


УДК 004.021:004.75

КЛАССИФИКАЦИЯ И АНАЛИЗ СНИМКОВ ЗЕМНОЙ ПОВЕРХНОСТИ



Е.И. Ковшер
Ассистент кафедры ЭВМ
БГУИР, магистрант
группы 356301
elizavetakovsher@mail.ru



Д.Ю. Перцев
Кандидат технических наук,
кафедра ЭВМ, БГУИР
pertsev@bsuir.by

Е.И. Ковшер

Окончила Белорусский государственный университет информатики и радиоэлектроники. Область научных интересов связана с исследованием искусственного интеллекта и методов машинного обучения.

Д.Ю. Перцев

Окончил аспирантуру Белорусского государственного университета информатики и радиоэлектроники (2016), защитил диссертацию в совете 05.13.01 (2020). Является доцентом кафедры ЭВМ.

Аннотация. В статье выполнен анализ методов и алгоритмов классификации снимков земной поверхности. Исследованы подходы к эффективному разделению изображений на различные классы, что имеет важное значение для обработки больших объемов данных, получаемых с помощью спутниковых снимков и аэро съемки.

Ключевые слова: Машинное обучение, нейронные сети, кластеризация, обработка геоинформационных данных.

Введение. В период стремительного технологического развития аэро съемки и взрывного роста объема геоинформационных данных, алгоритмы автоматизированной классификации объектов на снимках земной поверхности становятся ключевым компонентом их обработки и анализа. Современные методы аэро съемки, такие как спутниковые снимки, аэро съемка с беспилотных летательных аппаратов (БПЛА), предоставляют огромные объемы данных, требующие эффективных методов обработки и классификации.

В современных условиях, когда географическая среда подвергается быстрым изменениям, задача классификации объектов на снимках земной поверхности становится более актуальной. Способность быстро и осознанно реагировать на эти изменения становится ключевой, а данные о землеустройстве становятся важными в таких областях, как градостроительство, сельское хозяйство и экология.

Геоинформационные системы (ГИС) играют важную роль в обработке и анализе снимков. ГИС обеспечивают интеграцию данных и их визуализацию, а передовые технологии в этой области значительно повышают эффективность классификации, предоставляя уникальные возможности для практического применения результатов [1].

Эффективные методы классификации объектов на снимках земной поверхности становятся ключевыми в различных областях, от оптимизации сельского хозяйства до

мониторинга городского развития и выявления изменений в экосистемах. Результаты классификации служат основой для стратегических решений.

В условиях постоянного увеличения объема данных обеспечение надежности и точности объектов на снимках земной поверхности становится критически важным. Это не только гарантирует корректность полученных данных, но и служит основой для принятия обоснованных решений в различных секторах человеческой деятельности [2].

Классическое обучение для классификации объектов на снимках земной поверхности. Первые алгоритмы основывались на применении теории математической статистики и появились в 1950-е годы. Целью алгоритма являлось формализовать процессы, связанные с выявлением статистических закономерностей в числовых данных, оценкой схожести точек в многомерных пространствах и определением направлений в данных. В настоящее время значительная часть современного интернета основывается на применении классических алгоритмов, которые, начиная с пятидесятых годов, продолжают эффективно решать различные формальные задачи, предоставляя механизмы для выявления структурных особенностей и обработки данных в различных областях. Методы классического обучения представлены на рисунке 1.



Рисунок 1. Методы классического обучения.

Обучение с учителем в контексте классификации снимков земной поверхности – это метод машинного обучения, основанный на использовании размеченных обучающих данных [3]. В этом подходе каждый снимок в обучающем наборе данных имеет соответствующую разметку, где каждый участок земли отнесен к определенному классу (категории). Например, к классам могут относиться такие объекты, как лес, вода, городская застройка и другие.

Классификация начинается с формирования обучающего набора данных, где для каждой области на снимке определен её класс. Этот набор используется для обучения модели машинного обучения. В качестве модели могут использоваться различные методы, включая метод опорных векторов (*SVM*), случайные леса или нейронные сети. Схема обучения представлена на рисунке 2.

