

УДК: 519.857.4

Байесовская вероятностная локализация автономного транспортного средства путем ассимиляции сенсорных данных и информации о дорожных знаках

С. И. Веренцов^{1,а}, Э. А. Магеррамов¹, В. А. Виноградов¹,
Р. И. Гизатуллин¹, А. Е. Алексеенко², Я. А. Холодов¹

¹ Университет Иннополис,
Россия, 420500, г. Иннополис, ул. Университетская, д. 1

² Институт автоматизации проектирования РАН,
Россия, 123056, г. Москва, ул. 2-ая Брестская, д. 19/18

E-mail: ^аs.verentsov@innopolis.ru

Получено 28.02.2018, после доработки — 31.05.2018.

Принято к публикации 03.06.2018.

Локализация транспортного средства является важной задачей в области интеллектуальных транспортных систем. Хорошо известно, что слияние показаний с разных датчиков (англ. Sensor Fusion) позволяет создавать более робастные и точные навигационные системы для автономных транспортных средств. Стандартные подходы, такие как расширенный фильтр Калмана или многочастичный фильтр, либо неэффективны при работе с сильно нелинейными данными, либо потребляют значительные вычислительные ресурсы, что осложняет их использование во встроенных системах. При этом точность сливаемых сенсоров может сильно различаться. Значительный прирост точности, особенно в ситуации, когда GPS (англ. Global Positioning System) не доступен, может дать использование ориентиров, положение которых заранее известно, — таких как дорожные знаки, светофоры, или признаки SLAM (англ. Simultaneous Localization and Mapping). Однако такой подход может быть неприменим в случае, если априорные локации неизвестны или неточны. Мы предлагаем новый подход для уточнения координат транспортного средства с использованием визуальных ориентиров, таких как дорожные знаки. Наша система представляет собой байесовский фреймворк, уточняющий позицию автомобиля с использованием внешних данных о прошлых наблюдениях дорожных знаков, собранных методом краудсорсинга (англ. Crowdsourcing — сбор данных широким кругом лиц). Данная статья представляет также подход к комбинированию траекторий, полученных с помощью глобальных GPS-координат и локальных координат, полученных с помощью акселерометра и гироскопа (англ. Inertial Measurement Unit, IMU), для создания траектории движения транспортного средства в неизвестной среде. Дополнительно мы собрали новый набор данных, включающий в себя 4 проезда на автомобиле в городской среде по одному маршруту, при которых записывались данные GPS и IMU смартфона, видеопоток с камеры, установленной на лобовом стекле, а также высокоточные данные о положении с использованием специализированного устройства Real Time Kinematic Global Navigation Satellite System (RTK-GNSS), которые могут быть использованы для валидации. Помимо этого, с использованием той же системы RTK-GNSS были записаны точные координаты знаков, присутствующих на маршруте. Результаты экспериментов показывают, что байесовский подход позволяет корректировать траекторию движения транспортного средства и дает более точные оценки при увеличении количества известной заранее информации. Предложенный метод эффективен и требует для своей работы, кроме показаний GPS/IMU, только информацию о положении автомобилей в моменты прошлых наблюдений дорожных знаков.

Ключевые слова: байесовское обучение, слияние данных сенсоров, локализация, автономные транспортные средства

Работа выполнена при поддержке Министерства образования и науки РФ в рамках гранта федеральной целевой программы (номер гранта RFMEFI60917X0100), Российского научного фонда (номер гранта 14-11-00877) и компании «РoadAP», которая предоставила данные о положениях дорожных знаков.

