

## ВЫСОКОТОЧНОЕ АВТОНОМНОЕ ПОЗИЦИОНИРОВАНИЕ БЕСПИЛОТНОГО ЛОКОМОТИВА НА ОСНОВЕ КОМПЛЕКСИРОВАНИЯ НЕЙРОСЕТЕВОГО ИНТЕРФЕЙСА KAN С РАСШИРЕННЫМ ФИЛЬТРОМ КАЛМАНА

**ЕВДОКИМОВ Кирилл Александрович**<sup>1</sup>, аспирант кафедры «Автоматика и телемеханика на железнодорожном транспорте»; e-mail: kirill\_evdokimov\_95@mail.ru

**СОКОЛОВ Сергей Викторович**<sup>1,2</sup>, доктор техн. наук, профессор кафедры «Автоматика и телемеханика на железнодорожном транспорте»; профессор, заведующий кафедрой «Информатика и вычислительная техника»; e-mail: s.v.s.888@yandex.ru

**ШВАЛОВ Дмитрий Викторович**<sup>1</sup>, кандидат техн. наук, заведующий кафедрой «Автоматика и телемеханика на железнодорожном транспорте»; e-mail: d\_shvalov@mail.ru

**КАМЕНСКИЙ Владислав Валерьевич**<sup>1</sup>, кандидат техн. наук, доцент кафедры «Автоматика и телемеханика на железнодорожном транспорте»; e-mail: dcmdon@mail.ru

<sup>1</sup> Ростовский государственный университет путей сообщения; Ростов-на-Дону

<sup>2</sup> Московский технический университет связи и информатики, Северо-Кавказский филиал, Ростов-на-Дону

В статье рассмотрена задача повышения точности автономного определения навигационных параметров беспилотного локомотива в условиях отсутствия спутникового позиционирования. Предложен алгоритм позиционирования на основе комплексирования расширенного фильтра Калмана и сети Колмогорова — Арнольда. Фильтр производит оценивание пройденного пути и скорости по нелинейной модели движения благодаря одометру и тахометру. Сеть Колмогорова — Арнольда формирует упреждающий прогноз вектора состояния с учетом уклона и кривизны маршрута. Научная новизна заключается в использовании прогноза от сети в качестве априорной оценки фильтра и введении оценки доверия к прогнозу, определяемой по статистике ошибок. Работоспособность алгоритма исследована при помощи моделирования движения локомотива при наличии шумов измерений, проскальзывания колесных пар, кратковременных пропусков измерений, случайных ускорений, переменного уклона и кривизны пути. Результат показал снижение среднеквадратических ошибок по положению и скорости в сравнении со стандартным расширенным фильтром Калмана. Наибольшая эффективность заметна на участках разгона и торможения, где точность начинает снижаться у обоих способов, но гибридная схема сохраняет преимущество. Алгоритм ориентирован на работу в автономных локомотивах. Полученные данные характеризуют эффективность схемы в пределах области данных, использованных для обучения KAN, и требуют проверки на реальных маршрутах с иными характеристиками.

**Ключевые слова:** беспилотный локомотив, автономная навигация, оценка вектора состояния, расширенный фильтр Калмана, нейросетевой прогноз, упреждающая оценка, теорема Колмогорова — Арнольда, сеть KAN, алгоритм оценивания

DOI: 10.20295/2412-9186-2026-12-03-169-181

### ▼ Введение

В условиях современного развития транспорта постоянно возрастают требования к точности, безопасности и эффективности перевозочных процессов. Одним из ключевых условий надежного функционирования таких систем является оперативное определение местоположения транспортного объекта в текущий момент.

В настоящее время для позиционирования широко применяются системы, связанные со спутниковой навигацией (GPS, ГЛОНАСС и т. д.), оптические, а также инерциальные навигационные системы. Точность и устойчивость спутниковой навигации существенно зависят от условий распространения спутникового сигнала: значительное снижение качества позиционирования может

быть вызвано многолучевым распространением сигнала в условиях плотной городской застройки, экранированием сигнала в горной местности, а также его полной недоступностью в тоннелях и закрытых пространствах и др. [1–4].

Точность оптической навигации (визуальной одометрии), основанной на последовательном анализе изображений, может снижаться при недостаточной освещенности, ухудшении видимости, наличии динамических объектов и недостатке характерных признаков на изображении [5, 6].

Методы позиционирования, построенные на комплексировании измерений инерциальной навигационной системы и датчиков одометрии, с одной стороны, обеспечивают высокую автономность и независимость от других систем, но, с другой стороны, имеют такой существеннейший недостаток, как накопление ошибки во времени, что исключает длительное применение этих методов [1, 4, 7, 8].

В связи с этим для снижения ошибок позиционирования широко применяется подход к комплексированию всех вышеперечисленных навигационных систем, что позволяет компенсировать их частные недостатки и повысить тем самым устойчивость определения параметров движения локомотива [1, 2, 6, 9]. Однако эффективное объединение данных систем требует применения специальных алгоритмов обработки и фильтрации, способных учитывать шумы измерений, нелинейность движения объекта и изменяющиеся условия работы системы.

Целью исследования является разработка алгоритма высокоточного автономного оценивания вектора навигационных параметров беспилотного локомотива на основе комплексирования расширенного фильтра Калмана и нейросетевого прогнозирующего блока на базе сети Колмогорова — Арнольда. К разрабатываемому алгоритму предъявляются следующие требования:

- алгоритм должен основываться на адекватной физической модели движения локомотива и показаниях датчиков его штатного измерительного комплекса;
- обеспечивать устойчивую оценку вектора навигационных параметров;

- строить упреждающий прогноз состояния на горизонт 1–3 с, согласованный с временем реакции тормозной системы;
- сохранять работоспособность при потере измерительной информации.