При обучении модель извлекает признаки из снимков, такие как цвет, текстура, форма и другие характеристики, которые могут быть репрезентативными для определенных классов. Эти признаки используются для построения алгоритма, который может классифицировать новые, ранее не «виденные» данные.

После завершения обучения модель применяется к новым снимкам земной поверхности, где она предсказывает классы для каждой области. Этот процесс

обеспечивает автоматическую классификацию больших объемов данных, что может быть весьма полезным для различных целей, таких как мониторинг изменений в экосистемах, анализ использования сельскохозяйственных угодий или планирование городского развития.

Однако для успешного обучения модели требуется значительный объем размеченных данных, что может быть трудоемким и дорогостоящим процессом.

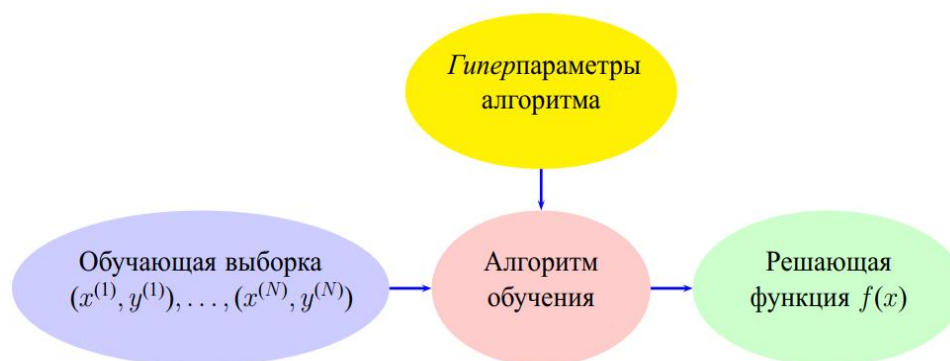


Рисунок 2. Схема обучения с учителем

Обучение без учителя в контексте анализа снимков земной поверхности представляет собой подход, призванный извлекать скрытые закономерности и структуры из больших объемов данных, не требуя предварительной разметки. Этот метод является эффективным инструментом в условиях, когда получение размеченных обучающих данных может быть сложным или дорогостоящим [3].

Одним из ключевых подходов в обучении без учителя для анализа снимков земли является кластеризация. Данный метод направлен на группировку схожих участков земли на основе их признаков, таких как цвет, текстура или другие характеристики. Например, алгоритмы кластеризации могут объединять участки с похожими спектральными характеристиками, что может указывать на схожие типы покрытия, такие как лес, вода или городская застройка.

На первом этапе выбирается метод кластеризации, например, k -средних или иерархическая кластеризация, и определяются признаки для анализа, такие как спектральные и текстурные характеристики снимков. Далее данные подвергаются предобработке, включая нормализацию и устранение шума. Применяется выбранный метод кластеризации, который группирует схожие участки земли в кластеры. Результаты оцениваются с использованием таких метрик, как коэффициент силуэта, затем выполняется интерпретация каждого кластера, связывая его с определенным типом покрытия (вода, лес, городская застройка и т. д.).

Обучение включает в себя итерации для уточнения параметров и выбора оптимальных методов предобработки, а также использование метрик для объективной оценки результатов. Этот подход позволяет автоматически выделять структуры на земной поверхности без явной разметки данных, что может быть полезным в мониторинге изменений в экосистемах, анализе использования сельскохозяйственных угодий и планировании городского развития.

Другой важный аспект обучения без учителя в данной области – это методы понижения размерности. Эти методы позволяют сократить число признаков, оставляя наиболее информативные аспекты данных [4]. Это может быть полезным при работе с большими массивами информации, такими как космические снимки, где эффективное извлечение ключевых характеристик спектральных данных может улучшить процесс анализа.

Примерами методов обучения без учителя для анализа снимков земли также являются методы ассоциативного правила, позволяющие выявлять «интересные» взаимосвязи и закономерности между различными областями земной поверхности, а также методы генеративных моделей, которые строят вероятностные модели для данных, что может быть полезным при синтезе новых областей, которые не анализировались ранее.

