

Применение методов машинного обучения для анализа вектора состояний РТК

А. И. Тихонова¹, Г. А. Мамедов², Д. А. Косневич³,
В. С. Радабольский⁴, М. А. Гисмельбари⁵

Санкт-Петербургский государственный электротехнический университет
«ЛЭТИ» им. В.И. Ульянова (Ленина)

¹ai.tikhonova037068@gmail.com, ²geidar.mamedov1@gmail.com, ³kosnevich.1999@gmail.com
⁴radabolsky2017@gmail.com, ⁵mohamedgbari@gmail.com

Аннотация. Современные системы локальной навигации робототехнических комплексов (РТК) имеют большое количество источников информации, которые часто обладают низкой точностью и большим количеством шумов. Фильтр Калмана позволяет минимизировать влияние этих шумов на данные, однако для нелинейных задач это сделать невозможно ввиду сложности определения шумов распределения. Для поиска таких нетривиальных зависимостей применяются различные модели машинного обучения. В работе представлен обзор способов повышения точности результата вектора Калмана для локальной навигации РТК с помощью методов машинного обучения.

Ключевые слова: вектор состояний; фильтр Калмана; машинное обучение; нейронная сеть

I. ВВЕДЕНИЕ

В настоящее время существует множество устройств, на которые установлены датчики для сбора информации, на основе данных с которых происходит осуществление полезных функций таких устройств. Для оценки и прогнозирования состояния системы на основе неполной и зашумленной информации используется фильтр Калмана. Данный математический алгоритм был разработан Рудольфом Калманом в 1960 году [1] и стал широко применяться во многих сферах жизни: авиации, бытовой технике, инженерных, эконометрических приложениях, навигации объектов и др. Прежде, чем перейти к объяснению механизма работы данного алгоритма, необходимо ввести некоторые обозначения. Пусть x – вектор состояния системы, P – мера неопределенности вектора состояния. Вектор состояния представляет собой набор данных, с помощью которых можно оценить систему. Например, для оценки местоположения РТК он состоит из координат, в которых находится объект, а также его углов поворота. Работа фильтра Калмана подразделяется на два этапа: прогноз состояния системы и его коррекция. Сначала алгоритм прогнозирует будущее состояние системы на основе данных о ее текущем состоянии, а далее корректирует прогноз на основе новой информации, полученной от сенсоров. Для того, чтобы понять принцип работы фильтра Калмана далее приведем пример. Предположим, существует некоторый объект, который представляет собой динамическую систему с вектором состояния x . Он перемещается в некоторой локальной системе координат и периодически получает

информацию о своем смещении. В момент времени t объект обладает состоянием x_t . С помощью фильтра Калмана необходимо получить состояние системы в момент $t + 1$. Для прогноза состояния системы \hat{x}_{t+1} используется формула (1):

$$\hat{x}_{t+1} = Fx_t + Bu_{t+1}, \quad (1)$$

где F – матрица перехода между состояниями, x_t – состояние системы, вычисленное на шаге t , B – матрица управляющего воздействия, u_{t+1} – управляющее воздействие в момент $t + 1$.

У датчиков, по показаниям которых определяется состояние системы, есть неопределенность, которая определяется коэффициентом ковариации \hat{P}_{t+1} , по формуле (2).

$$\hat{P}_{t+1} = F \cdot P_t \cdot F^T + Q, \quad (2)$$

где F и F^T – матрица перехода между состояниями и ее транспонирование соответственно, P_t – значение ковариации на шаге t , Q – расчетная ошибка.

Каждый раз, когда происходит предсказание состояния системы, фильтр Калмана увеличивает неопределенность в оценке вектора состояния. Для случая движения объекта в одномерной системе координат ошибка увеличивается на случайную величину Q : $P_{t+1} = P_t + Q$. Стоит отметить, что в случаях, когда фильтр Калмана не может провести этап коррекции, то есть в момент $t + 1$ не было получено данных о состоянии системы, этап прогноза постоянно увеличивает ошибку определения состояния из-за погрешности модели, вычислительных погрешностей или в случае нелинейности движения.