Как критерии качества далее рассмотрим среднеквадратичные ошибки положения и скорости, а также точность упреждающего прогноза на заданный горизонт времени.

### Система уравнений движения локомотива

Для решения поставленной задачи высокоточного позиционирования локомотива целесообразно рассматривать его не как совокупность связанных тел, а как единую систему, движущуюся вдоль оси пути, в которой основными переменными состояния являются пройденный путь и скорость. В настоящее время в качестве базовой модели движения локомотива используется следующая система дифференциальных уравнений [10]:

$$\begin{aligned} \frac{ds}{dt} &= v, \\ \frac{dv}{dt} &= \xi \frac{G + G_1 v + G_2 v^2 + G_3 v^3 + G_4 v^4}{v(2v + \beta)} + w, \end{aligned} \quad (1)$$

где  $G = \text{const}$  — приведенная сила тяги локомотива;

$G_1 = \text{const}$  — коэффициент влияния постоянного сопротивления движению;

$G_2 = \text{const}$  — коэффициент влияния линейного сопротивления движению (тормозная сила);

$G_3 = \text{const}$  — коэффициент влияния линейно-квадратичного сопротивления движению;

$G_4 = \text{const}$  — коэффициент влияния квадратичного сопротивления движению;

$\beta = \text{const}$  — параметр скоростной зависимости расчетного коэффициента трения для тормозных колодок;

$\xi = \text{const}$  — коэффициент, учитывающий инерционные свойства локомотива;

$w$  — случайная составляющая ускорения локомотива, обусловленная множеством равномошных неопределенных факторов различной физической природы, аппроксимируемая далее центрированным белым гауссовским шумом с постоянной интенсивностью  $\sigma_v^2$ .

Данные коэффициенты зависят от параметров локомотива (тип, мощность), типа вагона, тормозных колодок и кривизны пути. Для расчета необходимо использовать актуальные параметры тяговых расчетов для поездов.

В силу того, что обработка измерительной информации в бортовом процессоре локомотива происходит в цифровом виде, уравнения (1) представим далее в дискретной форме:

$$\begin{aligned} X_k &= F(X_{k-1}) + W_{k-1}, \\ X_k &= \begin{bmatrix} s_k \\ v_k \end{bmatrix}, \quad F(X_{k-1}) = X_{k-1} + \Delta t \cdot \begin{bmatrix} v_{k-1} \\ f(v_{k-1}) \end{bmatrix}, \quad (2) \\ W_{k-1} &= \begin{bmatrix} 0 \\ \Delta t \cdot w_{k-1} \end{bmatrix}, \\ f(v_{k-1}) &= \xi \frac{G + G_1 v_{k-1} + G_2 v_{k-1}^2 + G_3 v_{k-1}^3 + G_4 v_{k-1}^4}{v_{k-1}(2v_{k-1} + \beta)}, \end{aligned}$$

где  $X_k$  — вектор навигационных параметров;  
 $k$  — шаг дискретизации;  
 $\Delta t$  — время дискретизации.

В качестве измерений используются показания штатных датчиков подвижного состава: одометра (измерение пройденного пути) и тахометра (измерение скорости) [1, 7, 8]. В общем виде вектор измерений навигационных параметров локомотива  $Z_k$  в момент времени  $k$  может быть представлен следующим образом:

$$Z_k = X_k + V_k, \quad (3)$$

где  $V_k$  — центрированный белый гауссовский вектор-шум с постоянной матрицей интенсивности  $D_V$ , обусловленный следующими причинами:

- для одометра — проскальзыванием колесной пары, погрешностью счета импульсов, износом бандажей и конечной дискретностью отсчетов;
- для тахометра — вибрациями подвижного состава, собственными погрешностями датчика, влиянием электромагнитных помех и дискретизацией аналогового сигнала.

Полученные уравнения вектора навигационных параметров локомотива (2) и их наблюдателя (3) позволяют в полной мере использовать для их оценки существующие методы

нелинейной фильтрации [11–14], в частности расширенный фильтр Калмана.

### Оценка навигационных параметров локомотива на основе расширенного фильтра Калмана

Расширенный фильтр Калмана (РФК) является нелинейным обобщением классического фильтра Калмана и широко используется в задачах навигации, управления, обработки сигналов [11–14]. Его применение к оценке вектора состояния  $X_k$ , заданного системой уравнений (2), с использованием комплексированных измерений одометра и тахометра (3) позволяет записать уравнение оценивания в следующем виде:

$$\hat{X}_k = F(\hat{X}_{k-1}) + K_k [Z_k - F(\hat{X}_{k-1})], \quad (4)$$

где  $\hat{X}_k$  — оценка вектора состояния системы в  $k$ -й момент времени;  
 $F(\hat{X}_{k-1})$  — экстраполированная оценка вектора состояния;  
 $K_k$  — коэффициент усиления фильтра:

$$\begin{aligned} K_k &= P_{k/k-1} (P_{k/k-1} + D_V)^{-1}, \\ P_{k/k-1} &= \Phi_k \cdot P_{k-1} \cdot \Phi_k^T + D_w, \\ P_k &= P_{k/k-1} - K_k P_{k/k-1}, \end{aligned}$$

где  $P_{k/k-1}$  — экстраполированная ковариационная матрица;  
 $P_k$  — ковариационная матрица в  $k$ -й момент времени.

Ниже, в разделе «Экспериментальные исследования», приведены результаты использования РФК для традиционных и априорно известных параметров модели локомотива. Полученные численные результаты иллюстрируют возможность эффективного применения РФК при отсутствии неопределенностей в модели. Но в реальной дорожной обстановке возникают такие неопределенности, как переменное по величине и знаку дополнительное сопротивление движению, обусловленное реальным профилем пути (уклоном и кривизной участка) и не учитываемое номинальными коэффициентами  $G_1$ – $G_4$  модели (1); случайные возмущения продольного ускорения локомотива, вызванные изменением сцепления колеса с рельсом и прочими неопределенными факторами;

возрастание погрешности одометра на криволинейных участках пути вследствие увеличения проскальзывания колесной пары.

