

Наблюдатель продольного ускорения автомобиля на основе фильтра Калмана с нейросетевой моделью динамики системы

И. А. Громов

Аннотация— Точная оценка продольного ускорения автомобиля – задача, требующая учета широкого спектра факторов: модели динамики, набора используемых датчиков и т.д. В данной работе представлен подход к построению наблюдателя продольного ускорения автомобиля на основе расширенного фильтра Калмана. В составе модели системы, используемой в фильтре, рассмотрены как аналитическая модель продольной динамики системы, построенная согласно второму закону Ньютона, так и её нейросетевая модель. Сравнение точности наблюдателей на основе обеих моделей производилось после предварительной автоматизированной настройки параметров фильтра с использованием метода роя частиц. В работе подробно представлен вывод моделей предсказания и измерения для предложенного наблюдателя. Для настройки фильтра и оценки его точности использовались реальные данные, полученные из CAN-сети (Controller Area Network) легкового автомобиля.

Ключевые слова— метод максимального правдоподобия, метод роя частиц, модель динамики автомобиля, нейронная сеть, продольное ускорение, уклон дороги, фильтр Калмана.

I. ВВЕДЕНИЕ

Продольное ускорение является одной из наиболее значимых характеристик движения транспортного средства. Информация о текущем продольном ускорении, как правило, используется в функционирующих в режиме реального времени системах управления транспортными средствами для решения широкого спектра задач, таких, как, например, непосредственно, управление продольным движением транспортного средства, предсказание его состояния, оценка качественных характеристик процесса управления транспортным средством и т.д. [1]–[3].

В рамках данной работы рассматривается задача определения продольного ускорения транспортного средства применительно к легковому автомобилю. Точность определения продольного ускорения автомобиля является важным фактором решения таких промышленных задач [4], как разработка систем круиз-контроля, автоматической парковки, экстренного торможения, беспилотного вождения и т.д. Неточное определение продольного ускорения в таких системах

И.А. Громов, аспирант Федерального исследовательского центра «Информатика и управление» Российской Академии Наук (email: 8357743@gmail.com).

может приводить к различного рода рискам, вызывая или дискомфорт пассажиров автомобиля, или, в худших случаях, опасное для пассажиров и прочих участников дорожного движения поведение транспортного средства. Ключевая трудность решения задачи определения продольного ускорения автомобиля заключается в несовершенстве используемых для решения этой задачи датчиков. Так, в качестве источников “сырой” информации о текущем ускорении автомобиля используются, как правило, инерциальные датчики (акселерометр, гироскоп) и датчики скорости колёс.

Поскольку принцип работы таких инерциальных датчиков, как акселерометр, заключается в измерении равнодействующей сил, воздействующих на его чувствительный элемент, необходимо иметь в виду, что, помимо сил инерции, равнодействующая которых имеет линейную связь с ускорением автомобиля, на чувствительный элемент датчика воздействует также сила гравитации [5]. Соответственно, в условиях движения автомобиля в гору или с горы, акселерометр будет измерять его продольное ускорение с ошибкой, величина которой будет иметь связь с уклоном дороги. Кроме ошибки от уклона дороги, показания инерциальных датчиков содержат случайную ошибку, обусловленную собственными колебаниями их чувствительных элементов и их же вынужденными колебаниями, вызванными неровностью дороги и вибрацией кузова автомобиля.

Датчики скорости колёс, в свою очередь, позволяют оценить скорость движения автомобиля и, соответственно, путём численного дифференцирования последней получить продольное ускорение. Подобный подход также имеет недостатки. Так, численное дифференцирование приводит к появлению случайного шума в оценке продольного ускорения, а измерения, производимые датчиками скорости колёс, будут неточны при пробуксовке колёс автомобиля во время разгона и блокировке колёс при торможении [6]. Кроме того, на точности измерений датчиков скорости автомобиля негативно сказываются факторы, вызывающие изменение радиуса колёс: снижение давления в шинах автомобиля, изменение массы автомобиля под нагрузкой и износ протектора колеса.

Таким образом, метод, используемый для оценки величины продольного ускорения в конкретном частном случае, зависит от вида аппаратных устройств, используемых в качестве источников информации и

Статья получена 12 марта 2026. Исследование выполнено при поддержке гранта Российского научного фонда № 25-21-00704, <https://rscf.ru/project/25-21-00704/>.

требований к точности оценки. В рамках практических решений часто используются т.н. "наивные" методы измерения продольного ускорения транспортного средства [7], [8], опирающиеся на один аппаратный источник информации, однако, такие методы не отличаются высокой точностью. Наилучшие результаты в существующей практике решения задачи показывают методы, основанные на комплексировании показаний нескольких источников данных. В [9] авторы представили обзор подходов, используемых для оценки переменных состояния транспортных средств (в том числе, и переменных состояния продольной динамики), отмечая, что подходы отличаются друг от друга, преимущественно, видом используемой модели транспортного средства (кинематическая, динамическая), набором источников данных (датчики скорости колёс, инерциальные датчики, глобальная навигационная спутниковая система, видеокамера и т.д.) и используемым алгоритмом комплексирования (наблюдатель на основе скользящего режима, фильтр Калмана, расширенный фильтр Калмана, фильтр Калмана «без запахов», фильтр частиц, нейронная сеть и т.д.) [10]–[13]. При этом, в существенной доле работ, посвященных оценке продольного ускорения транспортного средства, производится оценка всего вектора состояния транспортного средства, включающего в себя переменные, характеризующие как продольную динамику, так и поперечную. Такой подход обусловлен тем, что модели подавляющего большинства транспортных средств (в т.ч. и автомобилей) даже при упрощенном анализе представляют собой неголономные системы, в которых уравнения продольной и поперечной динамики тесно связаны друг с другом [14].

Немаловажно отметить, что универсального способа оценки переменных состояния транспортного средства нет, поскольку различные транспортные средства имеют различные модели (не только с точки зрения величин параметров, но и с точки зрения структуры), обладают различным набором датчиков и могут функционировать в различных условиях окружающей среды. Текущее же развитие методов оценки переменных состояния происходит в направлении объединения как показаний разнообразных аппаратных устройств, так и выводов отличных друг от друга моделей одних и тех же транспортных средств. Кроме того, популярным трендом является использование в рассматриваемой задаче моделей, полученных с помощью методов машинного обучения [15].

Примером реализации наблюдателя продольного ускорения автомобиля с использованием машинно-синтезируемой модели динамики является текущая работа. Подход, представленный в работе, демонстрирует преимущества использования нейросетевой модели динамики системы в составе наблюдателя и подкрепляется результатами натурального эксперимента. Таким образом, проведенное исследование сосредоточено на иллюстрации метода построения наблюдателя продольного ускорения автомобиля и сравнении точности алгоритма наблюдения, использующего идентифицируемую нейросетевую модель с точностью аналогичного алгоритма с классической моделью продольной динамики.

В главе II текущей работы представлено описание наблюдателя, включающее в себя используемый в нём алгоритм комплексирования данных, структуру модели измерения наблюдаемых величин и варианты построения модели динамики автомобиля как с нейросетевой идентифицируемой моделью в её составе, так и без неё. В главе III описан процесс автоматизированной настройки параметров наблюдателя на основе максимизации правдоподобия с помощью метода роя частиц. В главе IV представлен эксперимент, наглядно иллюстрирующий преимущества использования в составе наблюдателя идентифицируемой с помощью нейронной сети модели продольной динамики системы. Глава V содержит ключевые выводы работы.

