

ПРИМЕНЕНИЕ НЕЧЕТКОГО КЛАССИФИКАТОРА NEFCLASS К ЗАДАЧЕ РАСПОЗНАВАНИЯ ЗДАНИЙ НА СПУТНИКОВЫХ ИЗОБРАЖЕНИЯХ СВЕРХВЫСОКОГО РАЗРЕШЕНИЯ

В работе рассматривается применение нечеткого классификатора NEFClass к задаче распознавания зданий с разнообразными формами крыши на спутниковых изображениях сверхвысокого разрешения. Проводится сравнительный анализ методов обучения нейронной сети: генетического, градиентного и метода сопряженных градиентов касательно поставленной задачи.

This article discusses the application of fuzzy classifier NEFClass to the problem of recognition buildings in high resolution satellite imagery. Comparative analysis methods for neural network training: genetic, gradient and conjugate gradient method on the problem of recognizing buildings with different forms of the roof.

Введение

Задача автоматического распознавания и извлечения зданий из спутниковых изображений сверхвысокого разрешения является важной частью в решении задачи автоматической интерпретации данных, получаемых из систем дистанционного зондирования земли. Автоматическая система распознавания зданий позволит сократить временные и материальные затраты на обновление базы данных ГИС (географической информационной системы), анализ использования земельных ресурсов и поддержание городских геодезических данных в актуальном состоянии.

Целью данной статьи является подробное рассмотрение и анализ метода распознавания разнообразных крыш зданий на спутниковых изображениях сверхвысокого разрешения. В основе предлагаемого метода распознавания лежит нечеткий классификатор NEFClass [4] с различными алгоритмами обучения. В статье проводится сравнительный анализ результатов работы различных алгоритмов обучения с целью выбора наилучшего для решения задачи классификации разнообразных форм крыши.

Предложенные ранее работы в области распознавания зданий разработаны с учетом того, что исследования проводятся на спутниковых изображениях, взятых из конкретного региона, где все здания имеют определенный оттенок и форму крыши. Рассмотрим некоторые из этих работ. В работе [1] было предложено решение, в котором для распознавания крыш зданий используется множество самоорганизующихся карт (SOM). Используя представление о степе-

ни насыщенности оттенков цветного спутникового изображения, множество самоорганизующихся карт обучается распознавать прямоугольные крыши различных цветов. Этот подход дает правильный результат только в 53% случаях, решение предполагает, что все крыши зданий должны иметь прямоугольную форму. В [2] был разработан подход, в котором в качестве признаков были использованы оттенки крыш и расположение теней зданий. Эксперимент был проведен для 177 зданий с корректным завершением в 86,6% случаев. Данный подход предполагает, что крыши зданий имеют прямоугольную форму и хотя бы часть из этих крыш красного оттенка. В работе [3] предлагается алгоритм, основанный на геометрических признаках и площади крыш зданий. После сегментации изображения применяется линейный классификатор для идентификации крыш зданий в каждом из полученных сегментов. В статье были приведены результаты для 240 протестированных зданий, большинство из которых имели красную крышу, алгоритм имел проблемы с идентификацией зданий, имеющих крыши других оттенков.

Описываемый в данной статье подход позволяет использовать систему распознавания для разнообразных форм крыши зданий, находящихся в различных регионах. В качестве системы распознавания используется нейронная сеть, что дает гибкую и обучаемую систему, которая легко адаптируется для выполнения поставленной задачи.

Вычисление признаков объектов

В данной части статьи рассматриваются признаки, которые станут основой для распознавания крыш зданий на спутниковых изображениях.

В работе рассматривается 3 основных вида крыш: треугольная, плоская и круглая крыши. На Рис. 1 приведены примеры разнообразных форм каждого из рассматриваемых видов крыши.




Рис. 1. Примеры разнообразных форм крыши:
(а) здания с треугольной крышей
(б) здания с плоской крышей
(в) здания с круглой крышей

На основе знаний о геометрической форме крыш зданий были подобраны оптимальные признаки для распознавания. Рассмотрим подробнее используемые в работе признаки.

- Округлость крыши здания для каждого сегмента рассчитывается как отношение площади к периметру. Этот признак может принимать значения от 0 до 1. Округлость крыши вычисляется по следующей формуле:

$$\text{Округлость} = \frac{4\pi * \text{Площадь}}{\text{Периметр}^2}$$

где Площадь сегмента рассчитывается как количество принадлежащих ему пикселей, а Периметр сегмента рассчитывается как количество пикселей лежащих на границе области.

