

# ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ КАЛИБРОВКИ МЭМС-АКСЕЛЕРОМЕТРОВ В МИКРОКОНТРОЛЛЕРНЫХ ИНЕРЦИАЛЬНЫХ СИСТЕМАХ

Кузнецов К. С.

Высшая школа компьютерных технологий и информационных систем

Санкт-Петербургский политехнический университет Петра Великого

Санкт-Петербург, Россия

E-mail: kuznetsov.ks@edu.spbstu.ru

*В работе рассматривается проблема калибровки МЭМС-акселерометров, применяемых в микроконтроллерных навигационных системах. Показано, что традиционные методы компенсации ошибок (устранение смещения нуля и погрешности масштаба) имеют ограниченную эффективность. Предложено использование методов машинного обучения, позволяющих адаптивно снижать систематические и случайные ошибки измерений. Для иллюстрации подхода приведено моделирование сигнала акселерометра с добавлением шума и смещения, а также его коррекция с применением линейной регрессии. Полученные результаты демонстрируют снижение среднеквадратической ошибки и подтверждают перспективность использования машинного обучения для повышения точности инерциальных навигационных систем.*

## ВВЕДЕНИЕ

Микроэлектромеханические датчики (МЭМС) занимают ключевое место в современных навигационных и управляющих системах благодаря низкой стоимости, компактности и возможности интеграции с микроконтроллерами [1]. Однако точность МЭМС-акселерометров ограничивается рядом факторов: смещением нуля, температурным дрейфом, шумами и перекрёстными погрешностями. Классические методы калибровки, такие как шестипозиционный тест и использование фильтра Калмана, позволяют частично компенсировать данные ошибки, но имеют ограничения при учёте нелинейных и нестабильных составляющих. В связи с этим актуальной задачей является применение методов машинного обучения (ML) для калибровки и коррекции выходных данных МЭМС-акселерометров в составе микроконтроллерных инерциальных навигационных систем (INS).

## I. Ошибки МЭМС-АКСЕЛЕРОМЕТРОВ

К типовым источникам погрешностей акселерометров относят [2]:

- смещение нуля (bias), изменяющееся со временем и температурой;
- масштабный коэффициент (scale factor), зависящий от условий эксплуатации;
- перекрёстные чувствительности (misalignment);
- случайные шумы.

На рисунке 1 представлена упрощённая схема формирования ошибок МЭМС-акселерометра.



Рис. 1 – Схема формирования ошибок МЭМС-акселерометра

## II. МЕТОДЫ КАЛИБРОВКИ

Классические подходы включают [3]:

- статическую калибровку в нескольких фиксированных положениях (шестипозиционный тест);
- динамическую калибровку с использованием эталонных траекторий;
- применение фильтра Калмана для совместной оценки параметров модели и состояния системы.

Ограничением указанных методов является их недостаточная эффективность при наличии нелинейных и изменяющихся ошибок.

Таблица 1 – Сравнение методов калибровки

Метод	Учет нелинейностей	Вычислительные ресурсы	Точность
Шестипозиционный тест	низкий	низкие	средняя
Фильтр Калмана	частичный	средние	выше
Машинное обучение	высокий	зависит от модели (TinyML – низкие)	высокая

## III. ПРИМЕНЕНИЕ И МОДЕЛИРОВАНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

Методы машинного обучения позволяют моделировать сложные зависимости между «сырыми» данными акселерометра и истинными значениями ускорений. Перспективными являются следующие направления:

- использование регрессионных моделей и нейросетей для предсказания смещения и масштабных коэффициентов [4];
- гибридные подходы (ML-корректор + фильтр Калмана) [5];

- внедрение технологий TinyML, позволяющих выполнять коррекцию непосредственно на микроконтроллере с ограниченными ресурсами [6].

Общий алгоритм применения ML можно описать следующим образом:

1. Сбор данных с акселерометра в различных условиях (температура, ориентация).
2. Обучение ML-модели на эталонных данных.
3. Интеграция обученной модели в прошивку микроконтроллера.
4. Использование модели для коррекции измерений в реальном времени.

Сигнал идеального акселерометра можно описать выражением

$$a_{true}(t) = A \cdot \sin(\omega t). \quad (1)$$

С учётом смещения и шумов измеренный сигнал имеет вид

$$a_{measured}(t) = (1 + \epsilon) \cdot a_{true}(t) + b + n(t), \quad (2)$$

где  $\epsilon$  – ошибка масштаба,  $b$  – смещение нуля,  $n(t)$  – гауссовский шум.