II. ОПИСАНИЕ ПРЕДЛАГАЕМЫХ МЕТОДОВ

A. Общее описание наблюдателя

В качестве используемого средства комплексирования нескольких источников данных предлагается использовать расширенный фильтр Калмана, алгоритм работы которого описывается, в частности, в [16] и состоит из двух этапов: предсказания и коррекции. При описании алгоритма работы фильтра Калмана используется запись вида $\hat{\mathbf{x}}_{n|m}$, представляющая собой оценку состояния системы в момент времени n с учётом измерений, полученных до момента m включительно. На этапе предсказания осуществляется оценка текущего состояния $\hat{\mathbf{x}}_{k|k-1}$ и соответствующей ему ковариационной матрицы $\mathbf{P}_{k|k-1}$ на основе прошлого состояния $\hat{\mathbf{x}}_{k-1|k-1}$, прошлого управления \mathbf{u}_{k-1} и прошлой ковариационной матрицы $\mathbf{P}_{k-1|k-1}$ в соответствии с выражениями:

$$\hat{\mathbf{x}}_{k|k-1} = \mathbf{f}(\hat{\mathbf{x}}_{k-1|k-1}, \mathbf{u}_{k-1}), \quad (1)$$

$$\mathbf{P}_{k|k-1} = \mathbf{F}_k \mathbf{P}_{k-1|k-1} \mathbf{F}_k^T + \mathbf{Q}_k, \quad (2)$$

где $\mathbf{f}(\mathbf{x}, \mathbf{u})$ – модель динамики системы, $\mathbf{F}_k = \frac{d\mathbf{f}}{d\mathbf{x}}|_{\hat{\mathbf{x}}_{k-1|k-1}, \mathbf{u}_{k-1}}$ – матрица Якоби модели динамики системы в предыдущий момент времени $k-1$, \mathbf{Q}_k – ковариационная матрица шума процесса.

На этапе коррекции определяется отклонение \mathbf{y}_k ожидаемого измерения от текущего \mathbf{z}_k (т.н. «невязка») и соответствующая отклонению ковариационная матрица \mathbf{S}_k :

$$\mathbf{y}_k = \mathbf{z}_k - \mathbf{h}(\hat{\mathbf{x}}_{k|k-1}), \quad (3)$$

$$\mathbf{S}_k = \mathbf{H}_k \mathbf{P}_{k|k-1} \mathbf{H}_k^T + \mathbf{R}_k, \quad (4)$$

где $\mathbf{h}(\mathbf{x})$ – модель измерения, $\mathbf{H}_k = \frac{d\mathbf{h}}{d\mathbf{x}}|_{\hat{\mathbf{x}}_{k|k-1}}$ – матрица Якоби модели измерений в текущий момент времени k , \mathbf{R}_k – ковариационная матрица шума измерений.

Затем определяется матрица коэффициентов усиления \mathbf{K}_k и, с её использованием, оценка вектора состояния $\hat{\mathbf{x}}_{k|k}$ с соответствующей матрицей ковариации $\mathbf{P}_{k|k}$, учитывающие текущее измерение \mathbf{z}_k :

$$\mathbf{K}_k = \mathbf{P}_{k|k-1} \mathbf{H}_k^T \mathbf{S}_k^{-1}, \quad (5)$$

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k \mathbf{y}_k, \quad (6)$$

$$\mathbf{P}_{k|k} = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_{k|k-1}. \quad (7)$$

Вид наблюдателя на основе фильтра Калмана зависит от выбора векторов состояния \mathbf{x} , управления \mathbf{u} и измерений \mathbf{z} , моделей динамики $\mathbf{f}(\mathbf{x}, \mathbf{u})$ и измерения $\mathbf{h}(\mathbf{x})$, а также моделей шума измерений \mathbf{R} и шума процесса \mathbf{Q} . Начальное значение матрицы ковариаций \mathbf{P}

вектора состояния не является столь важным, так как матрица \mathbf{P} , как правило, самостоятельно приходит к оптимальному виду за короткий срок в процессе функционирования фильтра.

Вид наблюдателя также зависит от вида и набора сенсоров, показания которых планируется использовать для коррекции состояния наблюдателя. В рамках данной работы рассматривается частный случай транспортного средства, в роли которого выступает легковой автомобиль с полным приводом, оснащённый встроенным 2D-акселерометром, измеряющим продольное и поперечное ускорения автомобиля и его угловую скорость. Шасси автомобиля оснащено датчиками скоростей вращения колёс, а рулевое колесо – датчиком угла поворота, измеряющим как сам угол поворота рулевого колеса, так и скорость его вращения. Измерения всех трёх датчиков доступны к получению из CAN-сети (CAN – Controller Area Network) автомобиля в реальном времени с частотой 100 Гц.

Таким образом, вектор измерений фильтра, содержащий показания используемых датчиков, имеет вид выражения (8). Переменные, входящие в состав вектора измерений (8) описаны в таблице 1. Причины указания в векторе (8) квадратов скоростей осей передних колёс объяснены в конце главы II.B.

$$\mathbf{z} = [a_{lgt_meas}, a_{lat_meas}, \varphi_{wheel}, \chi_{wheel}, v_{fl}^2, v_{fr}^2, v_{rl}, v_{rr}, \omega_{z_meas}]. \quad (8)$$

Переменные, входящие в состав наблюдаемого вектора состояния, выбираются удовлетворяющими одному из двух следующих условий:

1. Переменная является целью наблюдения (в нашем случае цель – продольное ускорение автомобиля);
2. Переменная нужна для описания взаимосвязи других переменных состояния и/или переменных вектора измерений.

Таким образом, вектор состояния фильтра для рассматриваемой задачи наблюдения ускорения примет вид (9). Переменные, входящие в состав выражения (9) описаны в таблице 2.

$$\mathbf{x} = [v_x, a_x, \theta, \gamma, \omega_z, \varepsilon_z, \varphi, \chi]. \quad (9)$$

В состав вектора управления входят переменные величины, не входящие в вектор состояния, но используемые в модели динамики системы. Как правило, предполагается, что их величины известны точно. В рассматриваемом случае вектор управления имеет вид (10). Переменные, входящие в его состав описаны в таблице 3.

$$\mathbf{u} = [T_e, i_t, p_{mc}]. \quad (10)$$

В. Модель измерений

Определим вид модели измерений фильтра Калмана. В частности, для этого необходимо установить зависимость между показаниями продольного и поперечного ускорений a_{lgt_meas} , a_{lat_meas} и вектором состояния \mathbf{x} . Допуская, что изменение угла продольного уклона дороги θ во времени представляет собой квазистационарный процесс, можно считать, что в каждый отдельный момент времени автомобиль совершает плоскопараллельное движение в плоскости дороги с уклоном θ . В этом случае, искомым связь

вектора ускорения акселерометра с вектором ускорения центра задней оси автомобиля (рис. 1) удобно описывать формулой Ривальса:

$$\mathbf{a}_k = \mathbf{a}_0 + \mathbf{a}_{k0}. \quad (11)$$

Разложив ускорения в правой части выражения (11) на тангенциальные и центростремительные составляющие, а вектор ускорения акселерометра в левой части выражения на продольную и поперечную составляющие, имеем:

$$\mathbf{a}_{lgt_meas} + \mathbf{a}_{lat_meas} = \mathbf{a}_0^T + \mathbf{a}_0^n + \mathbf{a}_{k0}^T + \mathbf{a}_{k0}^n. \quad (12)$$

Введём в уравнение (12) в качестве параметра вектор \mathbf{d} , связывающий центр задней оси автомобиля и акселерометр (рис. 1), а также \mathbf{v}_0 – вектор линейной скорости центра задней оси автомобиля, $\boldsymbol{\omega}$ – вектор угловой скорости автомобиля и $\boldsymbol{\varepsilon}$ – вектор углового ускорения автомобиля:

$$\mathbf{a}_{lgt_meas} + \mathbf{a}_{lat_meas} = \mathbf{a}_0^T + \boldsymbol{\omega} \times \mathbf{v}_0 + \boldsymbol{\varepsilon} \times \mathbf{d} + \boldsymbol{\omega} \times [\boldsymbol{\omega} \times \mathbf{d}]. \quad (13)$$




Рисунок 1 – Приведение измерений акселерометра к центру задней оси автомобиля

Спроецируем уравнение (13) на оси системы координат Oxy , связанной с автомобилем, считая, что при установке акселерометра в автомобиле не были допущены ошибки его ориентации:

$$\begin{cases} a_{lgt} = a_x - \omega_z^2 d_x - \varepsilon_z d_y \\ a_{lat} = \omega_z v_x - \omega_z^2 d_y + \varepsilon_z d_x' \end{cases} \quad (14)$$

где $[d_x \ d_y]$ – проекции вектора \mathbf{d} на оси системы координат Oxy , связанной с автомобилем.

