

УДК 004.85;004.67

DOI 10.22213/2413-1172-2017-3-125-129

А. И. Абрамов, кандидат технических наук, ИжГТУ имени М. Т. Калашникова

И. В. Абрамов, доктор технических наук, профессор, ИжГТУ имени М. Т. Калашникова

Т. А. Мазитов, аспирант, ИжГТУ имени М. Т. Калашникова

А. А. Никитин, аспирант, ИжГТУ имени М. Т. Калашникова

## НЕЙРОСЕТЕВАЯ СЕГМЕНТАЦИЯ ДАННЫХ ЛАЗЕРНОЙ СКАНИРУЮЩЕЙ СИСТЕМЫ

**В**ыделение объектов и их сопровождение является одной из перспективных и быстро развивающихся областей технического зрения, применяющейся в различных системах (сопровождение объектов на видео, системы помощи водителю, охранные системы и т. д.). Предложено большое количество алгоритмов и методик для различных датчиков (монокулярные и стереокамеры, радары, лидары, rgb-d-камеры и т. д.).

Множество работ по сегментации и сопровождению объектов выполнено для пассивных датчиков, таких как видеокамеры [1–3]. Для таких сенсоров характерна сильная зависимость от условий окружающей среды (уровень освещенности), что усложняет обработку данных, в то время как активные датчики (лидары, времяпролетные камеры и т. д.) лишены данного недостатка, что дает большую стабильность в результатах обработки данных.

В области сегментирования данных с лидаров выполнен ряд работ [4–8]. Хотя большинство работ посвящено обработке 3D-облаков точек, одноплоскостные лазерные датчики расстояния, предоставляющие 2D-облака точек, вызывают интерес исследователей и распространены в приложениях по построению карт, локализации объектов и сопровождению объектов. В таких системах сегментация, кластеризация и выделение особых точек являются важным этапом.

В большинстве работ для сегментации данных авторы использовали общий подход, основанный на том, что лучи, отраженные от одного объекта, имеют схожее расстояние. При исследовании данного подхода было обнаружено, что при нахождении различных объектов рядом невозможно отделить их друг от друга. В данной статье предлагается алгоритм сегментации данных, основанный не только на расстоянии до объектов, но и интенсивности отраженного луча. (Современные лидары предоставляют такие данные.)

Принцип работы лидара основан на явлении отражения света. Расстояние измеряется по времени, за которое сигнал преодолел дистанцию от источника импульсов до приемника, отразившись от измеряемого объекта. Для получения многомерных облаков точек лазерные сканеры содержат вращающиеся зер-

кала. В соответствии с принципом работы на выходе устройство предоставляет массив из  $k$  точек, где каждой точке соответствуют параметры  $\theta(i)$ ,  $\rho(i)$ ,  $\iota(i)$  ( $i \in [1, k]$ ), где  $\theta(i)$  – направление, на котором производилось соответствующее измерение;  $\rho(i)$  – расстояние от датчика до  $i$ -й отраженной точки;  $\iota(i)$  – величина интенсивности отраженного сигнала. В работе используется датчик HOKUYO utm-30lx-ew, предоставляющий данные дальности с частотой до 40 Гц в диапазоне  $-135...135^\circ$  с шагом  $0,25^\circ$  на расстоянии до 30 м. Типичные данные, получаемые такими датчиками, представлены на рис. 1.

На рис. 2 представлены данные дальности, преобразованные в двумерное облако точек, и соответствующее им значение интенсивности.

Лидары являются одним из распространенных датчиков при решении задач навигации, управления и сопровождения. В мобильной робототехнике, при управлении устройствами, задача навигации и составления карты в неизвестной окружающей среде – SLAM (*Simultaneous Localization and Mapping*) – является одной из главных. При построении карт важно понимать, какие объекты относятся к статическим, а какие – к динамическим. Кроме того, при обнаружении динамического объекта необходимо отслеживать его. Также в SLAM-алгоритмах при совмещении данных для уменьшения вычислительной сложности при обработке большого объема информации используются особые точки. Результаты данной работы могут быть использованы при решении вышеперечисленных задач.

Как уже отмечалось выше, большинство методов сегментации данных лидара основано на анализе данных расстояния. В самом простом случае авторы используют разницу между соседними точками: если расстояние выше определенного порога, то они принадлежат разным сегментам. Для определения порогового в [9] предлагается использовать следующую формулу:

$$d_{th} = \tan(\Delta a) \cdot \min(\rho(i), \rho(i + 1)),$$

где  $\Delta a$  – угловой шаг измерений лидара.

