сверточный слой, который использует 64 фильтра размером 3×3 пикселя для обработки входящего изображения. Эти фильтры выделяют определенные особенности изображения, что способствует повышению точности классификации. Затем следуют еще один сверточный слой и слой пулинга, который уменьшает размерность выходных данных предыдущего слоя, сохраняя при этом наиболее важные признаки. Это позволяет уменьшить количество параметров и таким образом упростить обработку данных в последующих слоях.

Следующие слои также являются сверточными и пулинг-слоями, которые повторяют процесс извлечения признаков изображения и уменьшения размерности данных. Далее идет вспомогательный выравнивающий слой (flatten), который преобразует многомерный тензор (например, 3D-тензор из сверточного слоя) в одномерный вектор. Этот слой позволяет передавать данные в полносвязный слой. Последние слои являются полносвязными, они преобразуют вектор признаков в выходные данные, представляющие собой вероятности принадлежности к каждому из классов. Для предотвращения переобучения применяются слои dropout. В результате общее количество обучаемых параметров в этой сети составляет 13604938. Каждая из моделей со своими гиперпараметрами прошла 150 эпох обучения на наборе изображений облачности.

Результаты и обсуждение

В рамках гибридного подхода все изображения перед классификацией нейронной сетью предварительно обрабатываются с целью извлечения текстурных признаков. В качестве методов получения признаков были выбраны метод ЛБШ, фильтр Габор, а также рассчитанные по исходным изображениям значения дисперсии, однородности, контраста, энтропии и энергии. Вся обработка выполнялась внутри скользящего окна размером 5×5 пикселей с шагом смещения один пиксель. Рассчитанное значение характеристики присваивалось центральному элементу в окне. Результат фильтрации представляется в виде двумерного массива или изо-

бражения, отображающего результат предобработки. Примеры предварительной обработки, сформированные на основе вычисленных признаков, приведены на рис. 2.

Нейронная сеть обучалась уже на этих предварительно обработанных изображениях для каждого признака в отдельности. Тестирование выполнялось на 124 изображениях с известной морфологической принадлежностью облачности, подготовленных аналогичным образом и не участвовавших в обучении. Результаты классификации, полученные с помощью разработанной нейросетевой топологии и гибридного подхода, с вычисленной вероятностью принадлежности к определенным классам представлены на рис. 3.




Рис. 2. Визуализация результатов предварительной обработки: исходное изображение (а); признаки, рассчитанные на основе статистических методов: контраст (б), энергия (в), энтропия (з), однородность (д), дисперсия (е); признаки, полученные с использованием фильтров Габор (ж) и методом ЛБШ (з)




Рис. 3. Результаты классификаций изображений облачности с помощью НС, полученные без предварительной обработки (а, б); результат работы гибридного подхода с предварительно вычисленным признакам: энергия (в), контраст (з); в легенде отражена вероятность принадлежности изображения к определенному классу

Таблица 1

Оценка качества классификации СНС, обученной на наборе исходных изображений (скорость обучения 0,01; количество эпох 150; размер блока 64)

Признак	Класс облаков										Accu- racy	Среднее	Средне- взве- шанное
	<i>Ac</i>	<i>As</i>	<i>Cb</i>	<i>Cc</i>	<i>Ci</i>	<i>Cs</i>	<i>Cu</i>	<i>Ns</i>	<i>Sc</i>	<i>St</i>			
Precision	0,98	1,00	0,99	0,97	1,00	1,00	0,99	0,97	1,00	1,00	0,99	0,99	0,99
Recall	0,98	0,98	0,98	0,99	0,99	0,99	1,00	0,99	0,99	1,00		0,99	0,99
F1-score	0,98	0,99	0,98	0,98	0,99	1,00	0,99	0,98	0,99	1,00		0,99	0,99
Support	1022	1059	1142	1198	1179	1271	1187	1157	958	1031		11204	11204