Система уравнений (14) не описывает полной связи между вектором состояния \mathbf{x} и измеренными акселерометром значениями продольного и поперечного ускорения автомобиля, так как акселерометр, в силу принципа своего устройства, измеряет не ускорение, как таковое, а равнодействующую внешних сил, приложенных к его чувствительному элементу. В состав этих сил, помимо сил инерции, подлежащих измерению, входит сила гравитации, проекция которой на плоскость, в которой установлен 2D-акселерометр, является ненулевой в случае нахождения автомобиля не на ровной горизонтальной поверхности. Таким образом, запишем

уравнения кинестатики для чувствительного элемента 2D-акселерометра в проекции на плоскость его измерения (рис. 2), считая при записи уравнений, что автомобиль движется прямолинейно (изменения показаний акселерометра при криволинейном движении отражены в системе уравнений (14) и не зависят от углов крена и тангажа автомобиля), а изменения углов продольного и поперечного уклона дороги представляют собой квазистационарные процессы. В результате получим систему уравнений:

$$\begin{cases} m_s a_{lgt} = m_s a_x + m_s g \cdot \sin(\tilde{\theta}), \\ m_s a_{lat} = m_s g \cdot \sin(\tilde{\gamma}), \end{cases} \quad (15)$$

где $g = 9.81 \text{ м/с}^2$ – ускорение свободного падения, m_s – масса инерционного элемента акселерометра, $\tilde{\theta} = \theta + \hat{\theta}$ – угол тангажа автомобиля, $\hat{\theta}$ – угол продольного наклона автомобиля относительно дорожного полотна, $\tilde{\gamma} = \gamma + \hat{\gamma}$ – угол крена автомобиля, $\hat{\gamma}$ – угол поперечного наклона автомобиля относительно дорожного полотна.

Углы продольного и поперечного наклона могут быть ненулевыми вследствие неравномерного распределения нагрузки на подвеску автомобиля и изменяться динамически при колебаниях подвески. В текущей работе пренебрегается моделью последней и принимается, что углы продольного и поперечного наклона автомобиля постоянны.

Сократив в системе уравнений (15) массу инерционного элемента m_s , получим выражения для измерений продольного и поперечного ускорения, учитывающие углы тангажа и крена автомобиля при его прямолинейном движении:

$$\begin{cases} a_{lgt} = a_x + g \cdot \sin(\tilde{\theta}), \\ a_{lat} = g \cdot \sin(\tilde{\gamma}). \end{cases} \quad (16)$$

Соответственно, добавив последние слагаемые из правых частей системы уравнений (16) в систему уравнений (14), имеем выражения, связывающие измерения ускорения акселерометром с вектором состояния \mathbf{x} при криволинейном движении автомобиля:

$$\begin{cases} a_{lgt} = a_x - \omega_z^2 d_x - \varepsilon_z d_y + g \cdot \sin(\tilde{\theta}), \\ a_{lat} = \omega_z v_x - \omega_z^2 d_y + \varepsilon_z d_x + g \cdot \sin(\tilde{\gamma}). \end{cases} \quad (17)$$

Установим зависимость между показаниями скоростей осей каждого из колес и переменными вектора состояния \mathbf{x} . Поскольку, как было условлено ранее, принимается, что автомобиль в каждый отдельный момент времени совершает плоскопараллельное движение в плоскости дороги, для нахождения связи линейных скоростей осей задних колёс со скоростью центра задней оси автомобиля может быть применена теорема о мгновенном центре скоростей (МЦС):

$$\frac{v_x}{R} = \frac{v_{rl}}{R - 0.5B} = \frac{v_{rr}}{R + 0.5B} = \omega_z, \quad (18)$$

где R – мгновенный радиус кривизны траектории движения центра задней оси автомобиля, B – колея автомобиля (рис. 3).

Из системы уравнений (18) выразим скорости осей

задних колёс v_{rl} и v_{rr} через v_x и ω_z :

$$\begin{cases} v_{rl} = v_x - 0.5B\omega_z, \\ v_{rr} = v_x + 0.5B\omega_z. \end{cases} \quad (19)$$

Связь между скоростями осей передних колёс и задних колёс можно установить, используя формулу Эйлера о связи между скоростями различных точек твёрдого тела:

$$\begin{cases} \mathbf{v}_{fl} = \mathbf{v}_{rl} + \boldsymbol{\omega} \times \mathbf{d}_l, \\ \mathbf{v}_{fr} = \mathbf{v}_{rr} + \boldsymbol{\omega} \times \mathbf{d}_r, \end{cases} \quad (20)$$

где \mathbf{d}_l – вектор, направленный от оси заднего левого колеса до оси переднего левого колеса, \mathbf{d}_r – вектор, направленный от оси заднего правого колеса до оси переднего правого колеса.

Учитывая, что в правых частях обоих выражений (20) слагаемые вектора ортогональны друг другу, имеем:

$$\begin{cases} v_{fl} = \sqrt{v_{rl}^2 + \omega_z^2 L^2}, \\ v_{fr} = \sqrt{v_{rr}^2 + \omega_z^2 L^2}, \end{cases} \quad (21)$$

где L – колёсная база автомобиля.

Подставив (19) в (21) имеем:

$$\begin{cases} v_{fl} = \sqrt{(v_x - 0.5B\omega_z)^2 + \omega_z^2 L^2}, \\ v_{fr} = \sqrt{(v_x + 0.5B\omega_z)^2 + \omega_z^2 L^2}. \end{cases} \quad (22)$$

После раскрытия скобок в (22) получаем итоговые выражения зависимости скоростей осей передних колёс от переменных вектора состояния \mathbf{x} :

$$\begin{cases} v_{fl} = \sqrt{v_x^2 - Bv_x\omega_z + (0.25B^2 + L^2)\omega_z^2}, \\ v_{fr} = \sqrt{v_x^2 + Bv_x\omega_z + (0.25B^2 + L^2)\omega_z^2}. \end{cases} \quad (23)$$

Обозначение	Величина	Единицы измерения	Примечания
a_{igt_meas}	продольное ускорение	м/с ²	используются «сырые» показания 2D-акселерометра без калибровки
a_{lat_meas}	поперечное ускорение	м/с ²	
φ_{wheel}	угол поворота рулевого колеса	рад	определяются датчиком угла поворота руля (SAS)
χ_{wheel}	скорость вращения рулевого колеса	рад/с	
v_{fl}	скорость оси переднего левого колеса	м/с	вычисляются электронным блоком антиблокировочной системы (ABS) по показаниям датчиков угловых скоростей колёс
v_{fr}	скорость оси переднего правого колеса	м/с	
v_{rl}	скорость оси заднего левого колеса	м/с	
v_{rr}	скорость оси заднего правого колеса	м/с	
ω_{z_meas}	угловая скорость	рад/с	используются «сырые» показания 2D-акселерометра