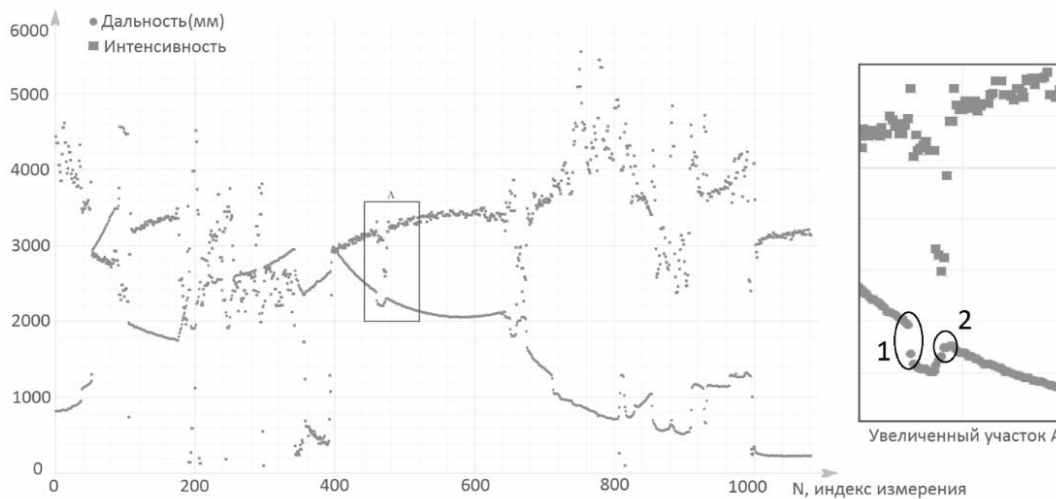


Рис. 1. Данные лидара (дальность и интенсивность)

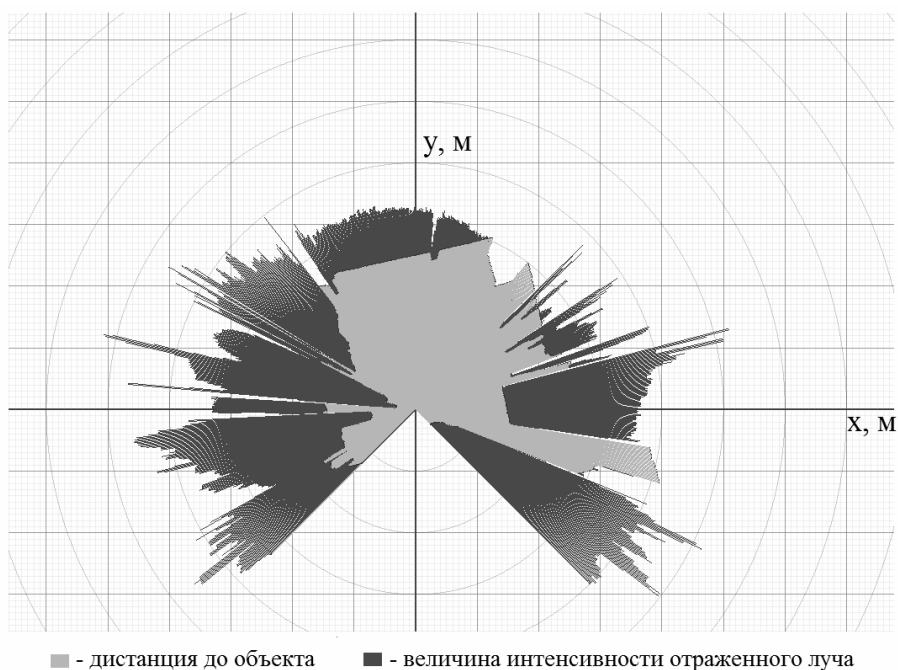


Рис. 2. Двумерные облака точек, полученные с помощью лидара

В работе [10] предлагается использование связанных компонент. В работе [11] используется алгоритм взаимных ближайших соседей (Reciprocal Nearest Neighbors). В работе [12] для сегментации используется алгоритм тензорного голосования (TENSOR VOTING). В ряде работ (например, [13]) сегментация выполняется на основе графических примитивов.