Итак, получен прогноз системы объекта в момент $t + 1$. После выполнения внутренней оценки следующего состояния системы в момент $t + 1$ и обновления матрицы ковариации вычисляется коэффициент усиления Калмана K по формуле (3).

$$K = \frac{\hat{P}_{t+1} \cdot H^T}{H \cdot \hat{P}_{t+1} \cdot H^T + R}, \quad (3)$$

где H и H^T – матрица наблюдения и ее транспонирование соответственно, R – расчетная ошибка изменения.

Коррекция прогноза в момент $t + 1$ происходит с помощью формулы (4):

$$x_{t+1} = \hat{x}_{t+1} + K_{t+1}(z_{t+1} - H \cdot \hat{x}_{t+1}) \quad (4)$$

где z_{t+1} – текущие показания датчика, полученные в момент времени $t + 1$, x_{t+1} – прогнозируемое состояние системы после коррекции.

На последнем этапе коррекции происходит обновление коэффициента ковариации для следующей итерации по формуле (5):

$$P_{t+1} = (I - K \cdot H)\hat{x}_{t+1} \quad (5)$$

Однако, фильтр Калмана применим только при следующих условиях [2]:

- модель динамической системы объекта является линейной и может быть как стационарной, так и нестационарной;
- получаемые оценки вектора состояния на каждой итерации стремятся к оптимальным, что означает минимизацию дисперсии ошибки оценки.

Перемещение РТК не является линейной системой. Потому для определения его локальной позиции используется расширенный фильтр Калмана, или же Extended Kalman filter – EKF, предложенный в 1967 году и описанный в работах [3, 4]. Данный алгоритм применяет линеаризацию нелинейных уравнений состояния. Матрица переходов заменяется матрицей Якоби (матрицей частных производных). Использование линеаризации также добавляет ошибку на каждой итерации, на которой происходит оценка состояния системы. Более того, решение матрицы Якоби может быть чрезвычайно ресурсозатратным.

Для решения этих проблем в 1997 году был представлен Unscented Kalman Filter, который работает следующим образом: на каждом этапе вокруг полученной оценки вектора состояния выбирается минимальное число сигма-точек, которые после этого используются для аппроксимации математического ожидания и матрицы ковариации случайного вектора состояния системы. Сигма-точки проходят через нелинейную функцию системы для получения прогноза. При использовании UKF нелинейная функция системы не линеаризуется, в отличие от EKF. Подробно механизм работы UKF рассмотрен в [5].

В последующее время были представлены и другие алгоритмы, модифицирующие работу фильтра Калмана. Среди них, например, кубатурные фильтры Калмана, которые, в отличие от EKF, не используют линеаризацию и при этом обладают высоким порядком аппроксимации статистических характеристик исследуемых процессов [6].

Однако, несмотря на множество существующих улучшений фильтра Калмана, наиболее широко применяемым алгоритмом остается расширенный

фильтр Калмана (EKF). EKF несмотря на то, что он не дает оптимальную оценку состояния системы в общем случае, является наиболее простым алгоритмом в применении, может обеспечить приемлемую производительность системы в большинстве приложений, а также предоставляет широкую возможность для его модификации. Тем не менее, для некоторых задач РТК существуют способы для улучшения работы фильтра Калмана. Целью данной статьи является обзор наиболее успешных подходов к применению методов машинного обучения для повышения точности фильтра Калмана. Для этого в работе проведена категоризация двух основных подходов: комбинация и интеграция фильтра Калмана, преимущества и недостатки каждого.

II. МОТИВАЦИЯ РАБОТЫ

Фильтр Калмана – это математический метод, который использует серию измерений, наблюдаемых во времени, содержащих статистический шум и другие неточности, и дает оценки неизвестных переменных, которые, как правило, более точны, чем оценки, основанные только на одном измерении. Однако часто эти шумы сильно влияют на качество работы фильтра.

Основной проблемой работы с шумами является то, что они сложные и не поддаются какому-то одному распределению. В реальном мире они представляют собой несколько распределений, смешанных с друг другом, что делает трудным описание нелинейных зависимостей, основываясь лишь на механизмах и характеристиках данных. Для поиска нетривиальных и скрытых закономерностей нелинейных систем подходят модели машинного обучения. Стоит учесть и то, что все больше и больше робототехнических систем оснащаются бортовыми вычислителями, подходящими для обработки большого количества информации, что делает машинное обучение перспективным подходом для исследователей.