- Среднее значение углов [3]. Углы являются важным признаком, позволяющим дифференцировать крышу здания от других объектов. Для того чтобы определить значение углов в выделенном сегменте необходимо построить шестиугольник по следующей схеме: 1. Проводится главная ось между двумя точками контура, которые находятся

на максимальном расстоянии друг от друга. 2. Определяются две вспомогательные оси с каждой стороны главной оси. Для этого строим вертикальные линии, лежащие на главной оси и имеющие максимальное расстояние от контура до главной оси. 3. Проводим поперечную ось, это должна быть вертикальная линия на главной оси, которая соединяет две точки контура находящиеся на максимальном расстоянии друг от друга. 4. Полученные шесть точек соединяем линиями в шестиугольник. В качестве признаков возьмем среднее значение двух углов, находящиеся по обе стороны главной оси.

- Длина крыши здания определяется как отношение длины главной оси к длине поперечной оси, полученного выше шестиугольника [3]:

$$\text{Длина} = \frac{m_{20} + m_{02} + \sqrt{(m_{20} - m_{02})^2 + 4m_{11}^2}}{m_{20} + m_{02} - \sqrt{(m_{20} - m_{02})^2 + 4m_{11}^2}}$$

- Полнота вычисляется как отношение общего количества пикселей, которые лежат внутри шестиугольника и не принадлежат к исследуемой области к количеству пикселей, которые лежат за пределами шестиугольника и принадлежат исследуемому сегменту.
- Градиент яркости поверхности крыши. Для определения градиента яркости будет использован оператор Собеля, который вычисляет приближенное значение градиента яркости изображения. В результате применения оператора Собеля, в каждой точке изображения будет получен вектор градиента яркости в данной точке. Таким образом, будет найдено направление наибольшего увеличения яркости и величина её изменения в данном направлении. В разработанном алгоритме сегмент делится на 20 равных частей, в центре каждой из полученных частей вычисляется значение оператора Собеля. В зависимости от полученных направлений увеличения яркости можно говорить об одном из исследуемых видов крыш.

Экспериментальные исследования

Для проверки эффективности работы рассматриваемой нейронной сети были проведены

тесты на изображениях с различными видами крыш. Для проведения экспериментов было использовано 90 изображений, из них 60 изображений использовались для обучения нейронной сети. Спутниковые изображения, на которых преобладают здания с круглыми крышами, отбирались из регионов, имеющих пустынный ландшафт, с треугольными крышами - из пригородных территорий, с плоскими крышами - из территорий крупных городов. Для тестирования было использовано 30 спутниковых изображений.

В разработанной системе NEFClass входам нейронной сети соответствуют описанные выше 5 признаков: округлость крыши, среднее значение двух углов, длина крыши, полнота, градиент яркости поверхности крыши. Выходам сети соответствуют 3 исследуемых вида крыш: круглая, треугольная, плоская.

Для обучения была использована гауссовская функция принадлежности [4], поскольку она дает более реальные данные и обеспечивает гибкость настройки нейронной сети.

$$\mu(x) = \exp\left[-\left(\frac{x-c}{\sigma}\right)^2\right] \quad (1)$$

Эксперимент был поставлен следующим образом. Каждое изображение было предварительно обработано и сегментировано. Каждый полученный сегмент содержит изображение крыши одного из видов. Для генерации базы правил каждому сегменту на изображении ставится в соответствие подходящая форма крыши. Таким образом, создается база правил. Проводим обучение нейронной сети одним из выбранных методов: генетическим, градиентным или методом сопряженных градиентов [4]. Далее на обученную сеть подаем тестовое изображение, на выходе получаем изображение, на котором отмечены распознанные крыши различными цветами, в зависимости от формы крыши. Так круглые крыши будут отмечены желтым цветом, треугольные - синим, а плоские - красным.

Если сравнить реализованные алгоритмы обучения между собой, то можно увидеть, что

не все три метода справляются хорошо и можно отметить следующие тенденции. Метод сопряженных градиентов в начале обучения сходится значительно быстрее, чем обычный градиентный метод и в итоге дает лучший результат. Генетический же метод сходится гораздо медленнее градиентного метода и метода сопряженных градиентов. Кроме того, генетический метод отличается этапным улучшением суммарной погрешности, то есть при общей тенденции сходимости и медленном уменьшении ошибки, есть моменты довольно резкого уменьшения ошибки.

Необходимо отметить, что градиентный метод и метод сопряженных градиентов сошлись к ошибке, которая была ниже установленного порога, поэтому оказались лучше генетического алгоритма. Однако в случае большего количества итераций и, возможно, других данных генетический алгоритм мог оказаться лучше, о чем свидетельствуют результаты, полученные при выполнении работы и теоретические данные [4].