Таблица 1. Показания датчиков автомобиля

Таблица 2. Наблюдаемые переменные состояния

Обозначение	Величина	Единицы измерения	Примечания
v_x	продольная скорость	м/с	определяются для центра задней оси автомобиля (рис. 1)
a_x	продольное ускорение	м/с ²	
θ	угол продольного уклона дороги	рад	не равен углу тангажа автомобиля (рис. 2)
γ	угол поперечного уклона дороги	рад	не равен углу крена автомобиля (рис. 2)
ω_z	угловая скорость	рад/с	считается, что автомобиль совершает плоскопараллельное движение (рис. 1)
ε_z	угловое ускорение	рад/с ²	
φ	средний угол поворота передних колёс	рад	угол схождения передних колёс предполагается нулевым
χ	средняя скорость поворота передних колёс	рад/с	

Таблица 3. Компоненты вектора управления

Обозначение	Величина	Единицы измерения	Примечания
T_e	момент вала двигателя	Нм	определяется электронным блоком управления двигателем
i_t	передаточное число трансмиссии	-	включает в себя передаточные числа коробки передач и главной передачи
p_{mc}	давление в мастер-цилиндре тормозной системы	Па	определяется датчиком давления в магистрали цилиндра




Рисунок 2 – Углы тангажа и крена автомобиля

Установим зависимость между измерениями углового положения и угловой скорости рулевого колеса и вектором состояния \mathbf{x} . Согласно кинематической схеме Аккермана в совокупности с геометрией классической рулевой рейки [17] угловое положение рулевого колеса имеет кинематическую связь со средним углом поворота передних колёс автомобиля. Соответственно, имеет место некоторая зависимость вида:

$$\varphi_{wheel} = s(\varphi). \quad (24)$$




Рисунок 3 – Взаимосвязь линейных скоростей осей колёс со скоростью центра задней оси автомобиля

Функцию (24) называют рулевой характеристикой. Её вид, в общем случае, нелинейный и определяется геометрическими параметрами рулевой трапеции и передаточным отношением между рулевым колесом и рулевой рейкой, однако, как отражено в [17], может быть приближённо описан линейной функцией:

$$\varphi_{wheel} = K_{st}\varphi. \quad (25)$$

Соответственно, связь между средней скоростью вращения передних колёс автомобиля и угловой скоростью поворота рулевого колеса может быть описана аналогично:

$$\chi_{wheel} = K_{st}\chi. \quad (26)$$

Уравнения (17,19,23,25,26) в совокупности образуют модель измерений $\mathbf{h}(\mathbf{x})$ расширенного фильтра Калмана. Однако, при составлении модели следует учитывать необходимость определения её якобиана \mathbf{H} , требуемого для вычисления ковариационной матрицы отклонений \mathbf{S} и матрицы коэффициентов усиления фильтра Калмана \mathbf{K} . Производные от уравнений (23) по некоторым компонентам вектора (9) будут громоздкими, поэтому при включении в состав модели измерения имеет смысл возвести в квадрат левые и правые части равенств (23):

$$\begin{cases} v_{fl}^2 = v_x^2 - Bv_x\omega_z + (0.25B^2 + L^2)\omega_z^2 \\ v_{fr}^2 = v_x^2 + Bv_x\omega_z + (0.25B^2 + L^2)\omega_z^2 \end{cases} \quad (27)$$

что объясняет наличие вместо скоростей передних колёс их квадратов в составе вектора (8).

В результате, модель измерений фильтра Калмана,

получаемая из уравнений (17,19,25,26,27), принимает следующий вид:

$$\mathbf{z}_k = \mathbf{h}(\mathbf{x}^k) = \begin{cases} a_x^k - \omega_z^{k2} d_x - \varepsilon_z^k d_y + g \cdot \sin(\theta^k + \hat{\theta}) \\ \omega_z^k v_x^k - \omega_z^{k2} d_y + \varepsilon_z^k d_x + g \cdot \sin(\gamma^k + \hat{\gamma}) \\ K_{st}\varphi^k \\ K_{st}\chi^k \\ v_x^{k2} - Bv_x^k\omega_z^k + (0.25B^2 + L^2)\omega_z^{k2} \\ v_x^{k2} + Bv_x^k\omega_z^k + (0.25B^2 + L^2)\omega_z^{k2} \\ v_x^k - 0.5B\omega_z^k \\ v_x^k + 0.5B\omega_z^k \\ \omega_z^k \end{cases} \quad (28)$$

При этом, немаловажно указать, что представленная модель измерений содержит следующие допущения:

1. Приближённое описание рулевой характеристики (24) линейной функцией (25);
2. Отсутствие явного учета в (19,27) проскальзывания или блокировки колёс;
3. Ошибка курсовой ориентации установки акселерометра при выводе (17) принимается равной нулю;
4. Подвеска автомобиля считается жёсткой.

С. Модель динамики системы

Определим вид модели динамики системы для фильтра Калмана. Для этого, в первую очередь, обратим внимание, что некоторые переменные вектора состояния \mathbf{x} являются производными по времени от других переменных. Так, например, продольное ускорение a_x является первой производной по времени от продольной скорости v_x . Соответственно, уравнение связи продольной скорости автомобиля в текущий момент времени v_x^k с предыдущим вектором состояния \mathbf{x}_{k-1} можно описать следующим выражением:

$$v_x^k = v_x^{k-1} + a_x^{k-1}\Delta t, \quad (29)$$

где Δt – временной период в секундах между оценками фильтра.

Аналогично для вычисления угловой скорости и среднего угла поворота передних колёс автомобиля справедливы выражения:

$$\omega_z^k = \omega_z^{k-1} + \varepsilon_z^{k-1}\Delta t, \quad (30)$$

$$\varphi^k = \varphi^{k-1} + \chi^{k-1}\Delta t. \quad (31)$$

Установим зависимость между угловым ускорением автомобиля ε_z и вектором состояния \mathbf{x} . Для этого воспользуемся уравнением кинематики велосипедной модели:

$$\omega_z = \frac{v}{L} \tan(\varphi).$$

Учитывая, что модуль угла поворота среднего колеса автомобиля φ , как правило, не превышает 30° , можно приближённо считать, что в диапазоне возможных значений φ справедливо выражение:

$$\omega_z \approx \frac{v_x}{L} \varphi. \quad (32)$$

Продифференцируем по времени уравнение (32):

$$\begin{aligned} \varepsilon_z &= \frac{1}{L} (\dot{v}_x \varphi + v_x \dot{\varphi}), \\ \varepsilon_z &= \frac{1}{L} (a_x \varphi + v_x \chi). \end{aligned} \quad (33)$$

Для углов продольного и поперечного уклона дороги

θ и γ и средней скорости поворота передних колёс автомобиля χ модель динамики будет иметь упрощённый вид ввиду отсутствия прямой связи с другими переменными состояниями:

$$\theta^k = \theta^{k-1}, \quad (34)$$

$$\gamma^k = \gamma^{k-1}, \quad (35)$$

$$\chi^k = \chi^{k-1}. \quad (36)$$

Аналогичное выражение для предсказания продольного ускорения a_x представляет собой модель продольной динамики автомобиля. Для его получения рассмотрим силы, действующие на автомобиль при его прямолинейном движении [18].

Сила тяги автомобиля, непосредственно приводящая его в движение, как правило, не поддаётся прямому измерению, но может быть определена косвенно через модель трансмиссии автомобиля, связывающую крутящий момент двигателя и крутящий момент колёс автомобиля:

$$F_t = \frac{2T_e i_t \eta_t}{d_w}, \quad (37)$$

где T_e – момент двигателя (Нм), i_t – передаточное отношение трансмиссии (включая передаточное отношение главной передачи), η_t – КПД трансмиссии, d_w – диаметр колеса (м).