Таблица 2

Точность определения классовой принадлежности облачности, %

Признак	Класс облаков										Среднее
	<i>Ac</i>	<i>As</i>	<i>Cb</i>	<i>Cc</i>	<i>Ci</i>	<i>Cs</i>	<i>Cu</i>	<i>Ns</i>	<i>Sc</i>	<i>St</i>	
Контраст	87,0	91,0	84,0	84,0	81,0	92,0	87,0	90,0	80,0	92,0	86,8
Энергия	85,0	88,0	84,0	87,0	87,0	88,0	85,0	86,0	87,0	88,0	86,5
Энтропия	32,0	28,0	42,0	59,0	25,0	23,0	39,0	22,0	25,0	52,0	34,7
Однородность	74,0	81,0	79,0	67,0	77,0	89,0	85,0	78,0	66,0	79,0	77,5
Дисперсия	62,0	83,0	62,0	59,0	65,0	83,0	63,0	68,0	58,0	94,0	69,7
ЛБШ	72,0	84,0	63,0	69,0	76,0	88,0	70,0	76,0	72,0	85,0	75,5
Габор	80,0	88,0	80,0	91,0	90,0	89,0	84,0	87,0	78,0	93,0	86,0
Исходное	98,0	100,0	99,0	97,0	100,0	100,0	99,0	97,0	100,0	100,0	99,0

Для объективной оценки качества обучения была построена динамика функции потерь и точности на валидационной выборке для нейросетей, обученных как на текстурированных (получают во время предварительной фильтрации), так и на исходных изображениях (в статье не приводятся). Для оригинальных изображений графики продемонстрировали более стабильное снижение потерь и значительное повышение точности, что указывает на лучшую обучаемость модели при использовании исходных данных.

Оценка нейросети, обученной на исходных изображениях, приведена в табл. 1. Чтобы понять, насколько хорошо работает эта модель, рассмотрим каждую из метрик.

1. Precision (точность) — мера того, насколько точно модель определяет предсказанный объект. В табл. 1 значения precision для каждого класса выше 0,97. Это говорит о том, что модель точно определяет каждый класс.

2. Recall (полнота) — мера того, насколько хорошо модель классифицирует все предсказанные объекты. Значения recall для каждого класса выше 0,97 (модель классифицирует почти все предсказанные объекты).

3. F1-score — среднее гармоническое между точностью и полнотой, которое учитывает обе метрики; F1-score > 0,97 для каждого класса (модель имеет высокую точность и полноту для каждого класса).

4. Support (поддержка) — количество объектов в каждом классе. Количество объектов разное для разных классов, но все классы имеют достаточно объектов для обучения модели.

5. Accuracy (точность) — мера того, насколько точно модель классифицирует все объекты; accuracy = 0,99 (модель правильно классифицирует 99% объектов).

Точность определения класса облачности с помощью НС представлена в табл. 2. Последняя строка в таблице отображает результаты определения принадлежности облачности к определенному классу, полученные при обучении нейронной сети на исходных изображениях без использования предобработки.

Как видно из табл. 2, классификация облачности по сформированным в результате предварительной обработки признакам, таким как энтропия, дисперсия и ЛБШ, имеет меньшую точность по сравнению с остальными признаками. Например, для признака «энтропия» среднее значение равно 34,7 при стандартном отклонении 12,3, что подчеркивает нестабильность этого признака.

Заключение

Реализованный гибридный подход с предложенной авторами топологией НС показал, что текстурные характеристики, выделенные классическими методами, могут быть несущественными для задач классификации с применением глубокого обучения. Значения функций потерь на проверочных выборках оказываются существенными, а точность классификации облачности снижается. Достаточно высокую надежность показали тесты на исходных изображениях, что свидетельствует об удачно выбранной топологии нейронной сети. Такой результат можно объяснить тем, что нейросеть самостоятельно извлекает признаки из изображений, не ограничиваясь характеристиками, получаемыми при использовании классических методов анализа. Полученные результаты можно объяснить также недостаточным объемом размеченных экспертами обучающих данных.

Возможно, для повышения точности классификации изображений облачности следует применять комбинации различных текстурных признаков. Таким образом, изучение и тестирование гибридных методов является важным направлением дальнейших исследований для разработки более точных и надежных систем анализа изображений.

Финансирование. Исследования выполнены в рамках госзадания ИОА СО РАН.