© 2018 Сергей Игоревич Веренцов, Эмиль Александрович Магеррамов, Владислав Александрович Виноградов, Рамиль Ильдарович Гизатуллин, Андрей Евгеньевич Алексеенко, Ярослав Александрович Холодов

UDC: 519.857.4

Bayesian localization for autonomous vehicle using sensor fusion and traffic signs

S. I. Verentsov^{1,a}, E. A. Magerramov¹, V. A. Vinogradov¹,
R. I. Gizatullin¹, A. E. Alekseenko², Ya. A. Kholodov¹

¹ Innopolis University,
1 Universitetskaya st., Innopolis, 420500, Russia

² Institute of Computer Aided Design of the Russian Academy of Sciences (ICAD RAS),
19/18 2-nd Brestskaya st., Moscow, 123056, Russia

E-mail: ^a s.verentsov@innopolis.ru

*Received 28.02.2018, after completion — 31.05.2018.
Accepted for publication 03.06.2018.*

The localization of a vehicle is an important task in the field of intelligent transportation systems. It is well known that sensor fusion helps to create more robust and accurate systems for autonomous vehicles. Standard approaches, like extended Kalman Filter or Particle Filter, are inefficient in case of highly non-linear data or have high computational cost, which complicates using them in embedded systems. Significant increase of precision, especially in case when GPS (Global Positioning System) is unavailable, may be achieved by using landmarks with known location — such as traffic signs, traffic lights, or SLAM (Simultaneous Localization and Mapping) features. However, this approach may be inapplicable if a priori locations are unknown or not accurate enough. We suggest a new approach for refining coordinates of a vehicle by using landmarks, such as traffic signs. Core part of the suggested system is the Bayesian framework, which refines vehicle location using external data about the previous traffic signs detections, collected with crowdsourcing. This paper presents an approach that combines trajectories built using global coordinates from GPS and relative coordinates from Inertial Measurement Unit (IMU) to produce a vehicle's trajectory in an unknown environment. In addition, we collected a new dataset, including from smartphone GPS and IMU sensors, video feed from windshield camera, which were recorded during 4 car rides on the same route. Also, we collected precise location data from Real Time Kinematic Global Navigation Satellite System (RTK-GNSS) device, which can be used for validation. This RTK-GNSS system was used to collect precise data about the traffic signs locations on the route as well. The results show that the Bayesian approach helps with the trajectory correction and gives better estimations with the increase of the amount of the prior information. The suggested method is efficient and requires, apart from the GPS/IMU measurements, only information about the vehicle locations during previous traffic signs detections.

Keywords: bayesian learning, sensor fusion, localization, autonomous vehicle

Citation: *Computer Research and Modeling*, 2018, vol. 10, no. 3, pp. 295–303 (Russian).

The work was supported by the Ministry of Education and Science of the Russian Federation within the framework of the grant of the federal target program (grant number RFMEFI60917X0100), the Russian Science Foundation (grant number 14-11-00877) and the company “RoadAR”, which provided data of traffic signs position.

1. Введение

Развитие автономных транспортных средств идет очень быстро, и метод одновременной локализации и построения карты [Simultaneous Localization and Mapping, SLAM, Dissanayake et al., 2001; Mur-Artal et al., 2015; Mur-Artal, Tardós, 2017; Forster et al., 2017] является популярным методом для получения информации об окружающей местности. Точная локализация очень важна для этой задачи [Wang et al., 2007].

Одним из способов локализовать транспортное средство является использование GPS [Rahiman, Zainal, 2013]. При этом большинство пользовательских устройств имеют невысокую точность: в тестах на улице в движении ошибка позиционирования GPS может вырасти до максимума в 20 метров [Zandbergen, Barbeau, 2011] при средней ошибке в 3 метра [Bettabah et al., 2011]. Кроме этого, интервал между последовательными измерениями с датчика GPS относительно высок — примерно 1 секунда. В городских условиях ошибка локализации GPS усугубляется высокими зданиями и узкими улицами [Chiang et al., 2013]. С другой стороны, ошибки при измерении координат с GPS независимы (нет корреляции по времени) и не накапливаются со временем. Недостаток состоит в том, что считывание данных с GPS происходит с частотой примерно 1 Герц, что ведет к задержке в измерении ускорения и в целом к шуму в данных. Относительное положение транспортного средства может быть измерено с использованием гиростабилизатора (Inertial measurement unit, IMU [Morrison, 1987]), чаще всего включающего в себя акселерометр и гироскоп и находящегося в большинстве современных смартфонов. IMU более точен [Milanés et al., 2008], чем GPS, и имеет частоту обновления около 400 Герц. Недостатком является то, что этот датчик не дает в чистом виде координаты устройства, и с помощью него можно лишь измерять положение только относительно предыдущей точки во времени. Следовательно, IMU имеет ошибки в вычислении скорости и положения в пространстве, которые накапливаются со временем [Knuth, Barooah, 2013]. Таким образом, он не подходит как единственный метод для оценки местоположения на больших временных и пространственных масштабах.