Компенсация их влияния возможна на основе использования нейросетевого блока, дополняющего РФК прогнозом состояния локомотива [15–17] по показаниям тахометра и одометра совместно с оценками навигационных параметров предыдущего участка пути. Помимо этого, прогноз вектора состояния локомотива на заданное число шагов, выполняемый нейросетевым модулем, позволяет сформировать упреждающую оценку, согласованную с временем реакции тормозной системы.

### Анализ нейросетевого интерфейса на основе сети KAN

Для разработки подобного нейросетевого интерфейса оказывается весьма перспективной нейросеть KAN (Kolmogorov — Arnold Networks), построенная на основе доказанной А. Н. Колмогоровым и В. И. Арнольдом возможности представления любой непрерывной функции нескольких переменных суперпозицией непрерывных функций одной переменной [18]. Данная сеть предлагает замену традиционных линейных весов и фиксированных функций на комбинации одномерных функций с настраиваемыми параметрами [18]:

$$f(x) = f(x_1, \dots, x_n) = \sum_{q=0}^{2^n} \Phi_q \left( \sum_{p=1}^n \phi_{q,p}(x_p) \right), \quad (5)$$

где  $x_p$  — компоненты входного вектора;

$\phi_{q,p} [0,1]$  — внутренние одномерные функции, преобразующие каждый вход по отдельности;

$\Phi_q$  — внешние одномерные функции, действующие на суммы преобразованных входов.

В архитектуре KAN эта замена реализуется с помощью гладких обучаемых функций, размещенных на связях между узлами. На каждом ребре располагается индивидуальная обучаемая функция  $\phi_{q,p}$ , при этом узлы выполняют функцию суммирования поступающих значений [18, 19].

В силу того, что обучаемые функции на ребрах задаются в виде линейной комбинации базисных функций (*B*-сплайнов) [18]:

$$spline(x) = \sum c_i B_i(x), \quad (6)$$

где  $B_i(x)$  — базисные функции (*B*-сплайны);

$c_i$  — обучаемые коэффициенты.

Изменение отдельного коэффициента влияет преимущественно на соответствующий участок функции, что обеспечивает гибкость и устойчивость ее настройки.

Слой KAN представляет собой набор одномерных функций, связывающих узлы соседних слоев:

$$\Phi(l) = \{\phi_{q,p}^{(l)}\}, p = 1, \dots, n_l, q = 1, \dots, n_{l+1}, \quad (7)$$

где  $n_l$  и  $n_{l+1}$  — числа узлов в соседних слоях.

Значение  $q$ -го узла следующего слоя определяется суммой преобразованных входных значений:

$$x_q^{(l+1)} = \sum \phi_{q,p}^{(l)}(x_p^{(l)}). \quad (8)$$

Для повышения устойчивости обучения функция на ребре формируется из базовой и сплайновой составляющих:

$$\phi(x) = w_b b(x) + w_s spline(x), \quad (9)$$

где  $b(x)$  — фиксированная базовая функция, в качестве которой, как правило, берется:

$$b(x) = silu(x) = \frac{x}{1 + e^{-x}}, \quad (10)$$

$spline(x)$  — обучаемая сплайновая часть (6);  $w_b$  и  $w_s$  — обучаемые весовые коэффициенты, балансирующие вклад базовой и сплайновой составляющих.

Поскольку одного слоя в общем случае недостаточно для представления сложных зависимостей, слои объединяют в более глубокую структуру, представляющую собой композицию нескольких последовательно формируемых слоев:

$$KAN(x) = (\Phi^L \circ \Phi^{(L-1)} \circ \dots \circ \Phi^1)(x), \quad (11)$$

где  $L$  — число слоев; символ  $\circ$  обозначает последовательную реализацию слоев (выход предыдущего слоя является входом последующего).

Архитектура KAN в общем случае представлена на рис. 1.




Рис. 1. Архитектура KAN

### Комплексирование РФК и KAN для решения задачи позиционирования локомотива

В общем виде схема совместного применения РФК и KAN выглядит следующим образом. На выходе РФК формируется оценка текущего вектора навигационных параметров локомотива, сеть KAN играет роль прогнозирующего блока: формирует прогноз вектора состояния локомотива на заданный горизонт времени (горизонт упреждения) [15–17, 20].

Горизонт упреждения задается в виде числа шагов измерения и определяется требуемым временем прогноза (упреждения)  $T_{\text{упр}}$  и шагом дискретизации измерения (оценки)  $\Delta t$ :

$$h = \left\lceil \frac{T_{\text{упр}}}{\Delta t} \right\rceil. \quad (12)$$

С учетом характерного времени реакции современных тормозных систем рекомендуемое время упреждения составляет 1–3 с, что, например, при  $\Delta t = 0,1$  с соответствует  $h = 10 \dots 30$  шагам.

Сформированный на выходе сети KAN прогноз вектора параметров движения,

во-первых, используется системой управления (при расчете тормозного пути и упреждающего торможения), а во-вторых, возвращается в фильтр как улучшенное начальное приближение на следующем шаге, повышая устойчивость оценки при кратковременной потере измерений.

При этом прогнозу KAN назначается собственная ковариация  $Q_{KAN}$  — отдельный параметр доверия, по смыслу аналогичный матрице шума  $D_w$ .