Список литературы

1. *Hassaballah M., Abdelmgeid A.A., Alshazly H.A.* Image features detection, description, and matching // Image Feature Detectors and Descriptors: Foundations and Applications. Cham: Springer, 2016. P. 11–45. DOI: 10.1007/978-3-319-28854-3_2.
2. *Lei B.J., Hendriks E.A., Reinders M.J.T.* On feature extraction from images. URL: https://www.academia.edu/656131/On_Feature_Extraction_from_Images (last access: 04.04.2025).
3. *Блощинский В.Д., Крамарева Л.С., Шамилова Ю.А.* Детектирование облачного покрова с использованием нейронной сети по данным прибора МСУ-ГС космического аппарата «Арктика-М» № 1 // Оптика атмосф. и океана. 2024. Т. 37, № 2. С. 99–104. DOI: 10.15372/AOO20240202; *Bloshchinskiy V.D., Kramareva L.S., Shamilova Yu.A.* Cloud cover detection using a neural network based on MSU-GS instrument data of Arktika-M No. 1 Satellite // Atmos. Ocean. Opt. 2024. V. 37, N 3. P. 394–399.
4. *Астафуров В.Г., Скороходов А.В., Курьянович К.В., Митрофаненко Я.К.* Характеристики различных типов облачности над природными зонами Западной Сибири по спутниковым данным MODIS // Оптика атмосф. и океана. 2020. Т. 33, № 4. С. 266–271. DOI: 10.15372/AOO20200404; *Astafurov V.G., Skorokhodov A.V., Kur'yanovich K.V., Mitrofanenko Ya.K.* Parameters of different cloud types over the natural zones of Western Siberia according to MODIS satellite data // Atmos. Ocean. Opt. 2020. V. 33, N 5. P. 512–518.
5. *Тассов К.Л., Бекасов Д.Е.* Обработка перекрытий в задачах отслеживания объектов в видеопотоке // Инженерный журнал: наука и инновации. 2013. № 6. С. 1–27. DOI: 10.18698/2308-6033-2013-6-1099.
6. *Ravi R., Yadhukrishna S.V., Prithviraj R.* A face expression recognition using CNN & LBP // 2020 Fourth International Conference on Computing Methodologies and Communication (ICCMC). New York: IEEE, 2020. P. 684–689. DOI: 10.1109/ICCMC48092.2020.ICCMC-000127.
7. *Hamdi M., Ebrahim M.S., Jadhav M.E., Olayah F., Awaji B., Alalayah K.M.* Hybrid models based on fusion features of a CNN and handcrafted features for accurate histopathological image analysis for Diagnosing malignant lymphomas // DiagnStics. 2023. V. 13, N 13. P. 2258. DOI: 10.3390/diagnStics13132258.
8. *Gurunathan A., Krishnan B.A.* Hybrid CNN-GLCM classifier for detection and grade classification of brain tumor // Brain Imaging Behav. 2022. V. 16, N 3. P. 1410–1427. DOI: 10.1007/s11682-021-00598-2.
9. *Haralick R.M., Shanmugam K., Dinstein I.H.* Textural features for image classification // IEEE Trans. Syst. Man Cybern. 1973. V. SMC-3, N 6. P. 610–621. DOI: 10.1109/TSMC.1973.4309314.
10. *Nurtanio I., Zainuddin Z., Setiadi B.H.* Cloud classification based on images texture features // IOP Conf. Ser.: Mater. Sci. Eng. 2019. V. 676, N 1. P. 012015. DOI: 10.1088/1757-899X/676/1/012015.
11. *Ameur Z., Ameur S., Adane A., Sauvageot H., Bara K.* Cloud classification using the textural features of Meteosat images // Int. J. Remote Sens. 2004. V. 25, N 21. P. 4491–4503. DOI: 10.1080/01431160410001735120.
12. *Ojala T., Pietikainen M., Harwood D.* Performance evaluation of texture measures with classification based on Kullback discrimination of distributions // Proc. 12th International Conference on Pattern Recognition. V. 1. 1994. P. 582–585. DOI: 10.1109/ICPR.1994.576366.
13. *Петрук В., Самородов А.В., Спиридонов И.Н.* Применение локальных бинарных шаблонов к решению задачи распознавания лиц // Вестн. Моск. гос. техн. ун-та им. Н.Э. Баумана. Сер. Приборостроение. 2011. № 5. С. 58–63.
14. *Wang Y., Cunzhaio S., Wang C., Xiao B.* Ground-based cloud classification by learning stable local binary patterns // Atmos. Res. 2018. V. 207. P. 74–89. DOI: 10.1016/j.atmosres.2018.02.023.
15. *Oikonomou S., Kazantzidis A., Econmou G., Fotopoulos S.* A local binary pattern classification approach for cloud types derived from all-sky imagers // Int. J. Remote Sens. 2019. V. 40, N 7. P. 2667–2682. DOI: 10.1080/01431161.2018.1530807.
16. *Laws K.I.* Rapid texture identification // Proc. SPIE. 1980. V. 238. P. 376–380. DOI: 10.1117/12.959169.
17. *Mallat S.G.* A theory for multiresolution signal decomposition: The wavelet representation // IEEE Trans. Pattern Anal. Mach. Intell. 1989. V. 11, N 7. P. 674–693. DOI: 10.1109/34.192463.
18. *Histograms of oriented gradients.* URL: <https://courses.cs.duke.edu/fall17/compsci527/Ntes/hog.pdf> (last access: 05.12.2024).
19. *Харалик Р.М.* Статистический и структурный подходы к описанию текстур // ТИИЭР. 1979. Т. 67, № 5. С. 98–120.
20. *Gonzalez R.C., Wood R.E.* Digital Image Processing, 4th ed. London: Pearson, 2017. 1192 p.
21. *Unser M.* Texture classification and segmentation using wavelet frames // IEEE Trans. Image Process. 1995. V. 4, N 11. P. 1549–1560. DOI: 10.1109/83.469936.
22. *Turner M.R.* Texture discrimination by Gabor functions // Biol. Cyber. 1986. V. 55, N 2. P. 71–82. DOI: 10.1007/BF00341922.
23. *Recio J.A.R., Fernandez L.A.R., Fernández-Sarriá A.* Use of Gabor filters for texture classification of digital images // Física de la Tierra. 2005. V. 17. P. 47.
24. *Шлеймович М.П., Ляшева С.А., Куртичников А.П.* Вычисление признаков изображений на основе вейвлет-преобразования // Вестн. технол. ун-та. 2015. Т. 18, № 18. С. 223–228.
25. *Фраленко В.П.* Методы текстурного анализа изображений, обработка данных дистанционного зондирования Земли // Программные системы: теория и приложения. 2014. Т. 5, № 4. С. 19–39.
26. *ResNet (34, 50, 101): «остаточные» CNN для классификации изображений.* URL: <https://neurohive.io/ru/vidy-nejrosetej/resnet-34-50-101> (дата обращения: 15.03.2023).
27. *VGG16 – нейросеть для выделения признаков изображений.* URL: <https://neurohive.io/ru/vidy-nejrosetej/vgg16-model/> (дата обращения: 15.03.2023).
28. *Liang J.* Image classification based on RESNET // J. Phys. Conf. Ser. 2020. V. 1634, N 1. P. 012110. DOI: 10.1088/1742-6596/1634/1/012110.