Преимущества обоих методов можно комбинировать с использованием подхода Sensor Fusion: при объединении измерений с GPS и IMU обе системы будут компенсировать ошибки друг друга, что приведет к более точным измерениям [Tazartes, Mark, 1988].

Существует много подходов к уточнению координат GPS. Например, в работе [Qu et al., 2015] данные о дорожных знаках с их географической привязкой включены в процесс ассимиляции данных с датчиков, чтобы исправить накопленную погрешность измерений. Недостатком этого подхода является то, что для него требуется актуальная база данных с очень точными координатами дорожных знаков. Авторы решают эту проблему, заранее обрабатывая видео местности, где будет протестирован алгоритм, и предварительно измеряя координаты дорожных знаков. Только после этого они применяют алгоритм локализации.

Мы предлагаем алгоритм, который одновременно обнаруживает знаки и корректирует положение транспортного средства, используя эту информацию. Наш подход используют детектор знаков на видеопотоке, полученном с камеры смартфона. Далее для уточнения текущих координат транспортного средства применяется вероятностный байесовский подход [Bayes, Price, 1763], использующий предварительную информацию о позициях, где ранее был обнаружен дорожный знак. Новое уточненное положение затем добавляется к набору предыдущих наблюдений. Таким образом, с помощью метода краудсорсинговой оценки координаты дорожных знаков непрерывно уточняются при поступлении новой информации об их местоположении от других транспортных средств.

В предлагаемом алгоритме мы используем только данные из GPS, IMU и камеры для обнаружения дорожных знаков (с использованием собственного алгоритма). Мы не используем подход SLAM для воссоздания траектории транспортного средства, поскольку он вычислительно намного дороже, чем алгоритм обнаружения дорожного знака [Guivant, Nebot, 2003], и поэтому на текущий момент непригоден для использования во встроенных или мобильных устройствах.

Результатом является то, что вероятностная коррекция ошибок траектории, основанная на обнаружении дорожных знаков, дает хорошие результаты даже без SLAM.

2. Методы

Для измерения точности вероятностного подхода с использованием знаков мы используем GPS-координаты, полученные с автомобильного видеорегистратора в качестве истинных значений. Данные, для которых производятся уточнения, взяты из других источников, смартфонов, участвующих в одновременном сборе данных. Мы строим траектории движения, используя разные подходы, такие как ассимиляция данных с датчиков GPS и IMU и использование дорожных знаков для уточнения координат, полученных с датчика GPS.

3. Данные

Данные, которые включают в себя видео для распознавания дорожных знаков, GPS-координаты и показания с датчиков IMU (акселерометр и гироскоп) были записаны с использованием нескольких мобильных телефонов, установленных внутри транспортного средства.

С того же транспортного средства, с которого были записаны координаты, было записано видео длиной 14 минут и разрешением 1280×720 , на кадрах которого были распознаны дорожные знаки. Видео было записано монокулярной камерой, которая была установлена внутри автомобиля в верхней части лобового стекла. Автомобиль двигался в городских условиях. Путь включал в себя здания небольшой и средней высоты, дорожные знаки и пешеходов, иногда переходящих через дорогу.

Данные о координатах, в которых ранее были замечены дорожные знаки, были получены с помощью мобильного приложения компании RoadAR. Эти данные были использованы для построения начальных распределений вероятности появления этих знаков.

Для тестирования байесовского уточнения координат нами был создан реалистичный тестовый набор предыдущих наблюдений дорожных знаков, а именно — нормально распределенный набор точек, направленный в сторону положений дорожных знаков.

4. Определение положения по данным GPS/IMU

На первом этапе применяется Sensor Fusion (ассимиляция данных с разных датчиков) для интерполяции данных о локализации, полученных с помощью GPS, а также сглаживания выбросов. В качестве дополнительного источника данных используются акселерометр и гироскоп.