Таким образом, обучение без учителя в анализе снимков земной поверхности предоставляет мощный инструмент для обнаружения паттернов, выделения характеристик и сжатия информации, что может быть ключевым в условиях стремительного развития технологий аэросъемки и обработки геоинформационных данных.

Ансамбли для классификации снимков земной поверхности. Ансамбли в контексте классификации снимков земной поверхности представляют собой метод машинного обучения, основанный на комбинировании результатов нескольких моделей для улучшения общей производительности и точности предсказаний.

При построении ансамбля создаются различные модели, используя вариации параметров. Эти модели затем объединяются для формирования более надежного и точного прогноза. В контексте классификации снимков земной поверхности, ансамбли могут быть применены для улучшения определения типов покрытия, таких как вода, лес, городская застройка и другие. Методы ансамблей представлены на рисунке 3.



Рисунок 3. Методы ансамблей

Популярные методы ансамблей включают в себя случайный лес (англ. *Random Forest*) и бустинг (англ. *Boosting*). Случайный лес – это алгоритм, который строит несколько деревьев решений при обучении и объединяет их для формирования более надежного и устойчивого предсказания. Каждое дерево строится на основе случайной подвыборки данных и случайного подмножества признаков. Это обеспечивает разнообразие моделей в ансамбле, что способствует улучшению обобщающей способности. При классификации каждое дерево голосует за определенный класс, и класс с наибольшим количеством голосов становится окончательным предсказанием. Бустинг – это метод, который последовательно обучает модели, уделяя больше внимания неправильно классифицированным данным на каждом этапе. Это позволяет улучшать точность предсказаний по мере итераций. Один из популярных вариантов бустинга – градиентный бустинг (англ. *Gradient Boosting*), который минимизирует ошибку, используя градиент функции потерь. Этот процесс приводит к созданию ансамбля, где каждая модель корректирует ошибки предыдущей, что приводит к повышению общей производительности [5].

Применение ансамблей в анализе снимков земной поверхности позволяет значительно улучшить обобщающую способность моделей и повысить эффективность классификации при обработке обширных объемов геоинформационных данных. Этот

подход становится важным элементом в арсенале методов для обеспечения точности и стабильности в решении задач классификации снимков земной поверхности.

Нейросети и глубокое обучение для классификации снимков земной поверхности. Глубокое обучение и нейросети представляют современный и мощный подход к классификации снимков земной поверхности. Нейросети, особенно свёрточные (*CNN*), являются ключевыми инструментами, способными автоматически извлекать сложные паттерны и признаки из данных. Методы глубокого обучения представлены на рисунке 4. Процесс начинается с тщательной подготовки размеченных данных, где каждый снимок земли связан с соответствующим классом.

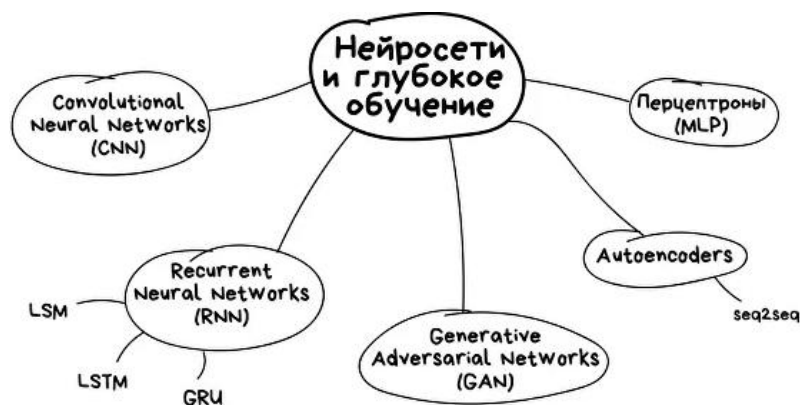


Рисунок 4. Методы глубокого обучения

Выбор подходящей архитектуры нейросети играет важную роль в обработке изображений. Свёрточные нейронные сети оптимизированы для эффективного извлечения признаков, что особенно важно при анализе снимков земли. Обучение модели включает в себя передачу данных через слои сети и корректировку весов на основе обучающих данных.