Сказанное выше проиллюстрировано на Рис. 2, который показывает зависимость суммарной погрешности от пройденных итераций по каждому из выбранных методов.

Рассмотрим график на Рис. 3, который показывает процесс обучения нейронной сети для каждого вида крыши, на примере обучения методом сопряженных градиентов, поскольку этот метод дал наилучший результат.

Можно увидеть, что наиболее легким примером для обучения нейронной сети были здания с плоскими крышами. Среди зданий этого типа наибольшее количество распознанных. В тоже время треугольная форма крыши была наиболее сложным примером для обучения и дольше других удерживала значение погрешности выше желаемого порога.

Также треугольная форма крыши чаще всего встречалась в нераспознанных образцах, что можно объяснить более сложной геометрической формой.




Рис. 2. Графическое представление зависимости суммарной погрешности от пройденных итераций




Рис. 3. Графическое представление зависимости погрешности от пройденных итераций для каждого вида крыши

Для эксперимента было отобрано 90 изображений – 60 для обучения и 30 для тестирования. Результаты обучения и классификации приведены в Табл. 1. По полученным результатам эксперимента можно сделать вывод, что наилучший результат был получен при обучении с помощью метода сопряженных градиентов.

о необходимости коррекции используемых признаков. Кроме того, наличие вокруг зданий на близком расстоянии деревьев в большом количестве увеличивает процент ошибочно классифицированных образцов. Это верно как для критерия количества неправильно классифицированных символов, так и по скорости обучения.

Необходимо отметить, что система не всегда правильно определяет тип крыши, что говорит

Табл. 1. Результаты обучения и тестирования

Алгоритмы обучения весовых коэффициентов	Обучение		Тестирование	
	Величина ошибки	% ошибочно классифицированных	Величина ошибки	% ошибочно классифицированных
Генетический	0,13	0	0,19	23,3
Градиентный	0,09	0	0,12	13,3
Сопряженного градиента	0,07	0	0,09	6,6

При тестировании было ошибочно классифицировано 14,4 % из проверочного набора данных.

Выводы и перспективы дальнейших исследований

Практическая реализация модели NEFClass показала, что эта система дает достаточно высокие результаты применительно к задаче распознавания крыш зданий на спутниковых изображениях. Программное обеспечение, разработанное при выполнении работы, показывает основные возможности нечетких нейронных сетей типа NEFClass и может служить базой для развития темы распознавания зданий в дальнейшем. Кроме того, разработанное программное обеспечение может быть использовано для проведения экспериментов по усовершенствованию методов построения и обучения нечетких нейронных сетей. Реализовав на практике градиентный, генетический алгоритмы, и алгоритм сопряженных градиентов, и проанализировав полученные данные, можно заключить,

что лучшим для решения поставленной перед системой задачи оказался метод сопряженных градиентов, который быстро сходится и дает наилучшие результаты. Необходимо отметить, что требуются дальнейшие исследования, направленные на усовершенствование нейросетевой архитектуры и методов ее обучения, об этом говорит достаточно высокий процент ошибочно классифицированных зданий. Это улучшение может быть получено путём коррекции признаков, которые поступают на вход сети и увеличения обучающей выборки. Также возможно улучшение результата путем дообучения базы правил с помощью алгоритма «наилучший для каждого класса» [4]. Такой подход позволит снизить процент неверно классифицированных крыш зданий. В заключение следует ещё раз отметить, что по результатам проведенных исследований можно говорить о достаточно высокой результативности применения нечеткого классификатора к задаче распознавания зданий на спутниковых изображениях сверхвысокого разрешения.

Список литературы

1. Persson M., Sandvall M., Duckett T. Automatic Building Detection from Aerial Images for Mobile Robot Mapping. – Finland: International Symposium on In Computational Intelligence in Robotics and Automation 2005, pp. 273-278.
2. Sirmacek B. Unsalan C. Building Detection from Aerial Images Using Invariant Color Features and Shadow Information. – Turkey: International Symposium on Computer and Information Sciences 2008, pp.1-5.
3. S. Müller and D. W. Zaum, Robust building detection from aerial images, IAPRS, Vol. XXXVI, Part 3/W24, Vienna, Austria, 2005. – pp. 143-148
4. Зайченко Ю.П. Нечёткие модели и методы в интеллектуальных системах. Учебное пособие для студентов высших учебных заведений. – К.: «Издательский Дом «Слово»», 2008. – с. 344