Проанализировав различные алгоритмы сегментации, мы обнаружили, что даже с помощью «умных» алгоритмов с высокой вычислительной сложностью нельзя отделить объекты схожей формы, находящиеся рядом, используя лишь данные дальности. Поэтому для сегментации данных предлагается использовать величину интенсивности отраженного луча в комплексе с данными дальности. Из рис. 1 видно, что данные интенсивности связаны

с данными дальности – характерное изменение в местах стыка объектов, но не всегда эта связь четко выражена. В выделенном участке 1 по значениям интенсивности проблематично сегментировать данные, тогда как в значениях дальности наблюдается разрыв; в то же время на участке 2 можно выделить локальное экстремальное значение в данных интенсивности, в данных дальности наблюдается только плавное изменение. На рис. 3 представлено фото соответствующего отсканированного лидаром участка. В то же время данные интенсивности сильно подвержены различным шумам и искажениям, резкие изменения и перепады в значениях связаны с характеристиками поверхности (неравномерные отражающие свойства, геометрия поверхности, угол падения луча сканирования).



Плоскость сканирования луча лидара

Рис. 3. Участок сканирования

Так как значения интенсивности сильно зашумлены, не всегда понятно, как значения интенсивности связаны с местом стыка двух сегментов. Для комплексирования данных при сегментации было предложено использование нейросетей.

Нейросети зарекомендовали себя как удобный инструмент при кластеризации и сегментации зашум-

ленных и сложно коррелируемых данных [14, 15]. В данной работе используется одна из наиболее распространенных и изученных моделей нейросетей – многослойный перцептрон (рис. 4).

Данная нейросеть состоит из входного слоя, на который подаются входные значения, нескольких скрытых слоев и выходного слоя. В свою очередь, каждый слой состоит из отдельных перцептронов, модель которого представлена на рис. 5.

Нейрон представляет собой сумматор, выход которого определяется через его входы и матрицу весов следующим образом:

$$y = \sum_{i=1}^n x_i w_i.$$

Полученное значение передается в функцию активации, результатом вычисления которой является выходное значение перцептрона. В представленной реализации в качестве функции активации используется логистическая функция

$$\sigma(x) = \frac{1}{(1 + e^{-tx})},$$

где  $t$  – параметр функции, определяющий ее крутизну.

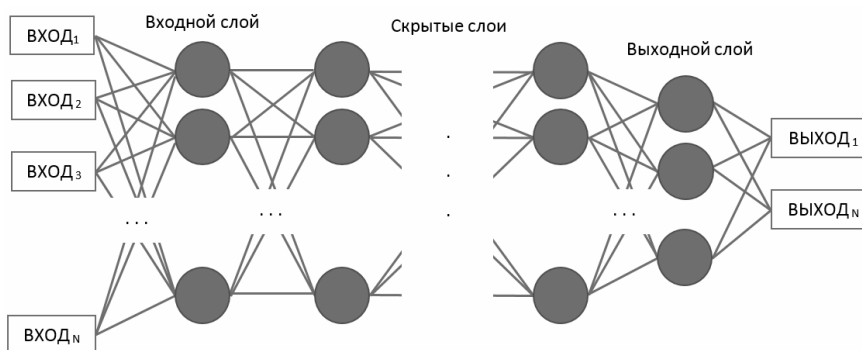


Рис. 4. Архитектура многослойного перцептрона




Рис. 5. Модель перцептрона

В экспериментальной оценке предложенной модели используется многослойный перцептрон с двумя скрытыми слоями, исследуемая окрестность 5 точек, следовательно, нейросеть должна иметь 20 входов (10 – разности соседних дальностей, 10 – разности интенсивности, рис. 6). На вход

нейросети подаются значения разностей данных интенсивности и дальности соседних точек, соответственно, в окрестности исследуемой точки. Выход нейросети должен выдавать 1, когда исследуемая точка является крайней точкой сегмента, в иных случаях – 0.

На рис. 6 представлена методика формирования входных данных нейросети для точки с индексом  $i$  и ее окрестности. Для данных, окрестности которых содержат менее 10 точек (начальные и конечные точки массива), данные расширяются на величину окрестности, скопировав ближайшие значения.

Обучение нейросети проводилось на заранее размеченных данных. Разметку данных осуществляли, руководствуясь следующими критериями.

1. Сегментом считается массив точек с плавно изменяющимися значениями.

2. Если в данных дальности присутствуют «разрывы», такие точки помечались как особые.

3. Если в плавно изменяющихся данных интенсивности присутствуют экстремумы или резко изменяющиеся значения, то соответствующие точки помечались как особые.






Рис. 6. Входные данные нейросети

На рис. 7 представлены результаты работы обученной нейросети.