Тормозная сила, если не рассматривать случай блокировки колёс, как правило, не допускаемый антиблокировочной системой, пропорциональна давлению в тормозном мастер-цилиндре p_{mc} . При этом, коэффициент пропорциональности k_b сложным образом зависит от диаметра колеса, геометрических параметров колодок, коэффициента трения в колодках и т.д.

$$F_b = k_b p_{mc}. \quad (38)$$

На автомобиль при движении также действует сила сопротивления воздуха, пропорциональная квадрату продольной скорости движения v_x . Коэффициент пропорциональности k_{aero} зависит от площади лобовой проекции автомобиля, его формы и плотности воздуха.

$$F_{aero} = k_{aero} v_x^2. \quad (39)$$

При ненулевой величине угла продольного уклона дороги θ , проекция на плоскость дороги силы гравитации, действующей на автомобиль, ненулевая и определяется выражением:

$$F_{slope} = m_a g \sin(\theta), \quad (40)$$

где m_a – масса автомобиля (кг).

Также на автомобиль действуют силы трения качения, величина которых зависит от продольного уклона дороги θ , массы автомобиля m и коэффициента трения качения k_{roll} :

$$F_{roll} = k_{roll} m_a g \cos(\theta). \quad (41)$$

Итого, уравнение продольной динамики автомобиля имеет вид:

$$m_\Sigma a_x = F_\Sigma = F_t - F_b - F_{aero} - F_{slope} - F_{roll}, \quad (42)$$

где m_Σ – приведённая масса автомобиля (кг), включающая в себя инерционные свойства трансмиссии автомобиля, двигателя и полезную нагрузку, a_x – продольное ускорение автомобиля (м/с²), F_Σ – сумма проекций внешних сил на продольную ось автомобиля (Н).

При подстановке в уравнение (42) выражений (37, 38, 39, 40, 41) имеем:

$$m_\Sigma a_x = F_\Sigma = \frac{2T_e i_t \eta_t}{d_w} - k_b p_{mc} - k_{aero} v_x^2 - m_a g \sin(\theta) - k_{roll} m_a g \cos(\theta). \quad (43)$$

В результате модель динамики системы для расширенного фильтра Калмана, составляемая из выражений (29, 30, 31, 33, 34, 35, 36, 43), принимает вид:

$$\mathbf{x}^k = \mathbf{f}(\mathbf{x}^{k-1}, \mathbf{u}^{k-1}) = \begin{cases} v_x^{k-1} + a_x^{k-1} \Delta t \\ F_\Sigma(T_e^{k-1}, i_t^{k-1}, p_{mc}^{k-1}, v_x^{k-1}, \theta^{k-1}) \\ m_\Sigma \\ \theta^{k-1} \\ \gamma^{k-1} \\ \omega_z^{k-1} + \varepsilon_z^{k-1} \Delta t \\ \frac{1}{L} (a_x^{k-1} \varphi^{k-1} + v_x^{k-1} \chi^{k-1}) \\ \varphi^{k-1} + \chi^{k-1} \Delta t \\ \chi^{k-1} \end{cases}. \quad (44)$$

Параметры описанной модели продольной динамики автомобиля (43) определяются или из документации, или в ходе процедуры идентификации, например, методом линейной регрессии [19]. Тем не менее, даже при правильном выборе параметров, точность такой модели ограничивается её структурой. Ниже перечислены основные допущения представленной модели динамики в целом:

1. В (43) не учитываются переменные силы трения, возникающие в трансмиссии автомобиля и, порой, существенные при старте, а также переменный характер приведённой массы автомобиля m_Σ (зависит в явном виде от, например, номера передачи) и массы автомобиля m_a , меняющейся от степени его загрузки;
2. Модель тормозной силы (38) является линейной лишь в первом приближении ввиду силы сопротивления возвратных пружин суппорта, существенной на старте торможения. Коэффициент k_b зависит от температуры тормозов и переменного, ввиду непостоянства давления в шинах, радиуса колеса;
3. Коэффициент трения качения k_{roll} зависит от переменного давления в шинах и переменного дорожного покрытия;
4. Модель силы тяги (37) не учитывает переменный характер КПД трансмиссии η_t , переменный диаметр колеса d_w , и нарушение зависимости в момент буксования автомобиля или размыкания сцепления;
5. Постоянство углов продольного и поперечного уклона дороги, а также средней скорости поворота передних колёс (34,35,36);
6. Средний угол поворота передних колёс принимается достаточно малым для $\tan(\varphi) \sim \varphi$ при получении (33).

Способом повышения точности модели продольной динамики автомобиля является усложнение её структуры. Одним из вариантов реализации такого подхода является использование нейронной сети. В таком случае, модель (43) может быть представлена в виде неизвестной функции следующего вида:

$$a_x^k = f_{nn}(T_e^{k-1}, i_t^{k-1}, p_{mc}^{k-1}, v_x^{k-1}, \theta^{k-1}). \quad (45)$$

Важным критерием выбора архитектуры нейронной сети для аппроксимации (45) является удобство вычисления частных производных от её выхода по её входам. Это условие накладывается на модель ввиду того, что для вычисления матрицы ковариаций состояния (2) расширенный фильтр Калмана требует вычислять матрицу Якоби от модели динамики системы. В частности, по этой причине для идентификации функции (45) удобно использовать многослойный перцептрон.

При этом, немаловажно указать, что нейросетевая модель продольной динамики автомобиля не лишается всех допущений модели классической, поскольку нейронная сеть, пусть и позволяет учесть нелинейные зависимости, вместе с тем, имеет постоянные параметры, как и классическая модель, а потому не учитывает переменный характер динамики автомобиля, обусловленный изменениями его характеристик в процессе эксплуатации.

Для обучения нейросетевой модели продольной динамики требуется набор данных, включающий не только предполагаемые заведомо истинными компоненты вектора управления (T_e, i_t, p_{mc}) , но и неизвестные переменные вектора состояния (v_x, a_x, θ) . Такая же проблема возникает при идентификации параметров уравнения (43). Решением проблемы является итеративный подход к разработке фильтра Калмана, описываемый в виде следующей последовательности этапов:

1. Настройка параметров (алгоритм описан в главе III) расширенного фильтра Калмана с упрощённой моделью продольной динамики: $a_x^k = a_x^{k-1}$.
2. Вычисление последовательности наблюдений $\mathbf{x}^N = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$ по последовательностям управлений $\mathbf{u}^N = \{\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_N\}$ и измерений $\mathbf{z}^N = \{\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_N\}$ для фильтра с упрощённой моделью и включение последовательности наблюдений в обучающий набор данных $\{\mathbf{x}^N, \mathbf{u}^N, \mathbf{z}^N\}$.
3. Использование полученного набора данных для идентификации параметров уравнения (43) или нейронной сети (45).
4. Настройка параметров расширенного фильтра Калмана с «полноценной» моделью динамики.

III. НАСТРОЙКА ПАРАМЕТРОВ РАСШИРЕННОГО ФИЛЬТРА КАЛМАНА

Для исполнения шагов предсказания и коррекции расширенного фильтра Калмана, описанных в главе II.A, необходимо иметь оценки неточности модели и источников данных, представляющие собой матрицы ковариаций шума процесса \mathbf{Q} и шума измерений \mathbf{R} . Выбор значений коэффициентов в составе матриц в рассматриваемой задаче оценки продольного ускорения осложняется их внушительным количеством: размерность матрицы \mathbf{Q} соответствует размерности вектора состояния системы (8x8), размерность матрицы \mathbf{R} соответствует размерности вектора измерений (9x9). Кроме того, ввиду отсутствия возможности записи для реального автомобиля заведомо истинных показаний продольного ускорения, исключается применение методов обучения с учителем для поиска искомых параметров.

В существующих работах, посвященных автоматизированной настройке параметров фильтра

Калмана, представлены следующие методы поиска значений коэффициентов матриц ковариаций, не требующие заведомо истинных данных о наблюдаемых переменных:

1. Оптимизация по критерию нормированных невязок [20];
2. Метод максимального правдоподобия [21];
3. Методы Монте-Карло [22];
4. Методы байесовской оптимизации [23].