Основными методами решения задачи являются методы, основанные на длинной кратковременной памяти – Long short-term memory networks (LSTM) и рекуррентному блоку с регуляризацией – Gated recurrent unit (GRU), основанному на рекуррентной нейронной сети – Recurrent neural net (RNN). Среди всех подходов к решению данной проблемы выделяются два основных: внешнее комбинирование фильтра Калмана и моделей машинного обучения и интеграция нейронных сетей в фильтр Калмана.

III. ОБЗОР РЕШЕНИЙ

Интеграция методов машинного обучения (ML) с традиционными методами обработки сигналов открыла новые возможности для повышения точности и эффективности различных систем. Среди этих интеграций выделяются два основных метода: комбинирование фильтра Калмана и нейронных сетей и интеграция нейронных сетей в фильтр.

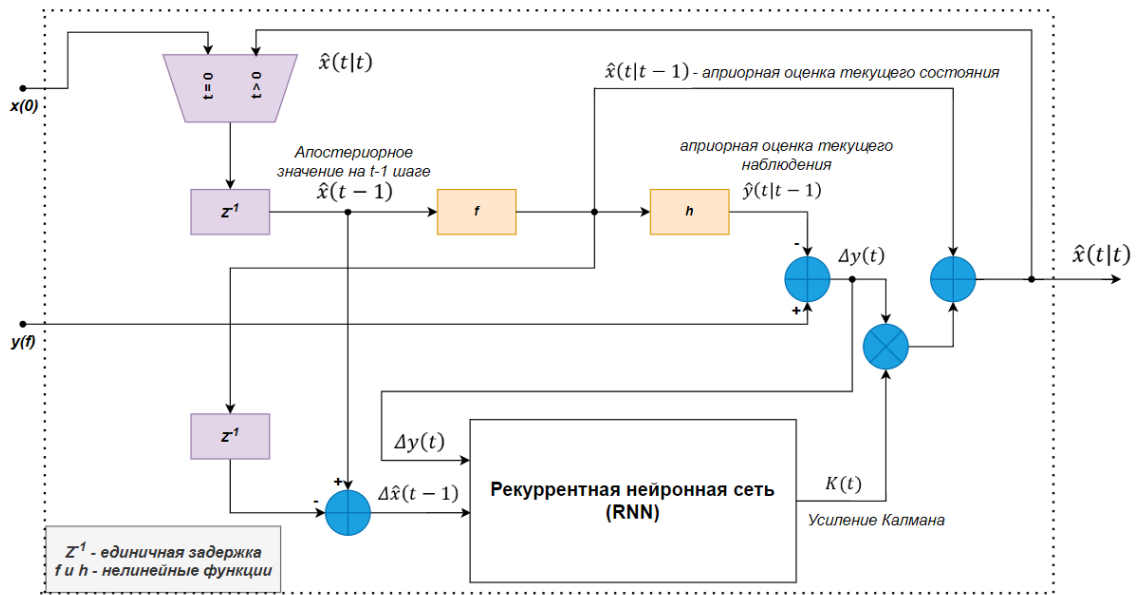


Рис. 1. Архитектура KalmanNet

А. Комбинирование фильтра Калмана и нейронных сетей

При таком виде взаимодействия фильтр и нейронные сети функционируют, не оказывая воздействия на внутреннюю структуру друг друга. Обычные конфигурации включают параллельную и последовательную реализацию фильтра Калмана и нейронных сетей соответственно. В настоящее время этот подход комбинирования моделей активно изучается в научных исследованиях в данной области и имеет большие перспективы развития.

Авторы статьи [7] предлагают адаптировать разработанную методологию KARNet, которая изначально была создана для задач автономного вождения, для векторного анализа состояния РТК, используя гибридный подход. Сочетание фильтров Калмана с рекуррентными нейронными сетями (RNN) может повысить точность прогнозирования траекторий РТК в целом и взаимодействия с окружающей средой. Использование автоэнкодеров для извлечения признаков из данных от датчиков РТК, RNN для моделирования временной динамики и фильтров Калмана для точной оценки состояния позволит значительно улучшить навигационные системы РТК, особенно в динамичных или непредсказуемых средах.