Калибровка выполняется методом линейной регрессии:

$$a_{calibrated}(t) = \alpha \cdot a_{measured}(t) + \beta, \quad (3)$$

где коэффициенты  $\alpha$ ,  $\beta$  подбираются методом наименьших квадратов.

Качество восстановления оценивается по среднеквадратической ошибке:

$$MSE = \frac{1}{N} \sum_{i=1}^N (a_{true}(t_i) - a_{signal}(t_i))^2. \quad (4)$$

Используя соотношения (1)–(4), был проведён модельный эксперимент, в ходе которого сгенерирован сигнал идеального акселерометра  $a_{true}(t)$  и искажённый сигнал  $a_{measured}(t)$  с добавлением смещения и шумов. Для коррекции измерений применялся метод линейной регрессии (3), позволяющий подобрать коэффициенты  $\alpha$  и  $\beta$  таким образом, чтобы минимизировать среднеквадратическую ошибку (4).

Результаты эксперимента показали, что применение регрессионной модели позволяет эффективно компенсировать систематические погрешности и уменьшить уровень шума. На рисунке 2 приведено сравнение исходного и откалиброванного сигналов, из которого видно, что восстановленный сигнал значительно ближе к истинным значениям ускорений.

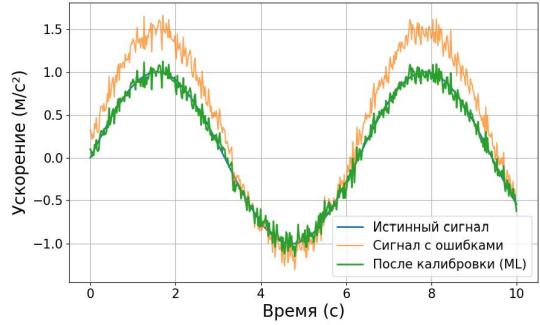


Рис. 2 – Сравнение измеренного и откалиброванного сигналов акселерометра

В модельном эксперименте использовались параметры:  $N = 500$ ,  $b = 0.2 \text{ м}/\text{с}^2$ , scale factor  $\epsilon = 1.3$ ,  $n(t) \sim \mathcal{N}(0, (0.1 \text{ м}/\text{с}^2)^2)$ . После калибровки методом линейной регрессии ( $\alpha = 0.7613$ ,  $\beta = -0.1509$ ) среднеквадратическая ошибка снизилась более чем на 95%, а восстановленный сигнал практически совпал с истинным, что подтверждает эффективность ML-подхода.

#### IV. ЗАКЛЮЧЕНИЕ

Применение методов машинного обучения для калибровки МЭМС-акселерометров в составе микроконтроллерных INS является перспективным направлением, позволяющим повысить точность навигационных решений. В отличие от классических методов, ML-подходы способны учитывать нелинейные и изменяющиеся погрешности. Развитие технологий TinyML делает возможной реализацию подобных алгоритмов даже на маломощных микроконтроллерах. Перспективными задачами являются исследование оптимальных архитектур нейросетей, адаптивная калибровка в реальном времени и интеграция ML-методов в комбинированные INS.

#### V. СПИСОК ЛИТЕРАТУРЫ

1. Mammadov,A. Z. The model of inertial navigation system on base of MEMS sensors for unmanned aerial vehicles / A. Z. Mammadov // Кронос. – 2019. – № 10 (37).
2. Аксенов,В. В. Инструментальные средства для экспериментального построения модели погрешностей МЭМС акселерометра / В. В. Аксенов // ИВД. – 2020. – № 11 (71).
3. Белоус,А. И. МЭМС: конструкции, технологии, приложения / А. И. Белоус, С. А. Чижик. – М.: ТЕХНОСФЕРА, 2024. – 620 с. – ISBN 978-5-94836-688-3.
4. Оксенчук,Т. А. Алгоритмы машинного обучения для регрессионного анализа и прогнозирования числовых данных / Т. А. Оксенчук // Вестник науки. – 2025. – № 6 (87).
5. Тихонова, А. И. Применение методов машинного обучения для анализа вектора состояний РТК / А. И. Тихонова, Г. А. Мамедов, Д. А. Косневич, В. С. Радабольский, М. А. Гисмельбари // XXVII Международная конференция по мягким вычислениям и измерениям (SCM'2024), 22–24 мая 2024, Санкт-Петербург, СПбГЭТУ «ЛЭТИ».
6. TinyML – машинное обучение на микроконтроллерах // Хабр, 2024. – Режим доступа: <https://habr.com/ru/companies/first/articles/665932/>.