В текущей работе для настройки матриц ковариаций описанного расширенного фильтра Калмана будет использован метод максимального правдоподобия. Ключевая идея этого подхода применительно к подбору параметров фильтров Калмана заключается в поиске таких матриц \mathbf{Q} и \mathbf{R} , чтобы наблюдаемая последовательность состояний была наиболее вероятной. Согласно [20] последовательность невязок (3) для правильно настроенного фильтра представляет собой последовательность независимых нормально распределенных случайных векторов с нулевым средним и ковариацией (4). Соответственно, для последовательности измерений $\mathbf{z}^N = \{\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_N\}$ совместная плотность вероятности наблюдений может быть факторизована через произведение плотностей невязок:

$$p(\mathbf{z}^N | \mathbf{Q}, \mathbf{R}) = \prod_{k=1}^N p(\mathbf{y}_k | \mathbf{Q}, \mathbf{R}) = \prod_{k=1}^N \frac{1}{\sqrt{(2\pi)^m |\mathbf{S}_k|}} \exp\left(-\frac{1}{2} \mathbf{y}_k^T \mathbf{S}_k^{-1} \mathbf{y}_k\right). \quad (46)$$

Тогда логарифмическая функция правдоподобия записывается в виде суммы:

$$L(\mathbf{Q}, \mathbf{R}) = -\frac{1}{2} \sum_{k=1}^N (m \log(2\pi) + \log |\mathbf{S}_k| + \mathbf{y}_k^T \mathbf{S}_k^{-1} \mathbf{y}_k). \quad (47)$$

Максимизация логарифмического правдоподобия (47) эквивалентна минимизации следующего функционала:

$$J(\mathbf{Q}, \mathbf{R}) = \sum_{k=1}^N (\log |\mathbf{S}_k| + \mathbf{y}_k^T \mathbf{S}_k^{-1} \mathbf{y}_k), \quad (48)$$

где невязки \mathbf{y}_k и матрицы ковариаций для невязок \mathbf{S}_k неявно зависят от \mathbf{Q} и \mathbf{R} .

Для поиска минимума функционала (48) предлагается использовать метод роя частиц [24]. Значимыми преимуществами метода роя частиц (в сравнении с, например, градиентными методами) в контексте рассматриваемой задачи являются устойчивость к попаданию в локальные минимумы и отсутствие необходимости в вычислении производных функционала (48). Главным же недостатком метода являются высокие вычислительные затраты (на каждой итерации метода роя частиц для каждой «частицы» необходимо вычислять текущее значение функционала (48), для чего требуется итеративно вычислять наблюдение расширенного фильтра Калмана на всей обучающей последовательности данных). Тем не менее, этот недостаток перекрывается тем, что настройку фильтра в рамках практического применения требуется производить однократно. Кроме того, метод роя частиц поддается распараллеливанию вычислений.

IV. ВЫЧИСЛИТЕЛЬНЫЙ ЭКСПЕРИМЕНТ

Расширенный фильтр Калмана для наблюдения продольного ускорения автомобиля на основе полученных моделей предсказания и измерения был реализован на языке python с использованием библиотеки `filterpy` с открытым исходным кодом [25] в двух версиях: с аналитической (43) и с нейросетевой (45) моделями продольной динамики автомобиля. Для подбора параметров матриц ковариаций был реализован алгоритм максимизации правдоподобия на основе метода роя частиц. Обучение нейросетевой модели продольной динамики осуществлялось с помощью библиотеки `pytorch` [26]. Для вычисления её матрицы Якоби использовалось автоматическое дифференцирование с помощью модуля `torch.autograd`.

Для поиска параметров фильтров и обучения нейросетевой модели продольной динамики автомобиля были собраны тренировочный и тестовый наборы данных. Важно отметить, что для вычисления функционала (48) в ходе оптимизации параметров фильтра требуется упорядоченная во времени последовательность измерений, достаточно продолжительная для того, чтобы ковариационная матрица состояния (2) успела «стабилизироваться». Таким образом, в качестве тренировочной выборки был записан непрерывный 600-секундный лог с CAN-сети автомобиля, содержащий:

1. Участки с разгонами различной интенсивности;
2. Участки с торможениями различной интенсивности;
3. Участки с поворотами различной кривизны;
4. Участки с подъемами и спусками с различным уклоном.

Графики, иллюстрирующие фрагмент тренировочного набора данных представлены на рисунке 4.

В качестве тестовых данных был записан аналогичный 600-секундный лог с участками схожей разнообразности, но по иному маршруту. Оба набора данных были декодированы в csv-формат и приведены к общей для всех записанных CAN-сообщений временной сетке с постоянным периодом 0.01 секунды с помощью линейной интерполяции.

Для проведения вычислительного эксперимента были выбраны гиперпараметры метода роя частиц [24]:

- Количество итераций: 30;
- Размер популяции: 32;
- Коэффициент инерции: 1.27;
- «Когнитивный» коэффициент: 0.76;
- «Социальный» коэффициент: 0.76.

На рисунке 5 представлены графики изменения в процессе обучения средних по популяции значений функционала на тренировочной и тестовой выборках для фильтра с аналитической моделью продольной динамики. Графики изменения средних значений функционала на тренировочной выборке обозначены сплошными линиями (разные цвета для разных попыток запуска метода оптимизации), графики же соответствующих изменений средних значений функционала на тестовой выборке обозначены пунктирными линиями. Аналогичные графики для фильтра с нейросетевой моделью продольной динамики представлены на рисунке 6.

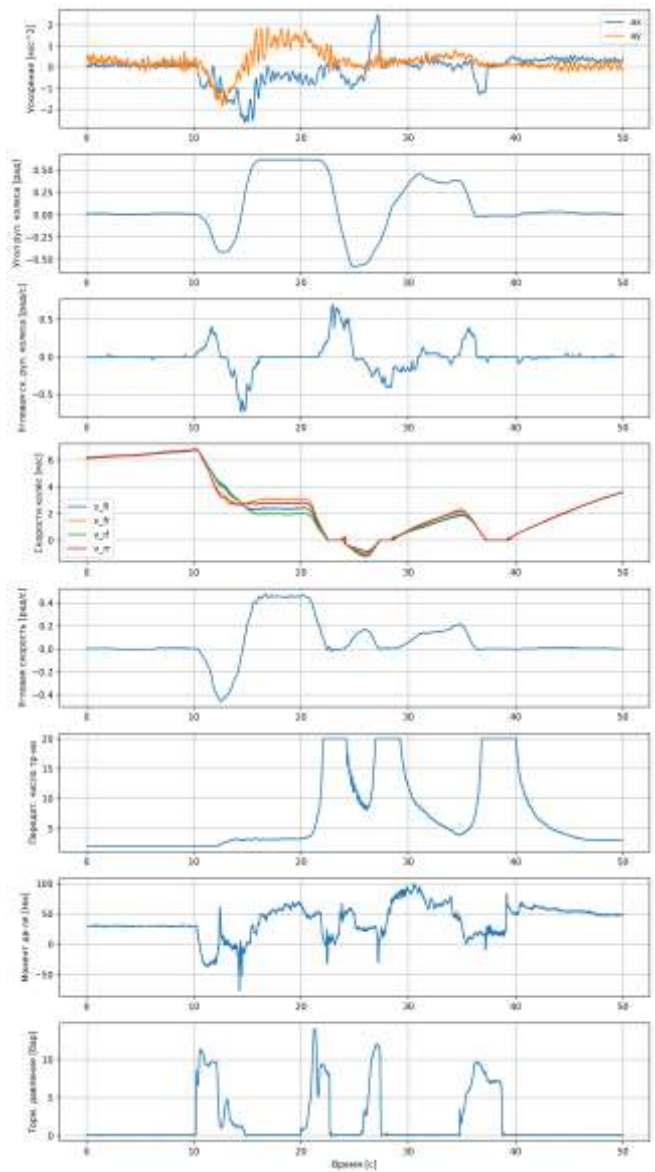


Рисунок 4 – Фрагмент тренировочного набора данных

Как можно видеть, метод роя частиц стабильно сходится в каждом из экспериментов без существенного переобучения. Кроме того, заметно, что в случае фильтра с нейросетевой моделью динамики он сходится немного быстрее. Результаты работы расширенного фильтра Калмана с аналитической и нейросетевой моделями продольной динамики после их настройки представлены на рисунке 7.