После завершения обучения модель проверяется на проверочном наборе данных для оценки её обобщающей способности. Затем выполняется тестирование на отдельном тестовом наборе для проверки точности и эффективности на новых данных. Тонкая настройка гиперпараметров модели требуется для предотвращения переобучения и оптимальной производительности [6].

В дальнейшем обученная модель может быть успешно применена к новым снимкам земной поверхности, автоматически классифицируя объекты в соответствии с предварительно определенными классами. Важно отметить, что для успешного применения глубокого обучения требуется значительный объем размеченных данных и вычислительные ресурсы.

Рекуррентные нейронные сети (англ. *RNN*) также могут быть включены в набор методов для анализа снимков земной поверхности. В отличие от сверточных нейронных сетей, *RNN* специализируются на обработке последовательных данных и могут быть полезны при работе с временными рядами или изображениями, где важна пространственная и временная зависимость.

В контексте анализа снимков земли, *RNN* могут использоваться, например, для учёта изменений в природных условиях или сезонных колебаний. Модели *RNN* позволяют анализировать последовательности снимков с течением времени и выявлять паттерны, которые могут быть важны для понимания динамики на земной поверхности.

Обучение *RNN* также включает в себя передачу данных через временные слои, и адаптацию весов в соответствии с обучающими данными. Такие модели предоставляют возможность учесть контекст и историю данных при классификации [7].

Однако, следует отметить, что *RNN* также могут сталкиваться с проблемой исчезающего градиента, особенно при работе с длинными последовательностями данных. В таких случаях, более современные архитектуры, такие как долгая краткосрочная память (англ. *LSTM*) или *Gated Recurrent Unit (GRU)*, могут использоваться для решения указанной проблемы.

Таким образом, *RNN* предоставляют дополнительные возможности для анализа снимков Земли, особенно там, где важна временная динамика и изменения с течением времени.

Генеративные состязательные сети (англ. *GAN*) представляют собой другой метод, состоящий из двух основных компонентов: генератора и дискриминатора.

Генератор создает новые изображения, имитируя реальные данные. В контексте снимков земной поверхности, генератор может создавать синтетические изображения, которые соответствуют различным классам покрытия, таким как леса, водные поверхности, города и т.д. Дискриминатор, с другой стороны, оценивает, насколько изображение соотносится между реальным и сгенерированным.

Процесс обучения представляет собой взаимодействие между генератором и дискриминатором. Генератор стремится к совершенствованию своей способности создания реалистичных изображений, в то время как дискриминатор улучшает свою способность отличать поддельные изображения от настоящих [8].

В контексте снимков земной поверхности, *GAN* могут использоваться для создания новых, несуществующих изображений, которые, тем не менее, выглядят правдоподобно. Это может быть полезным в ситуациях, где не хватает данных или для аугментации существующего набора данных.

Однако стоит отметить, что обучение *GAN* может быть сложным, и требует тщательной настройки параметров для достижения стабильного и качественного результата.

Многослойные перцептроны (англ. *MLP*) представляют собой класс нейронных сетей, состоящих из нескольких слоев: входного слоя, скрытых слоев и выходного слоя. В контексте классификации снимков земной поверхности, *MLP* являются эффективным инструментом для извлечения сложных закономерностей из данных:

- входной слой. На этом слое каждый нейрон представляет собой определенный признак снимка, такой как цвет, текстура или другие характеристики.

- скрытые слои. Эти слои служат для извлечения абстрактных иерархических признаков из входных данных. Каждый нейрон в скрытом слое соединен со всеми нейронами предыдущего и последующего слоя.

- выходной слой. На этом слое каждый нейрон представляет собой класс объекта или тип покрытия земли (например, лес, вода, город). Выходы этих нейронов могут интерпретироваться как вероятности принадлежности объекта к каждому классу.