Данные с акселерометра поставляются в локальных координатах устройства, поэтому необходимо получить вектор ускорения в глобальных координатах при помощи следующего линейного преобразования:

$$a_{global}(x_i) = R(x_i) \cdot a_{local}(x_i), \quad (1)$$

где $a_{global}(x_i)$ — вектор ускорения в точке x_i в глобальном координатном пространстве, $R(x_i)$ — матрица поворота в точке x_i , $a_{local}(x_i)$ — вектор ускорения в точке x_i в локальных координатах (данные, полученные непосредственно с акселерометра). Погрешность измерений акселерометра моделируется как два постоянных смещения — для локального (b_1) и глобального (b_2) вектора ускорений:

$$\hat{a}_{global}(x_i) = R(x_i)(a_{local}(x_i) + b_1) + b_2. \quad (2)$$

$R(x_i)$ вычисляется следующим образом:

$$R(x_i) = R(x_{i-1})(I + W_i \Delta t_i) = \prod_{j=1}^i (I + W_j \Delta t_j), \quad (3)$$

где Δt_i — временной интервал между i -м и $(i + 1)$ -м измерением IMU, $R(x_i)$ — данные, полученные непосредственно с гироскопа, W_i — их производная по времени, I — единичная матрица размером 3×3 .

Скорость в точке x_i выражается через $\hat{a}_{global}(x_i)$ и начальную скорость v_0 как

$$v_i^{IMU} = v_0 + \sum_{k=1}^i \hat{a}_{global}(x_k) \Delta t_k. \quad (4)$$

Значения b_1 , b_2 и v_0 должны быть найдены таким образом, чтобы значения скорости, полученные с IMU, максимально совпадали с данными, полученными с GPS. Это достигается при помощи решения следующей задачи оптимизации:

$$\min_{v_0, b_0, b_1} \sum_i \left(\left\| \sum_{j \in I_i} v_j^{IMU} \Delta t_j - v_i^{GPS} \Delta T_i \right\| \right), \quad (5)$$

где I_i — множество индексов измерений IMU между i -м и $(i + 1)$ -м измерением GPS, ΔT_i — временной промежуток между i -м и $(i + 1)$ -м измерением GPS, v_j^{IMU} — полученная оценка скорости для j -го измерения IMU, как описано в формуле (4), v_i^{GPS} — оценка скорости, полученная от датчика GPS.

Поставленная задача является задачей квадратичной оптимизации и может быть эффективно решена. В данной работе используется алгоритм L-BFGS [Liu, Nocedal, 1989] из-за его низкой вычислительной сложности.

Подход, использующий постоянные смещения для моделирования ошибок, показал недостаточную точность для длинных временных промежутков. По этой причине нахождение параметров b_1 , b_2 и v_0 выполняется отдельно для временных промежутков длиной более 40 секунд.

5. Байесовская оценка положения автомобиля

Использование заранее имеющихся данных о дорожных знаках — один из возможных способов исправления дрейфа, вызванного накопленной ошибкой с сенсоров. Мы используем информацию о дорожных знаках, полученную с помощью краудсорсинга. Эта информация включает в себя тип дорожного знака и положение в пространстве, в котором находилось транспортное средство, когда знак был обнаружен. Дополнительно для каждого знака известно направление движения автомобиля относительно него в момент обнаружения.

Одним из способов улучшить оценку положения транспортного средства при использовании заранее известной информации является применение байесовской статистики, а именно оценка апостериорного максимума (maximum a posteriori probability, MAP). С помощью MAP можно оценить неизвестный параметр θ , который равен моде апостериорного распределения. Предполагая, что априорное распределение $g(\theta)$, зависящее от θ , существует и θ является ее областью определения, можно рассчитать апостериорное распределение, θ имея некоторые наблюдения x , используя теорему Байеса:

$$f(\theta | x) = \frac{f(x | \theta) g(\theta)}{\int_{v \in \theta} f(x | v) g(v) dv}. \quad (6)$$

Теперь можно посчитать оценку $\hat{\theta}_{MAP}(x)$ неизвестного параметра как моду апостериорного распределения этой случайной переменной:

$$\hat{\theta}_{MAP}(x) = \arg \max_{\theta} f(\theta | x) = \arg \max_{\theta} f(x \vee \theta)g(\theta). \quad (7)$$

Знаменатель всегда положительный и не зависит от θ , следовательно, он не играет роли при выполнении оптимизации. Оценка апостериорного максимума MAP совпадает с оценкой максимального правдоподобия MLE, когда априорное распределение $g(\theta)$ равномерно.