Параметр  $Q_{KAN}$  задается по статистике ошибки прогноза сети на контрольной выборке [16, 17, 20]:

$$Q_{KAN} = \text{diag}(\sigma_s^2, \sigma_v^2), \quad (13)$$

где  $\sigma_s$  — среднестатистическая ошибка прогноза положения (пройденного пути) на горизонте упреждения  $h$ ;

$\sigma_v$  — среднестатистическая ошибка прогноза скорости на горизонте;

$\text{diag}(\sigma_s^2, \sigma_v^2)$  — диагональная матрица с дисперсиями ошибок положения и скорости.

Баланс между прогнозом KAN и физической моделью движения определяется как:

$$Q_{\text{пр}} = \alpha Q_{KAN} + (1 - \alpha) D_w, \quad (14)$$

где  $Q_{\text{пр}}$  — ковариация начального приближения;

$\alpha \in [0, 1]$  — весовой коэффициент доверия к нейросетевому прогнозу: при  $\alpha \rightarrow 1$  преобладает  $Q_{KAN}$ , при  $\alpha \rightarrow 0$  — ковариационная матрица  $D_w$  шума процесса физической модели движения, задающая недоверие к модельному прогнозу;

$(1 - \alpha) D_w$  — вклад модельной неопределенности в  $Q_{\text{пр}}$ .

Через соотношение  $Q_{KAN}$  и  $D_w$  фильтр взвешивает, в какой мере опираться на нейросетевой прогноз, а в какой — на физическую модель движения. Это обеспечивает устойчивость схемы комплексирования РФК — KAN: ошибочный прогноз не способен вызвать расходимость оценки — в пределе большого  $Q_{KAN}$  алгоритм вырождается в обычный РФК [16, 17, 20].

В настоящем исследовании сеть KAN обучается в режиме тренировки с учителем на контрольных метках открытой базы данных Railway-Precise-Localization [21], содержащей синхронизированные данные одометрии и высокоточные эталонные позиции. Целевым значением служит истинное будущее состояние локомотива. Сеть настраивается так, чтобы ее прогноз  $[\hat{s}_{k+h}, \hat{v}_{k+h}]^T$  максимально приближал фактическое состояние на  $h$  шагов вперед при движении по эталонной траектории. В качестве функции потерь используется среднеквадратичная ошибка между предсказанным и истинным будущим состоянием по обучающей выборке:

$$L = \frac{1}{N} \sum_{k=1}^N \| [\hat{s}_{k+h}, \hat{v}_{k+h}]^T - [s_{k+h}^{\text{ист}}, v_{k+h}^{\text{ист}}]^T \|^2. \quad (15)$$

Обучаемыми параметрами являются коэффициенты  $c_i$  B-сплайнов на ребрах, весовые коэффициенты  $w_b$  и  $w_s$  базовой и сплайновой составляющих активаций, а также смещения узлов. Оптимизация проводится градиентным методом; для предотвращения переобучения данные разбиваются на обучающую и валидационную выборки. После обучения параметры сети фиксируются, и в режиме эксплуатации KAN добавляет на каждом шаге лишь одно прямое прохождение через сеть, что сокращает вычислительные затраты.

Входной вектор признаков  $u_k$  включает компоненты текущей оценки навигационных параметров локомотива  $\hat{s}_k$  и  $\hat{v}_k$  и параметры участка пути по ходу движения: уклон  $i(s)$  и обратный радиус кривой  $1/R(s)$  [10].

Выходом сети является прогнозируемое состояние  $[\hat{s}_{k+h}, \hat{v}_{k+h}]^T$ . Размер скрытого слоя выбирается на основе теоремы Колмогорова — Арнольда, лежащей в основе выражения (5): для функции от  $n$  переменных достаточно скрытого слоя из  $2n + 1$  узлов. За счет того, что каждая связь в KAN реализует обучаемую функцию, а не скалярный вес, на практике требуемого качества прогноза удается достичь при существенно меньшем по сравнению с обычной нейросетью числе узлов, что соответствует свойству KAN достигать высокой точности при умеренном числе параметров и сохраняет интерпретируемость обучения: каждую функцию-активацию на ребре можно построить на графике и непосредственно увидеть обученную зависимость.

Обобщенная последовательность работы гибридного алгоритма представлена на рис. 2. Перед запуском основного цикла выполняется подготовительный этап: загрузка параметров локомотива ( $G, G_1, G_2, G_3, G_4, \xi, \beta, w$ ), геометрии маршрута (уклона и радиуса кривой) и контрольных меток Railway-Precise-Localization [21], а также инициализация вектора состояния  $x_0 = [x_0, v_0]^T$  (локомотив стоит на станции:  $v_0 = 0$ ) и начальной ковариационной матрицы  $P_0$ . Далее на каждом шаге выполняется следующая последовательность действий [11–14]:

1. Считывание данных датчиков — формирование вектора измерений  $z_k = [z_s, z_v]^T$ .

2. РФК PREDICT — прогноз состояния по уравнению движения с использованием в качестве априорной оценки прогноза KAN с предыдущего шага (при его наличии): вычисление  $\bar{s}_k, \bar{v}_k$ . Если прогноз KAN используется как априорная оценка, к ковариации добавляется  $Q_{KAN}$ , отражающая доверие к нейросетевому прогнозу.

3. РФК UPDATE — коррекция по датчикам: вычисление невязки  $[Z_k - F(\hat{X}_{k-1})]$ , коэффициента усиления  $K_k$ , оценки  $\hat{X}_k = F(\hat{X}_{k-1}) + K_k [Z_k - F(\hat{X}_{k-1})]$  и матрицы ковариации  $P_k$ .

4. KAN PREDICT — прогноз состояния на  $h$  шагов вперед:  $[\hat{s}_{k+h}, \hat{v}_{k+h}]^T = KAN(\hat{s}_k, \hat{v}_k, u_k)$




Рис. 2. Обобщенная последовательность работы гибридного алгоритма

по оценке фильтра и признакам маршрута  $i(s)$ ,  $R(s)$ .