Теоретическая архитектура статьи [8] дает детальное понимание применения фильтров Калмана к системам со сложной динамикой, таким как РТК. Подход «Градиент стратегии удаляющегося горизонта» (receding-horizon policy gradient), который фокусируется на итеративном изучении параметров фильтра Калмана, может быть особенно полезен для РТК, работающих в различных и меняющихся условиях. Динамически настраивая параметры фильтра на основе данных в реальном времени, РТК могут достигать более точных оценок состояния, повышая как точность навигации, так и эксплуатационную безопасность в сценариях с конечным горизонтом, распространенных в миссиях РТК.

Авторы статьи [9] представили полностью инерциальный алгоритм локализации, который включает динамическую настройку параметров фильтра Калмана с использованием глубоких нейронных сетей. Их подход подчеркивает важность динамической оценки ковариации измерений для улучшения характеристик фильтра Калмана. Авторы протестировали свой метод на наборе данных одометрии KITTI, достигнув средней поступательной ошибки 1,10% при оценке трехмерного положения, скорости и ориентации транспортного средства, что в рамках используемого набора данных является значительным результатом. Кроме того, метод самостоятельно калибрует смещения IMU, что делает его надежным решением для приложений точных вычислений.

В статье [10] исследуется объединение методов глубокого обучения с фильтром Калмана для улучшения интеграции данных из Глобальной навигационной спутниковой системы и инерциальной навигационной системы. Также в работе представлена новая структура, которая использует глубокое обучение для извлечения и выбора функций, тем самым повышая точность фильтра Калмана при оценке состояния системы. Это исследование имеет важное значение для областей, требующих точной оценки состояния в динамических условиях, таких как автономные транспортные средства и робототехника.

В. Интегрирование нейронных сетей в фильтр Калмана

При данном подходе нейронные сети участвуют в итеративном процессе. Вместо того, чтобы предоставлять параметры или подходящие отношения до и после процесса фильтрации, они активно участвуют в самом процессе фильтрации. Предыдущие исследования изучали интеграцию сетей NARX с фильтром с целью оптимизации усиления фильтрации и значений одношагового прогнозирования с использованием доступной информации. Этот подход дал перспективные

предварительные результаты оценки. Тем не менее, данный подход мало изучен и требует более

тщательного исследования.

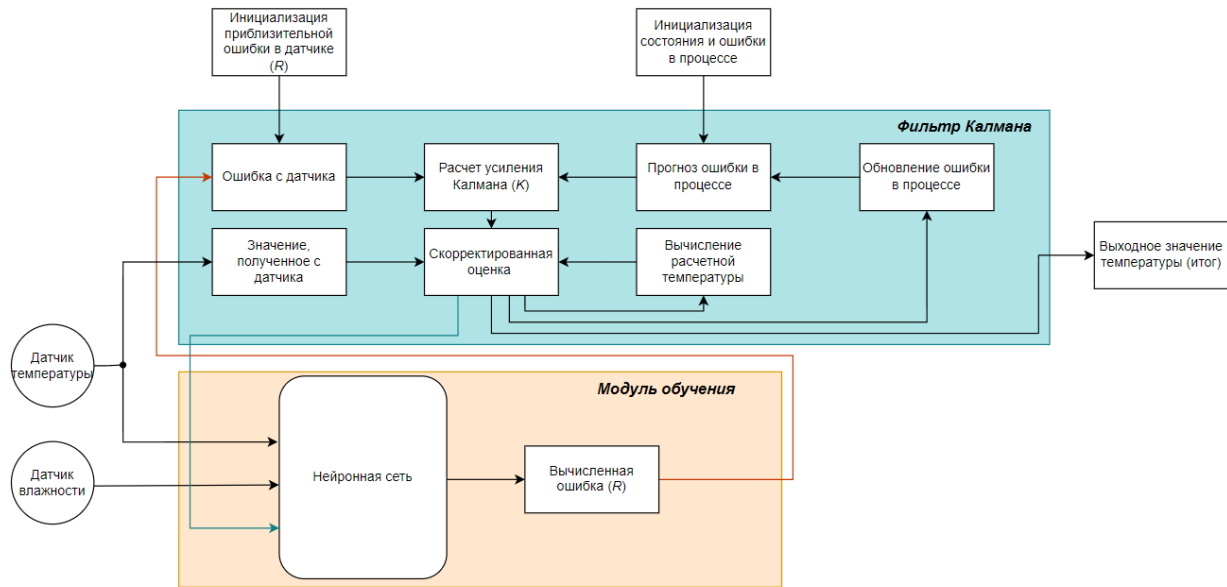


Рис. 2. Архитектура для предсказания температуры с использованием фильтра Калмана и нейронных сетей