Нашей задачей в этой статье является оценка скорректированного положения транспортного средства $x_{corrected}$, при наличии n предыдущих наблюдений $\bar{x}_{old} = [x_1, \dots, x_n]$ дорожных знаков s и текущей позиции транспортного средства $x_{current}$, полученной с помощью Sensor Fusion с датчиков GPS и IMU. Для этого мы рассчитываем моду апостериорного распределения в ε -окрестности $x_{current}$ и назначаем новое скорректированное положение $x_{corrected}$ равным координатам этой моды. В таком случае оптимизационная задача выглядит так:

$$x_{corrected} = \arg \max_{x_i \in B_{x_{current}}[\varepsilon]} p(s \vee x_i; \bar{x}_{old}) \cdot p(x_i \vee x_{current}), \quad (8)$$

где $B_{x_{current}}[\varepsilon] = \{x \in R^2 \vee \|x - x_{current}\|_2^2 \leq \varepsilon\}$ и ε подобрано опытным путем.

Мы моделируем вероятность наблюдения знака s , имея текущие координаты и предыдущие наблюдения \bar{x}_{old} , как двумерное нормальное распределение с матрицей ковариации Σ , рассчитанной с помощью набора предыдущих наблюдений. Также мы предполагаем, что наше априорное распределение $p(x_i; x_{current})$ является нормальным с параметром $\mu = x_{current}$ и параметром σ , подобранным опытным путем во время проведения экспериментов.

Более того, в предложенном фреймворке можно использовать метод байесовского обновления, чтобы получить более точную оценку положения транспортного средства при получении новых данных. Рассчитанное апостериорное положение $x_{corrected}$, при нахождении в котором дорожный знак был распознан, добавляется в набор наблюдений \bar{x}_{old} для конкретного найденного знака. Затем эта информация используется для перерасчета нового распределения вероятности обнаружения этого знака относительно некоторого положения в пространстве. Затем новое апостериорное распределение может быть рассчитано с использованием новых данных о положении, чтобы в будущем давать более точную оценку. Таким образом, наблюдения, которые алгоритм использует для предсказания скорректированного положения в пространстве, собираются с использованием краудсорсинга. Это отличается от подхода, при котором точный набор наблюдений должен быть собран заранее. Предложенный алгоритм требует только координат GPS, полученных во время наблюдения дорожных знаков, и формирует свой набор наблюдений для каждого знака за тем, чтобы смоделировать требуемое распределение.

6. Результаты

Мы собрали данные, перемещаясь на автомобиле в городской среде. Данные были собраны с нескольких устройств, установленных в разных положениях на лобовом стекле. Мы получили записи с камеры и показания акселерометра, гироскопа и GPS со смартфона, установленного на лобовом стекле. Мы взяли траекторию GPS с автомобильного видеорежистратора в качестве истинных значений. Данные наблюдений дорожных знаков (показаны на рис. 1) были получены методом краудсорсинга с использованием мобильного приложения RoadAR. Данные состоят из GPS-координат автомобиля в момент, когда дорожный знак был виден в последний раз. Дорожные знаки обнаруживаются на изображениях с помощью алгоритма компании RoadAR. Мы собрали данные для эксперимента во время поездки на автомобиле в городе Ин-



Рис. 1. Карта дорожных знаков города Иннополиса

нополисе, и сама система может работать в других средах, представляя собой инструмент сбора данных с использованием метода краудсорсинга.

Мы сравниваем два подхода к построению траектории: первый использует только данные GPS + IMU, а второй также использует данные наблюдений дорожных знаков, чтобы корректировать оценку текущего положения транспортного средства.