5. Передача прогноза — прогноз КАН направляется в подсистему управления (для расчета тормозного пути) и сохраняется для использования на шаге 2 следующей итерации.

6. Сохранение результата шага — фиксация оценки  $\hat{x}_k = [\hat{s}_k, \hat{v}_k]^T$ , ковариации  $P_k$  и прогноза вектора состояния.

7. Проверка завершения (логический блок «конечная станция?»): при отрицательном исходе — переход к следующему шагу с возвратом к п. 1; при положительном — цикл завершается.

### Экспериментальные исследования

Работоспособность описанного гибридного алгоритма (рис. 2) проверялась имитационным моделированием движения локомотива на интервале 600 с с шагом дискретизации  $\Delta t = 0,1$  с при временном интервале поступления измерений одометра и тахометра 2,5 с, обеспечивающем согласование горизонта упреждения КАН с диапазоном 1–3 с. Параметры моделирования:  $\sigma_w = 0,015$  м/с<sup>2</sup> (шум процесса),  $\sigma_v = 0,30$  м/с (тахометр),  $\sigma_s = 1,4$ – $4,4$  м (одометр, рост на кривых). Неучтенные моделью (1) возмущения: уклон 1,6‰ + синусоида 3,0‰ (период 3000 м), кривизна пути (коэффициент 700). Данные факторы увеличивают ошибку РФК; схема РФК — КАН компенсирует их через зависимость остатка от  $i(s)$  и  $1/R(s)$ .

Приведенные далее результаты получены при реализации случайных возмущений на траектории с протяженным квазистационарным участком, попадающим в область определения обученных сплайновых функций сети и характеризующим достижимый верхний предел эффективности схемы РФК — КАН. Соответственно, представленные ниже показатели рассматриваются как оценка достижимого верхнего предела эффективности гибридной схемы РФК — КАН. Полученные результаты иллюстрируют закономерный рост абсолютной ошибки обоих алгоритмов на переходных режимах (разгон 0–60 с и торможение 540–600 с) при сохранении гибридной схемой систематического преимущества за счет учета нелинейной зависимости остатка от силы тяги и тормозной силы в признаковом пространстве КАН.

### Анализ ошибок позиционирования локомотива

На квазистационарном участке (60–540 с) ошибка классического РФК накапливается, тогда как схема РФК — КАН удерживает ее в узком диапазоне за счет прогноза КАН как уточненную априорную оценку фильтра. На участках разгона (0–60 с) и торможения (540–600 с) ошибки обоих алгоритмов возрастают, при этом гибридная схема сохраняет преимущество по точности (рис. 3) за счет учета нелинейности тяги, торможения и профиля пути.


Вероятностный анализ ошибок позиционирования показывает, что по сравнению с распределением ошибки РФК — КАН распределение ошибки классического РФК шире и смещено относительно нуля из-за накопления систематической составляющей, при этом для РФК — КАН гистограмма распределения уже ближе к нулю и симметричнее (рис. 4). Это согласуется с назначением  $Q_{KAN}$  по статистике ошибки прогноза и со взвешиванием: достоверный прогноз сужает неопределенность, а при росте  $Q_{KAN}$  схема вырождается в обычный РФК.

### Анализ ошибок оценки скорости локомотива


При оценке скорости у РФК наблюдаются всплески в моменты измерений и рост отклонения между ними. Блок КАН снижает амплитуду выбросов и средний уровень ошибки: сеть прогнозирует скорость с учетом уклона  $i(s)$  и кривизны  $1/R(s)$ , а ковариация  $Q_{KAN}$  ограничивает влияние прогноза при расхождении с измерениями. На переходных режимах ошибки возрастают у обоих алгоритмов, но РФК — КАН быстрее возвращается к малому уровню (рис. 5).

### Анализ среднеквадратичных ошибок позиционирования и скорости

Данные показатели характеризуют верхний предел эффективности схемы. Диаграммы на рис. 6 иллюстрируют снижение схемой РФК — КАН среднеквадратичных ошибок по обеим координатам относительно классического РФК: различие максимально на установившемся участке и сохраняется на переходных режимах.



**Рис. 3.** Ошибки позиционирования во времени



**Рис. 4.** Гистограммы распределения ошибок позиционирования

### Заключение

В результате проведенного исследования установлено, что задача высокоточного автономного позиционирования беспилотного локомотива в условиях ограниченной доступности спутниковой навигации может быть эффективно решена на основе применения гибридной схемы РФК — KAN и автономных

измерителей пути и скорости. В предложенной структуре расширенный фильтр Калмана реализует оценку состояния по дискретной модели движения и комплексированным автономным измерениям, а сеть Колмогорова — Арнольда формирует прогноз положения и скорости локомотива с учетом уклона и кривизны пути. Прогноз используется как системой управления




Рис. 5. Ошибки оценки скорости во времени




Рис. 6. Сравнение среднеквадратических ошибок позиционирования и скорости РФК и РФК + KAN

(при расчете тормозного пути), так и фильтром при оценке навигационных параметров, при этом заданный (ковариацией  $Q_{KAN}$  и коэффициентом  $\alpha$ ) баланс доверия исключает расхожимость при ошибочном прогнозе сети. Для возможности практического использования разработанного алгоритма сформулирова-

ны соответствующие требования к нему, обеспечивающие сохранение работоспособности схемы при кратковременной потере измерений: опора на физическую модель движения и штатные датчики (одометр, тахометр), упреждающий прогноз на горизонт 1–3 с, согласованный с временем реакции тормозной системы, и др.