Авторы статьи [11] представили гибридную модель, сочетающую глубокое обучение с ЕКФ. Данный подход предполагает, что распределение шумового сигнала неизвестно, при этом рассматриваются эволюция состояния и функции наблюдения как аппроксимации реальной динамики. Два типа структурного обучения Калмана созданы с использованием GRU (Gated Recurrent Units). В одном методе каждая неизвестная переменная состояния соответствует отдельному GRU. Общая архитектура состоит из трех блоков GRU и нескольких полностью связанных уровней, соединенных между собой нестандартным образом. Общая архитектура всей системы представлена на рис. 1. Численные исследования показали, что аналогично фильтру Калмана, этот метод поддерживает оценку в реальном времени, а RNN решает проблемы несоответствия моделей и нелинейности.

В статье [12] исследуются методы повышения производительности алгоритма фильтра Калмана в динамических условиях путем включения модуля обучения на основе искусственных нейронных сетей (ANN). Общая архитектура метода представлена на рис. 2. Главной целью данного метода является повышение точности фильтра Калмана в различных сценариях обработки данных. В исследовании представлены экспериментальные результаты, сравнивающие производительность фильтра Калмана как с модулем обучения, так и без него, выявляя заметные улучшения таких показателей, как среднее абсолютное отклонение (MAD) и среднеквадратическая ошибка (RMSE) при различных уровнях шума. Следовательно, авторы предлагают метод динамической настройки параметров фильтра Калмана на основе прогнозов модуля обучения, тем самым повышая его устойчивость и точность в динамических средах.

IV. СРАВНЕНИЕ

Исходя из проведенного обзора, можно заметить, что ни один из подходов не может решить все задачи РТК в целом. Однако, рассмотренные методы имеют некоторые преимущества для решения конкретных задач.

В случае, когда задача требует легкого внедрения в комплекс, предпочтительнее использовать подход комбинации, так как он прост в имплементации и позволяет использовать готовые компоненты, такие как известные модели машинного обучения и отдельные параметры фильтра Калмана. Использование подхода интеграции предполагает наличие высокого уровня сложности разработки системы. Однако, данный метод может обеспечить более высокую производительность и эффективность благодаря корректировке расчета некоторых параметров фильтра Калмана. Сравнительный анализ некоторых рассмотренных подходов приведен в табл. 1.

V. ЗАКЛЮЧЕНИЕ

При комбинировании фильтра Калмана с нейронной сетью каждый из подходов дополняет недостатки другого: нейронная сеть может предсказывать или заполнять данные, которые подаются на вход фильтру Калмана, тогда как сам фильтр Калмана может повысить точность и стабильность работы нейронной сети. Эти подходы просты и эффективны. Интегрирование нейронных сетей в фильтр Калмана исследует итерационный процесс, свойственный фильтру Калмана. При интеграции сочетании нейронная сеть использует концепцию «черного ящика» для представления взаимосвязей между внутренними параметрами фильтра Калмана. На текущий момент данная гибридная модель еще слабо изучена, хоть и полученные результаты являются более точными в сравнении с комбинированием.