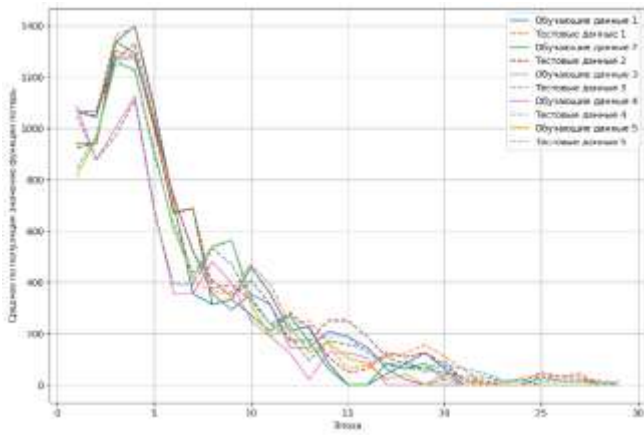


Рисунок 5 – Изменение среднего значения функционала для фильтра с классической моделью




Рисунок 6 – Изменение среднего значения функционала для фильтра с нейросетевой моделью




Рисунок 7 – Результаты наблюдения настроенными фильтрами

Качество обоих фильтров после их настройки было оценено с помощью метрики нормированной суммы квадратов невязок на тестовой выборке:

$$Metric = \frac{1}{N} \sum_{k=1}^N (\mathbf{y}_k^T \mathbf{S}_k^{-1} \mathbf{y}_k). \quad (49)$$

Согласно [20], для наилучшим образом настроенного фильтра, математическое ожидание (49) равно размерности вектора измерений ($\dim(\mathbf{z}) = 9$). В целях сравнения точности фильтров с различными моделями продольной динамики фильтры с обеими моделями были настроены по 5 раз. В таблице 4 приведены результаты вычисления метрики для настроенных фильтров после каждого независимого цикла настройки.

Таблица 4. Значение метрики (49) для фильтров с различными моделями продольной динамики

№	Метрика (49) для фильтра с моделью (43)	Метрика (49) для фильтра с моделью (45)
1	9.41	9.09
2	9.36	9.13
3	9.42	9.14
4	9.48	9.24
5	9.33	9.15

Как можно видеть из таблицы 4, значение метрики (49) для фильтра Калмана с нейросетевой моделью продольной динамики стабильно ближе к целевому значению ($\dim(\mathbf{z}) = 9$), что свидетельствует о его более высокой точности оценки состояния.

V. ЗАКЛЮЧЕНИЕ

В статье предложен метод построения наблюдателя продольного ускорения автомобиля на основе расширенного фильтра Калмана с нейросетевой моделью продольной динамики автомобиля в составе фильтра. Вычислительный эксперимент показал преимущество использования нейронной сети для оценки текущего ускорения в сравнении с классической моделью с жестко заданной структурой. Критерием лучшей модели в составе фильтра служила нормированная сумма квадратов невязок фильтра Калмана, вычисленная в ходе моделирования работы фильтра на тестовой выборке упорядоченных во времени данных.

Результаты работы, а именно, архитектура наблюдателя (модели измерений и динамики системы) и использованный метод настройки матриц ковариации расширенного фильтра Калмана могут быть использованы инженерами в области разработки беспилотных транспортных средств или систем помощи водителю для повышения точности определения продольного ускорения автомобиля.

БЛАГОДАРНОСТИ

Исследование выполнено при поддержке гранта Российского научного фонда № 25-21-00704, <https://rscf.ru/project/25-21-00704/>.

БИБЛИОГРАФИЯ

- [1] Jeon S., Tomizuka M. Benefits of acceleration measurement in velocity estimation and motion control //Control Engineering Practice. – 2007. – Т. 15. – №. 3. – С. 325-332.
- [2] Marotta R. et al. On the prediction of the sideslip angle using dynamic neural networks //IEEE Open Journal of Intelligent Transportation Systems. – 2024. – Т. 5. – С. 281-295..
- [3] De Winkel K. N. et al. Standards for passenger comfort in automated vehicles: Acceleration and jerk //Applied Ergonomics. – 2023. – Т. 106. – С. 103881.
- [4] Сысоева С. Интеллектуальные автомобильные ассистенты и датчики. Функций-больше," железа"-меньше //Компоненты и технологии. – 2012. – №. 1 (126). – С. 7-18.
- [5] Сысоева С. Автомобильные акселерометры. Часть 3. Классификация и анализ базовых рабочих принципов //Компоненты и технологии. – 2006. – №. 55. – С. 42-49.
- [6] Oniz Y., Kayacan E., Kaynak O. A dynamic method to forecast the wheel slip for antilock braking system and its experimental evaluation //IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics). – 2008. – Т. 39. – №. 2. – С. 551-560.
- [7] Rajamani R. Vehicle dynamics and control. – Boston, MA : Springer US, 2006.

- [8] Matsuzaki R., Kamai K., Seki R. Intelligent tires for identifying coefficient of friction of tire/road contact surfaces using three-axis accelerometer //Smart Materials and Structures. – 2015. – T. 24. – №. 2. – C. 025010.
- [9] Wang X. et al. Review of State Estimation Methods for Autonomous Ground Vehicles: Perspectives on Estimation Objects, Vehicle Characteristics, and Key Algorithms //Sensors. – 2025. – T. 25. – №. 13. – C. 3927.
- [10] Park S. et al. Model predictive control-based fault detection and reconstruction algorithm for longitudinal control of autonomous driving vehicle using multi-sliding mode observer //Microsystem Technologies. – 2020. – T. 26. – №. 1. – C. 239-264.
- [11] Li J. et al. Research on vehicle stability control based on a union disturbance observer and improved adaptive unscented Kalman filter //Electronics. – 2024. – T. 13. – №. 16. – C. 3220.
- [12] Liu Y., Cui D., Peng W. Vehicle state and parameter estimation based on adaptive robust unscented particle filter //Journal of Vibroengineering. – 2023. – T. 25. – №. 2. – C. 392-408.
- [13] Napolitano Dell'Annunziata G. et al. Estimation of vehicle longitudinal velocity with artificial neural network //Sensors. – 2022. – T. 22. – №. 23. – C. 9516.
- [14] Qiao Y. et al. Curvature-Constrained Vector Field for Motion Planning of Nonholonomic Robots //IEEE Transactions on Robotics. – 2025.
- [15] Tan C. et al. Vehicle state estimation combining physics-informed neural network and unscented Kalman filtering on manifolds //Sensors. – 2023. – T. 23. – №. 15. – C. 6665.
- [16] Qi D. et al. Maximum correntropy extended Kalman filter for vehicle state observation //International journal of automotive technology. – 2023. – T. 24. – №. 2. – C. 377-388.
- [17] Иоффе М. Л. Принцип Аккермана и его реализации в современных автомобилях //Известия высших учебных заведений. Машиностроение. – 2021. – №. 9 (738). – C. 40-47.
- [18] Zhang T. et al. A survey of vehicle dynamics modeling methods for autonomous racing: Theoretical models, physical/virtual platforms, and perspectives //IEEE Transactions on Intelligent Vehicles. – 2024. – T. 9. – №. 3. – C. 4312-4334.
- [19] James S. S., Anderson S. R., Da Lio M. Longitudinal vehicle dynamics: A comparison of physical and data-driven models under large-scale real-world driving conditions //Ieee Access. – 2020. – T. 8. – C. 73714-73729.
- [20] Cai L. et al. Towards auto-tuning of Kalman filters for underwater gliders based on consistency metrics //OCEANS 2019 MTS/IEEE SEATTLE. – IEEE, 2019. – C. 1-6.
- [21] Fraser C., Ulrich S. An adaptive Kalman filter for spacecraft formation navigation using maximum likelihood estimation with intrinsic smoothing //2018 Annual American Control Conference (ACC). – IEEE, 2018. – C. 5843-5848.
- [22] Oshman Y., Shaviv I. Optimal tuning of a Kalman filter using genetic algorithms //AIAA guidance, navigation, and control conference and exhibit. – 2000. – C. 4558.
- [23] Chen Z. et al. Kalman filter tuning with Bayesian optimization //arXiv preprint arXiv:1912.08601. – 2019.
- [24] Kennedy J., Eberhart R. Particle swarm optimization //Proceedings of ICNN'95-international conference on neural networks. – iee, 1995. – T. 4. – C. 1942-1948.
- [25] Labbe R. R. Filterpy documentation. [Online]. – URL: <https://filterpy.readthedocs.io/en/latest/> (accessed 01.03.2026).
- [26] Paszke A. et al. Pytorch: An imperative style, high-performance deep learning library //Advances in neural information processing systems. – 2019. – T. 32. [Online]. – URL: <https://github.com/pytorch/pytorch> (accessed 01.03.2026).