Проведенное имитационное моделирование подтвердило эффективность предложенной схемы. Гибридный алгоритм РФК — KAN обеспечил существенное снижение средне-квадратических ошибок позиционирования и оценки скорости по сравнению с классическим РФК. Преимущество сохраняется и на переходных режимах разгона и торможения. Важно отметить, что алгоритм опирается только на штатный измерительный комплекс локомотива. Дооснащение подвижного состава дополнительной аппаратурой не требуется. В режиме эксплуатации выполняется лишь один прямой проход через обученную сеть на каждом шаге. Это допускает реализацию алгоритма на бортовом процессоре в реальном времени.

Полученные показатели характеризуют эффективность схемы в пределах области данных, использованных для обучения KAN. Поэтому дальнейшие исследования целесообразно направить на проверку алгоритма на реальных маршрутах с иными характеристиками. Также перспективной задачей является адаптивная настройка коэффициента доверия по текущей статистике невязок фильтра.

### Список источников

1. A Review on Technologies for Localisation and Navigation in Autonomous Railway Maintenance Systems / M. Rahimi [et al.] // *Sensors*. 2022. Vol. 22, no. 11. P. 4185. DOI: 10.3390/s22114185. EDN GCUHJY
2. Steuer M., Burdzik R., Piednoir F. Implementation of Global Navigation Satellite Systems in Railway Traffic Control Systems: Overview of Navigation Systems, Application Areas, and Implementation Plans / M. Steuer // *Applied Sciences (Switzerland)*. 2025. Vol. 15, no. 1. P. 356. DOI: 10.3390/app15010356. EDN RXMVLG
3. Михайлов С. Влияние многолучевости распространения радиоволн от навигационного космического аппарата на точность определения координат GPS-приемником // *Беспроводные технологии*. 2006. № 2 (3). С. 60–71. EDN MTGAGL
4. Sokolov S. V., Novikov A. I., Ivetic V. Determining the Initial Orientation for Navigation and Measurement Systems of Mobile Apparatus in Reforestation // *Inventions*. 2019. Vol. 4, no. 4. P. 56. DOI: 10.3390/inventions4040056. EDN RPIASW
5. Тюкин А. Л., Лебедев И. М. Исследование качества работы алгоритма навигации, использующего оптический канал получения данных // *Системы синхронизации, формирования и обработки сигналов*. 2014. Т. 5, № 2. С. 54–56. EDN VBLUJR
6. Rail Vehicle Localization and Mapping with LiDAR-Vision-Inertial-GNSS Fusion / Yu. Wang [et al.] // *IEEE Robotics and Automation Letters*. 2022. Vol. 7, no. 4. Pp. 9818–9825. DOI: 10.1109/lra.2022.3190093. EDN XKKPYQ
7. Ибраев А. С. Система навигации транспортного средства на основе интегрированной ИНС/ЧНС/одометрии // *Технические науки — от теории к практике*. 2017. № 5 (65). С. 31–43. EDN YPZWCV
8. A Novel Approach for Reducing Train Localization Errors by Inertial Measurements / M. Marinoni [et al.] // *IEEE Access*. 2023. Vol. 11. Pp. 5281–5295. DOI: 10.1109/access.2023.3236784. EDN JHEMLF
9. Разработка высокоточной спутниковой локально-инерциальной системы навигации для беспилотного управления транспортными средствами / Д. Е. Чикрин [и др.] // *Известия высших учебных заведений. Приборостроение*. 2020. Т. 63, № 12. С. 1094–1102. DOI: 10.17586/0021-3454-2020-63-12-1094-1102. EDN VJVIKN
10. Оптимизация управления движением поездов: учебное пособие для студентов специальностей «Управление и информатика в технических системах» и «Электрическая тяга» / Баранов Л. А. [и др.], под ред. Л. А. Баранова. М.: Московский государственный университет путей сообщения. 2011. 163 с. ISBN 978-5-7876-0151-0. EDN QNYRIV.
11. Степанов О. А. Применение теории нелинейной фильтрации в задачах обработки навигационной информации. Издание 3-е. СПб. ЦНИИ «Электроприбор», 2003. 370 с. ISBN 5-900780-45-7. EDN RJFCUL
12. Wang Ju, Chen X., Shi Ch. A Novel Robust Iterated CKF for GNSS/SINS Integrated Navigation Applications // *EURASIP Journal on Advances in Signal Processing*. 2023. Vol. 2023, no. 1. P. 83. DOI: 10.1186/s13634-023-01044-9. EDN EFMBJD
13. On the Adaptivity of Unscented Particle Filter for GNSS/INS Tightly-Integrated Navigation Unit in Urban Environment / O. Vouch [et al.] // *IEEE Access*. 2021. Vol. 9. Pp. 144157–144170. DOI: 10.1109/access.2021.3122006. EDN OMLNBZ
14. Chen L., Hu H., McDonald-Maier K. EKF Based Mobile Robot Localization. 2012 Third International Conference on Emerging Security Technologies // *IEEE*, 2012. P. 6.
15. Аль Б., Гаврилов А. И. Технологии интеллектуальных вычислений в задачах повышения точности интегрированных навигационных систем // *Вестник Московского государственного технического университета*