Первый подход использует Sensor Fusion для компенсации ошибок измерений GPS и сглаживания выбросов с использованием данных IMU (акселерометр и гироскоп). Мы используем метрику ошибки переноса (translation error) как метрику оценки. Ошибка переноса — это сумма квадратов кратчайших расстояний между генерируемыми точками и точками на истинной траектории.

Как видно на рис. 2 (слева), ошибка накапливается во время движения, а значение ошибки часто увеличивается во время поворотов. Средняя погрешность измерения для этой траектории составляет 6.6 метра.

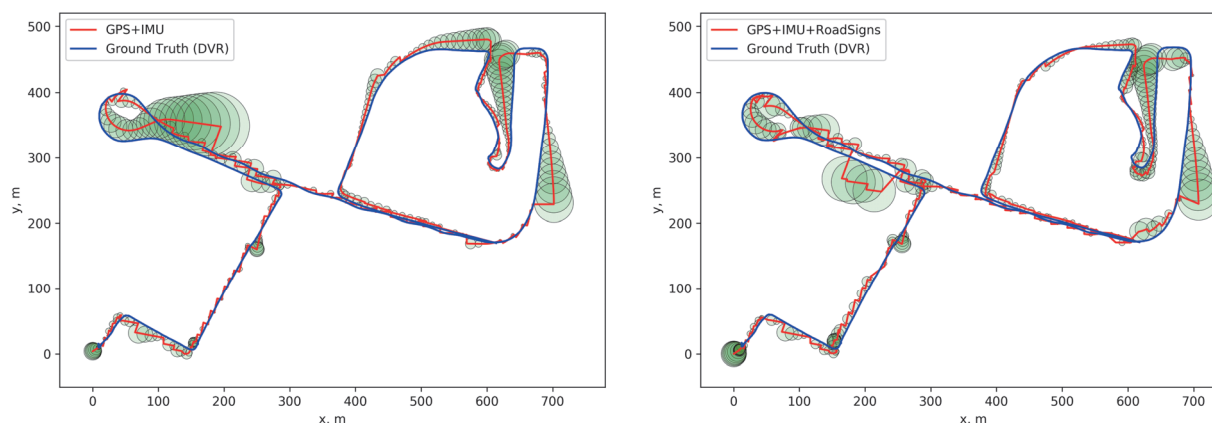


Рис. 2. Сравнение траекторий GPS и GPS + IMU (слева) и GPS + IMU и GPS + IMU + RoadSigns (справа). Ошибка локализации отображена в виде окружностей с центром на границе одной траектории и радиусом, равным расстоянию до ближайшей точки другой траектории

Во втором подходе генерировался искусственный набор наблюдений за дорожными знаками путем симуляции примеров из нормального распределения с центром в месте расположения конкретного дорожного знака (оцененного с помощью данных о предыдущих наблюдениях). После применения предложенного алгоритма к модельным данным траектория корректируется с учетом предыдущих наблюдений данного знака. Несмотря на то что местоположения наблюдений неточны из-за ограничений технологии GPS, чем больше предшествующих наблюдений мы генерируем, тем лучше оценка. Сходимость скорректированного значения к истинному местоположению демонстрирует идею краудсорсинга наблюдений за дорожными знаками с целью получить более точную оценку в будущем.

Как показано на рис. 2 (справа), ошибка на поворотах уменьшается при использовании информации о дорожных знаках. Средняя погрешность измерения для траектории, построенной с помощью GPS + IMU + данных о дорожных знаках, равна 6.2 метра.

Таким образом, добавление информации о дорожных знаках приводит к уменьшению ошибки на 6.1 % с использованием нашего подхода, даже если предыдущие данные о положениях дорожных знаков не очень точны.

7. Заключение

Мы предлагаем алгоритм исправления ошибок координат автомобиля, основанный на краудсорсинге наблюдений дорожных знаков и байесовской статистике. Он использует метод ассимиляции данных (Sensor Fusion) для комбинирования траекторий, полученных с помощью датчика GPS в транспортном средстве и датчика IMU (акселерометр и гироскоп). После комбинации полученная траектория корректируется с использованием байесовского алгоритма, основанного на данных о последних наблюдениях дорожных знаков, полученных с помощью краудсорсинга, на модельных данных и данных о прошлых наблюдениях.