Процесс обучения включает в себя передачу данных через сеть, расчет предсказаний и сравнение их с фактическими метками классов. Алгоритм обратного распространения ошибки используется для корректировки весов нейронов, чтобы минимизировать ошибку предсказания. Этот процесс повторяется на множестве эпох обучения [9].

Преимущества *MLP* включают их способность моделировать сложные нелинейные отношения между признаками и классами. Они также могут автоматически извлекать признаки из данных, что упрощает процесс обучения.

Однако для успешного обучения *MLP* требуется большой объем размеченных данных, и процесс обучения может быть вычислительно интенсивным, особенно при использовании глубоких архитектур.

Заключение. Методы классификации снимков земной поверхности представляют разнообразные подходы, варьирующиеся от классических алгоритмов до передовых

технологий вроде нейросетей и глубокого обучения. Каждый из рассмотренных методов обладает своими преимуществами и ограничениями. Выбор метода машинного обучения для классификации и анализа снимков земной поверхности зависит от различных факторов, включая характеристики данных, объем данных, требования к точности, а также доступные ресурсы. Характеристики данных, такие как разрешение изображений, спектральные характеристики и текстурные особенности, могут влиять на эффективность различных методов. Объем данных, в свою очередь, может потребовать использование вычислительно эффективных алгоритмов или параллельных вычислений для обеспечения быстрой обработки. В данной области часто используется комбинация различных методов для достижения наилучших результатов. В дальнейшем планируется практическая реализация представленных методов классификации и сопоставление полученных результатов между собой.

Список литературы

- [1] Капралов Е.Г., Кошкарев А.В., Тикун В.С. и др. Основы геоинформатики. Уч. пособие. – М.: Изд. центр «Академия», 2004. – 480 с.
- [2] Шовенгердт Р.А. Дистанционное зондирование. Модели и методы обработки изображений. М.: Техносфера, 2010. – 560 с.
- [3] Васенков Д.В. Методы обучения искусственных нейронных сетей // Компьютерные инструменты в образовании. 2007. № 1. – 20 с.
- [4] Хайкин С. Нейронные сети. Полный курс. – М.: Вильямс, 2006. – 1104 с.
- [5] Viola P., Jones M.J. Robust real-time face detection // International Journal of Computer Vision, 2004 – 137 с.
- [6] Татьянkin, В. М. Подход к формированию архитектуры нейронной сети для распознавания образов / В. М. Татьянkin // Вестник Югорского государственного университета, 2016, – 61 с.
- [7] Никитин, К.В. Новый подход к применению рекуррентных нейронных сетей для решения задач распознавания образов, 2007 – 85 с.
- [8] Гудфеллоу, И.Дж. Генеративные состязательные сети в системах обработки нейронной информации / И.Дж. Гудфеллоу, Дж. Пуже-Абади, М. Мирза, Б. Сюй, Д. Вард-Фарли, С. Озер, А.С. Курвиль, Ю. Бенжио // 27-я Ежегодная конференция по нейронным системам. – 2014. – С. 2672-2680.
- [9] Толмачев С.Г., Системы искусственного интеллекта. Нейросетевые модели: учебное пособие, Балт. гос. техн. ун-т. – СПб., 2011 г. – 170 с.

Авторский вклад

Ковшер Елизавета Игоревна – обзор методов и алгоритмов, применяемых для классификации снимков земной поверхности.

Перцев Дмитрий Юрьевич – постановка задачи исследования, анализ полученных результатов.

CLASSIFICATION AND ANALYSIS OF EARTH SURFACE IMAGES

E. KOVSHER

*Assistant at the Department of
Electronic Computing Machines,
BSUIR, Master's student group
356301*

D. PERTSAU

*PhD,
Electronic Computing Machines
Department, BSUIR*

Abstract. In this article, an analysis of methods and algorithms for the classification of images of the Earth's surface has been conducted. Approaches to the effective separation of images into various classes were explored, which is crucial for processing large volumes of data obtained from satellite imagery and aerial photography.

Keywords: Machine Learning, Neural Networks, Clustering, Geoinformation Data Processing.