- им. Н. Э. Баумана. Серия «Приборостроение». 2019. № 1 (124). С. 62–89. DOI: 10.18698/0236-3933-2019-1-62-89. EDN VVIBSE
16. KalmanNet: Neural Network Aided Kalman Filtering for Partially Known Dynamics / G. Revach [et al.] // IEEE Transactions on Signal Processing. 2022. Vol. 70. Pp. 1532–1547. DOI: 10.1109/tsp.2022.3158588. EDN LLIILH
  17. Al Bitar N., Gavrilov A. A Novel Approach for Aiding Unscented Kalman Filter for Bridging GNSS Outages in Integrated Navigation Systems // Navigation, Journal of the Institute of Navigation. 2021. Vol. 68, no. 3. Pp. 521–539. DOI: 10.1002/navi.435. EDN NDUTQG
  18. KAN 2.0: Kolmogorov — Arnold Networks Meet Science / Z. Liu [et al.] M. Tegmark. 2024. DOI: 10.48550/arXiv.2408.10205
  19. Livieris I. E. C-KAN: A New Approach for Integrating Convolutional Layers with Kolmogorov — Arnold Networks for Time-Series Forecasting // Mathematics. 2024. Vol. 12, no. 19. P. 3022. DOI: 10.3390/math12193022. EDN TGGSAI
  20. Hybrid Kalman Filter — Kolmogorov — Arnold Network Using Local Interpretable Model-Agnostic Explanations for Photovoltaic Power Forecasting / J. P. M. Carvalho [et al.] // SN Computer Science. 2026. Vol. 7, no. 4. P. 319. DOI: 10.1007/s42979-026-04823-x. EDN ZAVNSI
  21. ETH-PBL. Railway-Precise-Localization: Raw Dataset Combining Precise GNSS and IMU Information in a Live Railway Application. URL: <https://github.com/ETH-PBL/Railway-Precise-Localization> (дата обращения: 03.08.2026)

*TRANSPORT AUTOMATION RESEARCH. 2026. Vol. 12, no. 3, pp. 169–181*  
 DOI: 10.20295/2412-9186-2026-12-03-169-181

### High-Precision Autonomous Positioning of an Unmanned Locomotive Based on the Integration of a Kolmogorov — Arnold Network with an Extended Kalman Filter

#### Information about authors:

**EVDOKIMOV Kirill Aleksandrovich**<sup>1</sup>, Postgraduate Student of the “Automation and Remote Control on Railways” Department;  
 e-mail: kirill\_evdokimov\_95@mail.ru

**SOKOLOV Sergej Viktorovich**<sup>1,2</sup>, Dr. Sci. in Engineering, Professor, Professor of the “Automation and Remote Control on Railways” Department, Head of the “Computer Science and Computer Engineering” Department;  
 e-mail: s.v.s.888@yandex.ru

**SHVALOV Dmitriy Viktorovich**<sup>1</sup>, PhD in Engineering, Head of the “Automation and Remote Control on Railways” Department;  
 e-mail: d\_shvalov@mail.ru

**KAMENSKIY Vladislav Valer'evich**<sup>1</sup>, PhD in Engineering, Associate Professor of the “Automation and Remote Control on Railways” Department;  
 e-mail: dcmdon@mail.ru

<sup>1</sup> Rostov State Transport University, Rostov-on-Don

<sup>2</sup> Moscow Technical University of Communications and Informatics, North Caucasus Branch, Rostov-on-Don

**Abstract:** the paper considers the problem of improving the accuracy of autonomous navigation-parameter estimation for an unmanned locomotive under unavailable or limited satellite positioning. A positioning algorithm based on the integration of an extended Kalman filter and a Kolmogorov — Arnold network is proposed. The extended Kalman filter estimates the travelled distance and velocity using a nonlinear model of longitudinal locomotive motion and measurements from autonomous sensors. The KAN module generates a predictive state estimate taking into account the track gradient and curvature. The scientific novelty consists in using the neural-network prediction to form an additional a priori estimate and in introducing a prediction-error covariance determined from validation data. The algorithm is studied by simulation under measurement noise, wheelset slip, short-term measurement outages, random longitudinal accelerations, variable gradient, and track curvature. The Railway-Precise-Localization dataset, containing precise GNSS/RTK and IMU measurements recorded onboard a railway

vehicle, is used to form a reference railway trajectory. If standard odometer and tachometer channels are absent from the selected data, their measurements are generated by adding prescribed errors to the reference distance and velocity. The results demonstrate a reduction in position and velocity root-mean-square errors compared with a conventional extended Kalman filter. The results characterize the performance of the method within the domain represented in the training data and require additional validation on independent routes with different dynamic and geometrical characteristics.

**Keywords:** unmanned locomotive, autonomous positioning, state-vector estimation, extended Kalman filter, neural-network prediction, predictive state estimation, Kolmogorov — Arnold network, KAN, odometry, railway navigation

#### References

1. Rahimi M., et al. A Review on Technologies for Localisation and Navigation in Autonomous Railway Maintenance Systems, *Sensors*, 2022, vol. 22, no. 11, p. 4185. DOI: 10.3390/s22114185. EDN GCUHJY.
2. Steuer M., Burdzik R., Piednoir F. Implementation of Global Navigation Satellite Systems in Railway Traffic Control Systems: Overview of Navigation Systems, Application Areas, and Implementation Plans, *Applied Sciences (Switzerland)*, 2025, vol. 15, no. 1, p. 356. DOI: 10.3390/app15010356. EDN RXMVLG.
3. Mihajlov S. Vlijanje mnogoluchevosti rasprostranjenja radiovaln ot navigacionnogo kosmicheskogo apparata na tochnost' opredelenija koordinat GPS-priemnikom [Influence of Multipath Propagation of Radio Waves from a Navigation Spacecraft on the Accuracy of Coordinate Determination by a GPS Receiver], *Besprovodnye tehnologii [Wireless Technologies]*, 2 Normally, 2006, no. 2 (3), pp. 60–71. EDN MTGAGL (In Russian)
4. Sokolov S. V., Novikov A. I., Ivetic V. Determining the Initial Orientation for Navigation and Measurement Systems of Mobile Apparatus in Reforestation, *Inventions*, 2019, vol. 4, no. 4, p. 56. DOI: 10.3390/inventions4040056. EDN RPIASW.
5. Tyukin A. L., Lebedev I. M. Issledovanie kachestva raboty algoritma navigacii, ispol'zujushhego opticheskij kanal polucheniya dannyh [Study of the Performance Quality of a Navigation Algorithm Using an Optical Data Acquisition Channel], *Sistemy sinhronizacii, formirovaniya i obrabotki signalov [Synchronization, Signal Generation and Processing Systems]*, 2014, vol. 5, no. 2, pp. 54–56. EDN VBLUJR (In Russian)
6. Wang Yu., et al. Rail Vehicle Localization and Mapping with LiDAR Vision Inertial GNSS Fusion, *IEEE Robotics and Automation Letters*, 2022, vol. 7, no. 4, pp. 9818–9825. DOI: 10.1109/LRA.2022.3190093. EDN XKKPYQ.
7. Ibraev A. S. Sistema navigacii transportnogo sredstva na osnove integrirovannoj INS/SNS/odometrii [Vehicle Navigation System Based on Integrated INS/GNSS/