Car longitudinal acceleration observer based on the Kalman Filter with neural system dynamics model

I. A. Gromov

Abstract— An accurate car longitudinal acceleration estimation is a task that requires a wide range of factors to be taken into account: the dynamics model, the types of sensors used, etc. This paper presents an approach to car longitudinal acceleration observer development based on an extended Kalman filter. System model used in the filter for state prediction. Both an analytical model of the longitudinal dynamics of the system and its neural network model are considered. The accuracy of observers based on both models was compared after preliminary automated adjustment of the filter parameters using the particle swarm method. The paper presents in detail the derivation of prediction and measurement models for the proposed observer. To set up the filter and evaluate its accuracy, real data obtained from the passenger car's CAN bus was used.

Keywords— car dynamics model, Kalman filter, longitudinal acceleration, maximum likelihood method, neural network, particle swarm method, road slope.

REFERENCES

- [1] Jeon S., Tomizuka M. Benefits of acceleration measurement in velocity estimation and motion control //Control Engineering Practice. – 2007. – T. 15. – #. 3. – S. 325-332.
- [2] Marotta R. et al. On the prediction of the sideslip angle using dynamic neural networks //IEEE Open Journal of Intelligent Transportation Systems. – 2024. – T. 5. – S. 281-295..
- [3] [3] De Winkel K. N. et al. Standards for passenger comfort in automated vehicles: Acceleration and jerk //Applied Ergonomics. – 2023. – T. 106. – S. 103881.
- [4] Sysoeva S. Intellektual'nye avtomobil'nye assistenty i datchiki. Funkcij-bol'she, " zheleza"-men'she //Komponenty i tehnologii. – 2012. – #. 1 (126). – S. 7-18.
- [5] Sysoeva S. Avtomobil'nye akselerometry. Chast' 3. Klassifikacija i analiz bazovyh rabochih principov //Komponenty i tehnologii. – 2006. – #. 55. – S. 42-49.
- [6] Oniz Y., Kayacan E., Kaynak O. A dynamic method to forecast the wheel slip for antilock braking system and its experimental evaluation //IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics). – 2008. – T. 39. – #. 2. – S. 551-560.
- [7] Rajamani R. Vehicle dynamics and control. – Boston, MA : Springer US, 2006.
- [8] Matsuzaki R., Kamai K., Seki R. Intelligent tires for identifying coefficient of friction of tire/road contact surfaces using three-axis accelerometer //Smart Materials and Structures. – 2015. – T. 24. – #. 2. – S. 025010.
- [9] Wang X. et al. Review of State Estimation Methods for Autonomous Ground Vehicles: Perspectives on Estimation Objects, Vehicle Characteristics, and Key Algorithms //Sensors. – 2025. – T. 25. – #. 13. – S. 3927.
- [10] Park S. et al. Model predictive control-based fault detection and reconstruction algorithm for longitudinal control of autonomous driving vehicle using multi-sliding mode observer //Microsystem Technologies. – 2020. – T. 26. – #. 1. – S. 239-264.
- [11] Li J. et al. Research on vehicle stability control based on a union disturbance observer and improved adaptive unscented Kalman filter //Electronics. – 2024. – T. 13. – #. 16. – S. 3220.
- [12] Liu Y., Cui D., Peng W. Vehicle state and parameter estimation based on adaptive robust unscented particle filter //Journal of Vibroengineering. – 2023. – T. 25. – #. 2. – S. 392-408.
- [13] Napolitano Dell'Annunziata G. et al. Estimation of vehicle longitudinal velocity with artificial neural network //Sensors. – 2022. – T. 22. – #. 23. – S. 9516.
- [14] Qiao Y. et al. Curvature-Constrained Vector Field for Motion Planning of Nonholonomic Robots //IEEE Transactions on Robotics. – 2025.
- [15] Tan C. et al. Vehicle state estimation combining physics-informed neural network and unscented Kalman filtering on manifolds //Sensors. – 2023. – T. 23. – #. 15. – S. 6665.
- [16] Qi D. et al. Maximum correntropy extended Kalman filter for vehicle state observation //International journal of automotive technology. – 2023. – T. 24. – #. 2. – S. 377-388.
- [17] Ioffe M. L. Princip Akkermana i ego realizacii v sovremennyh avtomobiljah //Izvestija vysshih uchebnyh zavedenij. Mashinostroenie. – 2021. – #. 9 (738). – S. 40-47.
- [18] Zhang T. et al. A survey of vehicle dynamics modeling methods for autonomous racing: Theoretical models, physical/virtual platforms, and perspectives //IEEE Transactions on Intelligent Vehicles. – 2024. – T. 9. – #. 3. – S. 4312-4334.
- [19] James S. S., Anderson S. R., Da Lio M. Longitudinal vehicle dynamics: A comparison of physical and data-driven models under large-scale real-world driving conditions //Ieee Access. – 2020. – T. 8. – S. 73714-73729.
- [20] Cai L. et al. Towards auto-tuning of Kalman filters for underwater gliders based on consistency metrics //OCEANS 2019 MTS/IEEE SEATTLE. – IEEE, 2019. – S. 1-6.
- [21] Fraser C., Ulrich S. An adaptive Kalman filter for spacecraft formation navigation using maximum likelihood estimation with intrinsic smoothing //2018 Annual American Control Conference (ACC). – IEEE, 2018. – S. 5843-5848.
- [22] Oshman Y., Shaviv I. Optimal tuning of a Kalman filter using genetic algorithms //AIAA guidance, navigation, and control conference and exhibit. – 2000. – S. 4558.
- [23] Chen Z. et al. Kalman filter tuning with Bayesian optimization //arXiv preprint arXiv:1912.08601. – 2019.
- [24] Kennedy J., Eberhart R. Particle swarm optimization //Proceedings of ICNN'95-international conference on neural networks. – IEEE, 1995. – T. 4. – S. 1942-1948.
- [25] Labbe R. R. Filterpy documentation. [Online]. – URL: <https://filterpy.readthedocs.io/en/latest/> (accessed 01.03.2026).
- [26] Paszke A. et al. Pytorch: An imperative style, high-performance deep learning library //Advances in neural information processing systems. – 2019. – T. 32. [Online]. – URL: <https://github.com/pytorch/pytorch> (accessed 01.03.2026).