29. *Very Deep Convolutional Networks for Large-Scale Image Recognition*. URL: <https://doi.org/10.48550/arXiv.1409.1556> (last access: 15.03.2023).
30. *Improved U-net remote sensing classification algorithm based on multi-feature fusion perception* // *Remote Sens.* 2022. V. 14, N 5. P. 1118. DOI: 10.3990/rs14051118.
31. *Хромов С.П., Петросян М.А.* Метеорология и климатология: учеб. пособие. М.: МГУ, 2012. 584 с.
32. *TJNU ground-based remote sensing cloud database (TJNU-GRSCD)*. URL: <https://github.com/shuang-liutjnu/TJNU-Ground-based-Remote-Sensing-Cloud-Database> (last access: 21.03.2025).
33. *Cirrus Cumulus Stratus Nimbus (CCSN) Database*. URL: <https://data-verse.harvard.edu/dataset.xhtml?persistentId=doi:10.7910/DVN/CADDPD> (last access: 21.03.2025).
34. *Галилейский В.П., Елизаров А.И., Кокарев Д.В., Морозов А.М.* База данных изображений облачного поля над городом Томск // Свидетельство о государственной регистрации базы данных № 2018620430 от 14.03.2018. Правообладатель: Федеральное государственное бюджетное учреждение науки Институт оптики атмосферы им. В.Е. Зуева Сибирского отделения Российской академии наук (ИОА СО РАН) (RU).

A.I. Elizarov, A.V. Shaleev, I.I. Galtsev. A hybrid approach to cloud image classification.

This paper considers the problem of classifying cloud images, which are complex texture structures with heterogeneous characteristics. Traditional image analysis methods do not always adequately classify such images, and modern deep learning methods require large amount of data and computational resources. The research focuses on evaluating the feasibility of developing a hybrid method combining traditional statistical approaches to texture description and state-of-the-art deep learning techniques. It was hypothesised that the high-level features extracted by a neural network during training can be insufficiently sensitive to subtle local differences in cloud formations. The hybrid approach was implemented and analysed; low-level texture features were extracted from the images before being analysed by the neural network. However, the test results showed that this technique did not improve the classification quality and turned out to be less effective in terms of accuracy compared to the use of unprocessed images. The results of this work can be of interest to specialists in of Earth remote sensing data analysis, meteorology, and development of new texture image analysis methods.