- Odometry], *Tekhnicheskie nauki — ot teorii k praktike [Technical Sciences — from Theory to Practice]*, 2017, no. 5 (65), pp. 31–43. EDN YPZWCV (In Russian)
8. Marinoni M., et al. A Novel Approach for Reducing Train Localization Errors by Inertial Measurements, *IEEE Access*, 2023, vol. 11, pp. 5281–5295. DOI: 10.1109/ACCESS.2023.3236784. EDN JHEMLF.
  9. Chikrin D. E., et al. Razrabotka vysokotochnoj sputnikovoj lokal'no inercial'noj sistemy navigacii dlja bespilotnogo upravlenija transportnymi sredstvami [Development of a High Precision Satellite Local Inertial Navigation System for Unmanned Vehicle Control], *Izvestija vysshih uchebnyh zavedenij. Priborostroenie [Proceedings of Higher Educational Institutions. Instrumentation]*, 2020, vol. 63, no. 12, pp. 1094–1102. DOI: 10.17586/0021-3454-2020-63-12-1094-1102. EDN VJVIKN (In Russian)
  10. Baranov L. A., et al. Optimizacija upravlenija dvizheniem poezdov: uchebnoe posobie dlja studentov special'nostej "Upravlenie i informatika v tehnikeskikh sistemah" i "Elektricheskaja tjaga" [Train Movement Control Optimization: Textbook for Students of "Control and Informatics in Technical Systems" and "Electric Traction"], ed. by L. A. Baranov, Moscow: Moscow State University of Railway Engineering, 2011, 163 p. ISBN 978-5-7876-0151-0. EDN QNYRIV (In Russian)
  11. Stepanov O. A. Primenenie teorii nelinejnoj filtracii v zadachah obrabotki navigacionnoj informacii [Application of Nonlinear Filtering Theory in Navigation Data Processing], 3rd ed., Saint Petersburg: Central Research Institute "Elektropribor", 2003, 370 p. ISBN 5-900780-45-7. EDN RJFCUL (In Russian)
  12. Wang Ju, Chen X., Shi Ch. A Novel Robust Iterated CKF for GNSS/SINS Integrated Navigation Applications, *EURASIP Journal on Advances in Signal Processing*, 2023, vol. 2023, no. 1, p. 83. DOI: 10.1186/s13634-023-01044-9. EDN EFMBJD.
  13. Vouch O., et al. On the Adaptivity of Unscented Particle Filter for GNSS/INS Tightly Integrated Navigation Unit in Urban Environment, *IEEE Access*, 2021, vol. 9, pp. 144157–144170. DOI: 10.1109/ACCESS.2021.3122006. EDN OMLNBZ.
  14. Chen L., Hu H., McDonald-Maier K. EKF Based Mobile Robot Localization, Third International Conference on Emerging Security Technologies, IEEE, 2012, p. 6.
  15. Al B., Gavrilov A. I. Tehnologii intellektual'nyh vychislenij v zadachah povyshenija tochnosti integrirrovannyh navigacionnyh sistem [Intelligent Computing Technologies in Improving the Accuracy of Integrated Navigation Systems], *Vestnik Moskovskogo gosudarstvennogo tehnikeskogo universiteta im. N. E. Baumana. Serija "Priborostroenie" [Bulletin of the Bauman Moscow State Technical University. Series Instrumentation]*, 2019, no. 1 (124), pp. 62–89. DOI: 10.18698/0236-3933-2019-1-62-89. EDN VVIBSE (In Russian)
  16. Revach G., et al. KalmanNet: Neural Network Aided Kalman Filtering for Partially Known Dynamics, *IEEE Transactions on Signal Processing*, 2022, vol. 70, pp. 1532–1547. DOI: 10.1109/TSP.2022.3158588. EDN LLILH.
  17. Al Bitar N., Gavrilov A. A Novel Approach for Aiding Unscented Kalman Filter for Bridging GNSS Outages in Integrated Navigation Systems, *Navigation, Journal of the Institute of Navigation*, 2021, vol. 68, no. 3, pp. 521–539. DOI: 10.1002/navi.435. EDN NDUTQG.
  18. Liu Z., et al. Tegmark M. KAN 2.0: Kolmogorov — Arnold Networks Meet Science, 2024. DOI: 10.48550/arXiv.2408.10205.
  19. Livieris I. E. C-KAN: A New Approach for Integrating Convolutional Layers with Kolmogorov — Arnold Networks for Time Series Forecasting, *Mathematics*, 2024, vol. 12, no. 19, p. 3022. DOI: 10.3390/math12193022. EDN TGGSAI.
  20. Carvalho J. P. M., et al. Hybrid Kalman Filter — Kolmogorov — Arnold Network Using Local Interpretable Model Agnostic Explanations for Photovoltaic Power Forecasting, *SN Computer Science*, 2026, vol. 7, no. 4, p. 319. DOI: 10.1007/s42979-026-04823-x. EDN ZAVNSI.
  21. ETH PBL. Railway Precise Localization: Raw Dataset Combining Precise GNSS and IMU Information in a Live Railway Application. URL: <https://github.com/ETH-PBL/Railway-Precise-Localization> (accessed: August 03, 2026).