Мы протестировали алгоритм на данных, собранных в городской среде. Добавление информации о дорожных знаках позволило снизить среднюю ошибку измерений на 6.1 %.

В дальнейшем алгоритм может быть улучшен с помощью использования других визуальных ориентиров, таких как дорожные разметки и городские здания, а также с помощью использования траекторий, созданных с помощью метода SLAM.

Список литературы (References)

- Chiang K. W., Duong T. T., Liao J. K.* The performance analysis of a real-time integrated INS/GPS vehicle navigation system with abnormal GPS measurement elimination // *Sensors*. — 2013. — Vol. 13, No. 8. — P. 10599–10622.
- Dissanayake M. W. M. G. et al.* A solution to the simultaneous localization and map building (SLAM) problem // *IEEE Transactions on robotics and automation*. — 2001. — Vol. 17, No. 3. — P. 229–241.
- Forster C. et al.* Svo: Semidirect visual odometry for monocular and multicamera systems // *IEEE Transactions on Robotics*. — 2017. — Vol. 33, No. 2. — P. 249–265.
- Guivant J. E., Nebot E. M.* Solving computational and memory requirements of feature-based simultaneous localization and mapping algorithms // *IEEE Transactions on Robotics and Automation*. — 2003. — Vol. 19, No. 4. — P. 749–755.
- Knuth J., Barooah P.* Error growth in position estimation from noisy relative pose measurements // *Robotics and Autonomous Systems*. — 2013. — Vol. 61, No. 3. — P. 229–244.
- Liu D. C., Nocedal J.* On the limited memory BFGS method for large scale optimization // *Mathematical programming*. — 1989. — Vol. 45, No. 1–3. — P. 503–528.
- Morrison M. M.* Inertial measurement unit, Granted Patent US 4 711 125 A, 1987.

- Milanés V. et al.* Autonomous vehicle based in cooperative GPS and inertial systems // *Robotica*. — 2008. — Vol. 26, No. 5. — P. 627–633.
- Bayes Mr., Price M.* An essay towards solving a problem in the doctrine of chances. by the late rev. mr. bayes, frs communicated by mr. price, in a letter to john canton, amfrs // *Philosophical Transactions* (1683–1775). — 1763. — P. 370–418.
- Mur-Artal R., Tardós J. D.* Orb-slam2: An open-source slam system for monocular, stereo, and rgb-d cameras // *IEEE Transactions on Robotics*. — 2017. — Vol. 33, No. 5. — P. 1255–1262.
- Mur-Artal R., Montiel J. M. M., Tardos J. D.* ORB-SLAM: a versatile and accurate monocular SLAM system // *IEEE Transactions on Robotics*. — 2015. — Vol. 31, No. 5. — P. 1147–1163.
- Qu X., Soheilian B., Paparoditis N.* Vehicle localization using mono-camera and geo-referenced traffic signs // *Intelligent Vehicles Symposium (IV)*, 2015 IEEE. — IEEE, 2015. — P. 605–610.
- Rahiman W., Zainal Z.* An overview of development GPS navigation for autonomous car // *Industrial Electronics and Applications (ICIEA)*, 2013 8th IEEE Conference on. — IEEE, 2013. — P. 1112–1118.
- Berrabah S. A., Sahli H., Baudoin Y.* Visual-based simultaneous localization and mapping and global positioning system correction for geo-localization of a mobile robot // *Measurement Science and Technology*. — 2011. — Vol. 22, No. 12. — P. 124003.
- Tazartes D. A., Mark J. G.* Integration of GPS receivers into existing inertial navigation systems // *Navigation*. — 1988. — Vol. 35, No. 1. — P. 105–119.
- Wang C. C. et al.* Simultaneous localization, mapping and moving object tracking // *The International Journal of Robotics Research*. — 2007. — Vol. 26, No. 9. — P. 889–916.
- Zandbergen P. A., Barbeau S. J.* Positional accuracy of assisted GPS data from high-sensitivity GPS-enabled mobile phones // *The Journal of Navigation*. — 2011. — Vol. 64, No. 3. — P. 381–399.