б

Рис. 7. Сегментация данных: а – выходы нейросети; б – сегментированное облако точек

Для определения крайних точек сегментов выполняется поиск локальных максимумов выше порогового значения, определяющегося эмпирически исходя из результатов обучения нейронной сети. Следовательно, если такая точка находится, то она является особой точкой, разделяющей два сегмента. На рис. 7, б представлены результаты сегментации. Несмотря на то, что выделенный на изображении сегмент находится вплотную к ближайшему объекту, обученная нейросеть смогла корректно его выделить, чего сложно, а иногда невозможно добиться, используя только данные дальности.

### Выводы

Предложенная методика работает относительно быстро по сравнению с частотой измерительной системы. Позволяет эффективно выделять сегменты, расположенные вплотную друг к другу, используя данные дальности в комплексе с соответствующими значениями интенсивности отраженного от поверхности сигнала. К особенностям предложенной методики можно отнести тот факт, что она выделяет дополнительные сегменты (ложные срабатывания). Это напрямую связано с подбором обучающей выборки. С другой стороны, дополнительные отклики стабильно появляются в физически одинаковых местах, следовательно, их можно использовать как особые точки для ориентирования, построения карты и траектории.

Результаты данного исследования могут быть использованы не только в задачах сегментации облаков точек, но и при решении задач построения карт, для выделения особых точек при анализе двумерных облаков точек, построения систем сопровождения объектов.

### Библиографические ссылки

1. Video segmentation by tracking many figure-ground segments / F. Li [et al.] // Proceedings of the IEEE International Conference on Computer Vision. – 2013. – P. 2192–2199.
2. Ochs P., Malik J., Brox T. Segmentation of moving objects by long term video analysis // IEEE transactions on pat-

tern analysis and machine intelligence. – 2014. – Vol. 36, No. 6. – P. 1187–1200.

3. Fully automated segmentation and tracking of the intima media thickness in ultrasound video sequences of the common carotid artery / D. E. Ilea [et al.] // IEEE transactions on ultrasonics, ferroelectrics, and frequency control. – 2013. – Vol. 60, No. 1. – P. 158–177.

4. Yao W., Hinz S., Stilla U. Object extraction based on 3d-segmentation of lidar data by combining mean shift with normalized cuts : Two examples from urban areas // Urban Remote Sensing Event. – 2009 Joint. – P. 1–6.

5. Rubio D. O., Lenskiy A., Ryu J. H. Connected Components for a Fast and Robust 2D Lidar Data Segmentation // Modelling Symposium (AMS). – 2013, 7th Asia. – IEEE, 2013. – P. 160–165.

6. Efficient segmentation of 3d lidar point clouds handling partial occlusion / J. Aue, D. Langer, B. Muller-Bessler, B. Huhnke // Intelligent Vehicles Symposium (IV), 2011 IEEE, 2011. – P. 423–428.

7. Difference of normals as a multi-scale operator in unorganized point clouds / Y. Ioannou, B. Taati, R. Harrap, M. Greenspan. – ArXiv e-prints, Sep. 2012.

8. Simultaneous segmentation and superquadrics fitting in laser-range data / R. Pascoal [et al.] // IEEE Transactions on Vehicular Technology. – 2015. – Vol. 64, No. 2. – P. 441–452.

9. Thuy M., Leon F. P. Non-linear, shape independent object tracking based on 2d lidar data // Intelligent Vehicles Symposium, 2009 IEEE. – IEEE, 2009. – P. 532–537.

10. Rubio D. O., Lenskiy A., Ryu J. H. Op. cit.

11. Fast reciprocal nearest neighbors clustering / R. J. López-Sastre [et al.] // Signal Processing. – 2012. – Vol. 92, No. 1. – P. 270–275.

12. Schuster H. F. Segmentation of lidar data using the tensor voting framework // International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences. – 2004. – Vol. 35, No. B3. – P. 1073–1078.

13. Simultaneous segmentation and superquadrics fitting in laser-range data / R. Pascoal [et al.] // IEEE Transactions on Vehicular Technology. – 2015. – Vol. 64, No. 2. – P. 441–452.

14. Large-scale video classification with convolutional neural networks / A. Karpathy [et al.] // Proceedings of the IEEE conference on Computer Vision and Pattern Recognition. – 2014. – P. 1725–1732.

15. Chen Y., Zhao X., Jia X. Spectral-spatial classification of hyperspectral data based on deep belief network // IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. – 2015. – Vol. 8, No. 6. – P. 2381–2392.