ТАБЛИЦА I. СРАВНЕНИЕ ПРИВЕДЕННЫХ ПОДХОДОВ

Подходы	Динамическая настройка параметров	Улучшение интеграции данных навигационных систем	Внедрение нейронной сети в процесс работы фильтра Калмана	Повышение производительности фильтра Калмана
Источники	[8]	[9]	[11]	[12]
Тип комбинации	Комбинирование	Комбинирование	Интеграция	Интеграция
Роль искусственного интеллекта	Динамическая настройка параметров в основе данных в реальном времени	Обучение оптимальному коэффициенту Калмана вместе с ошибками инерциальных измерительных приборов	Сопоставление каждой переменной состояния блока GRU	Постоянный анализ показаний фильтра Калмана и внешних воздействий на систему
Характеристики	Возможность быстрого адаптивования к быстроменяющимся условиям	Повышение точности результата при средней ресурсозатратности	Преодоление нелинейности данных в реальном времени	Устойчивость к изменяющимся ошибкам датчика
Применение	Навигация РТК	Навигация колесных систем	Модели, в которых не указана явно статистика шума	Улучшение показаний с датчиков. Применение при изменяющейся погрешности датчика
Метод Машинного обучения	Receding horizon police gradient	Deep Neural Network, Convolutional Neural Network	Рекуррентные нейронные сети (RNN)	Искусственная нейронная сеть (ANN)
Достоинства	Возможность обобщения на широкий спектр областей дискретных систем без серьезных изменений в основном процессе	Высокая точность и робастность автоматическая калибровка; простота в реализации	Не применяет линеаризацию нелинейной модели; фильтрация происходит нелинейно, усиление Калмана зависит только от входного сигнала; устойчив к несоответствиям модели.	Адаптируемость к различным приложениям; продвинутое устранение шумов; меняет расчет ошибки датчика в фильтре Калмана
Недостатки	Метод ограничен дискретными системами	Ограничен данными с IMU	Сложность разработки и поддержки системы;	Сложность разработки и поддержки системы; ресурсозатратность

В целом, сочетание фильтра Калмана с нейронными сетями представляет собой перспективное направление исследований, обеспечивающее точные и надежные оценки состояния в сложных системах. Выбор метода интеграции фильтра Калмана с нейронной сетью зависит от сложности системы и требований к точности оценки состояния. Интеграция фильтра Калмана с нейронной сетью демонстрирует перспективные результаты в улучшении точности и стабильности оценки состояния.

В свете постоянно возрастающего спроса на точные и эффективные оценки состояния существует необходимость в дальнейших исследованиях и разработках данной темы.

СПИСОК ЛИТЕРАТУРЫ

- [1] Kalman R.E. A new approach to linear filtering and prediction problems. 1960.
- [2] Моделирование дискретного фильтра Калмана: Метод, указания к дипломному проектированию / Сост. Н.Г. Ламанова, Перм. нац. исслед. политехн. ун-т. Пермь, 2016. 27 с.
- [3] Gruber M. An approach to target tracking. MIT Lincoln Laboratory, 1967. С. 0038.
- [4] Larson R.E., Dressler R.M., Ratner R.S. Application of the extended kalman filter to ballistic trajectory estimation. Menlo Park: Stanford Research Institute, 1967.
- [5] Куликова М.В., Куликов Г.Ю. Численные методы нелинейной фильтрации для обработки сигналов и измерений // Вычислительные технологии. 2016. Т. 21. №. 4. С. 64-98.
- [6] Чубич В.М., Кулабухова С.О. Квадратно-корневые алгоритмы робастных модификаций непрерывно-дискретного кубатурного фильтра Калмана // Вычислительные технологии. 2020. Т. 25. №. 3. С. 88-98.
- [7] Manjunatha H. et al. Karnet: Kalman filter augmented recurrent neural network for learning world models in autonomous driving tasks //arXiv preprint arXiv:2305.14644. 2023.
- [8] Zhang X., Hu B., Başar T. Learning the Kalman filter with fine-grained sample complexity //2023 American Control Conference (ACC). IEEE, 2023. С. 4549-4554.
- [9] Brossard M., Barrau A., Bonnabel S. AI-IMU dead-reckoning //IEEE Transactions on Intelligent Vehicles. 2020. Т. 5. №. 4. С. 585-595.
- [10] Li S. et al. Deep Learning Based Kalman Filter for GNSS/INS Integration: Neural Network Architecture and Feature Selection //2023 International Conference on Localization and GNSS (ICL-GNSS). IEEE, 2023. С. 1-7.
- [11] Revach G. et al. KalmanNet: Neural network aided Kalman filtering for partially known dynamics //IEEE Transactions on Signal Processing. 2022. Т. 70. С. 1532-1547.
- [12] Ullah I., Fayaz M., Kim D. H. Improving accuracy of the Kalman filter algorithm in dynamic conditions using ANN-based learning module //Symmetry. 2019. Т. 11. №. 1. С. 94.