

УДК 681.518

URL: <https://ptsj.bmstu.ru/catalog/iemim/imm/1124.html>

СОВРЕМЕННЫЕ АЛГОРИТМЫ ПОСТРОЕНИЯ ПРОГНОЗИРУЮЩИХ МОДЕЛЕЙ ДЛЯ ИНЕРЦИАЛЬНЫХ НАВИГАЦИОННЫХ СИСТЕМ, СОДЕРЖАЩИХ МЭМС-ДАТЧИКИ

3.3. Набиева

nabzarina03@yandex.ru

МГТУ им. Н.Э. Баумана, Москва, Российская Федерация

Представлен обзор современных алгоритмов построения прогнозирующих моделей для инерциальных навигационных систем на основе микроэлектромеханических систем (МЭМС-ИНС). Показано, что переход от линейных и квазилинейных моделей к полностью нелинейным архитектурам позволяет существенно повысить точность аппроксимации и краткосрочного прогнозирования дрейфа, смещения и шумовых составляющих МЭМС-датчиков, в том числе в условиях сложных температурных и динамических режимов. Сформулированы перспективные направления исследований, включающие использование генеративных моделей для синтеза навигационных и ошибочных сигналов, развитие квантово-классических гибридных алгоритмов для оптимизации параметров сенсоров и внедрение адаптивных мультимасштабных архитектур, объединяющих физические, статистические и нейросетевые компоненты в единую прогнозирующую систему.

Ключевые слова: инерциальные навигационные системы, микроэлектромеханические системы, прогнозирующие модели, погрешность МЭМС-датчиков, коррекция, прогнозирование ошибок, машинное обучение, многослойные нейронные сети

Введение. Микроэлектромеханические системы (МЭМС) — миниатюрные устройства, объединяющие механические и электронные компоненты и изготавливаемые с применением технологий микроэлектроники и микромеханики. МЭМС-гироскопы и акселерометры стали основными компонентами инерциальных навигационных систем (ИНС) благодаря компактности, низкой стоимости и малому энергопотреблению. Однако МЭМС-датчики подвержены систематическим и случайным ошибкам, температурному дрейфу и деградации характеристик. Это приводит к накоплению ошибок на уровне 0,3...3,0 % от пройденного расстояния в минуту, что ограничивает использование таких систем в задачах, требующих высокой надежности [1, 2].

Традиционные методы компенсации ошибок основаны на вероятностно-статистическом моделировании и оценке состояния системы с помощью фильтра Калмана и его модификаций. Однако их эффективность существенно ограничивается априорными предположениями о линейности динамики и стационарности шумов. В реальных условиях эксплуатации МЭМС-датчики демонстрируют выраженную нелинейность и зависимость характеристик от режима работы, температуры и времени эксплуатации [3, 4].

С развитием вычислительных ресурсов и методов машинного обучения появились новые алгоритмы построения прогнозирующих моделей. В таких алгоритмах инерциальные погрешности моделируются по данным измерений. Это позволяет использовать как стационарные, так и сложные нестационарные и нелинейные компоненты ошибок.

Недостатки линейных стохастических моделей компенсации ошибок.

Классические методы моделирования, такие как анализ Аллана — Варианса и авторегрессионное моделирование, предполагают возможность декомпозиции ошибок на линейные компоненты. Такая аппроксимация оказывается недостаточной для описания поведения датчиков в реальных условиях эксплуатации [5].




Рис. 1. Результаты оценки фильтра Калмана зашумленного сигнала гироскопа (графики построены в системе MATLAB):

a — постоянный сигнал; *б* — измерения сигнала с шумом и оценка фильтра Калмана

Для применения фильтра Калмана и его модификаций, остающиеся наиболее распространенными алгоритмами для оценки состояния нелинейных систем (рис. 1), требуется точно задавать матрицы перехода и ковариаций шумов. Этап корректировки описывается следующими уравнениями:

$$\begin{aligned} K_k &= \mathbf{P}_k^- \mathbf{C}^T (\mathbf{C} \mathbf{P}_k^- \mathbf{C}^T + \mathbf{R}); \\ \hat{\mathbf{X}}_k &= \hat{\mathbf{X}}_k^- + K_k (\mathbf{Z}_k - \mathbf{C} \hat{\mathbf{X}}_k^-); \\ \mathbf{P}_k &= (\mathbf{I} - K_k \mathbf{C}) \mathbf{P}_k^-, \end{aligned}$$

где K_k — коэффициент усиления Калмана; $\mathbf{P}_k^-$ — предсказанная ковариационная матрица ошибки; $\mathbf{C}$ — выходная матрица системы; $\mathbf{R}$ — ковариацион-

ная матрица шума измерений; $\hat{X}_k$ — оценка состояния на текущей итерации; $\hat{X}_k^-$ — априорная (предсказанная) оценка состояния; Z_k — вектор измерений на текущей итерации; P_k — апостериорная ковариационная матрица ошибки; I — единичная матрица.

Несоответствие модельных представлений реальному поведению системы приводит к быстрой расходимости фильтра.

Алгоритмы машинного обучения для МЭМС-ИНС. Одними из первых методов машинного обучения, использованных к задачам моделирования и компенсации ошибок МЭМС, были многослойные перцептроны (Multilayer Perceptron, MLP) и метод опорных векторов (Support Vector Machine, SVM). Такие модели позволяют аппроксимировать нелинейные зависимости между вектором измерений и оценкой погрешности. В частности, модель на основе метода опорных векторов наименьших квадратов (Least Squares Support Vector Machine, LSSVM), оптимизированная с помощью хаотического алгоритма оптимизации роем частиц (Chaotic Particle Swarm Optimization, CPSO), показала значительное снижение дисперсии случайного дрейфа МЭМС-гироскопов более чем в 5 раз [6].

Статические алгоритмы машинного обучения обладают фундаментальным ограничением, заключающимся в отсутствие учета временных зависимостей. Поскольку ошибки МЭМС-имеют выраженную автокорреляционную структуру, ее исключение датчиков ведет к потере информации и ограничивает точность моделей. Такие модели слабо масштабируются к задачам с длительными временными рядами и сложными нелинейными зависимостями во времени, что привело к переходу к рекуррентным архитектурам.

Сети долгой краткосрочной памяти (Long Short-Term Memory, LSTM) представляют собой специализированный вид рекуррентных нейронных сетей, предназначенный для моделирования как краткосрочных, так и долгосрочных зависимостей во временных рядах. Применение LSTM-сетей к обработке сигналов МЭМС-ИНС позволило существенно повысить точность фильтрации и прогнозирования ошибок. В одной из типичных конфигураций входным сигналом сети служит многомерная временная последовательность показаний акселерометров и гироскопов, а выходом — оценка очищенного сигнала или вектора ошибок.

Экспериментальные результаты показали, что использование LSTM-архитектур позволило снизить стандартное отклонение выходных сигналов трехосного гироскопа на 60,3, 37,0 и 44,6 % по соответствующим осям относительно базовых методов и уменьшить ошибки определения ориентации соответственно на 47,6, 42,3 и 52,0 % по сравнению с традиционными фильтраци-

онными подходами [7]. LSTM-сети являются естественным развитием ранее применявшихся статических моделей, поскольку они эксплуатируют внутреннюю временную структуру шумов и дрейфа.

Гибридные алгоритмы, объединяющие классические методы цифровой обработки сигналов и нейросетевые аппроксиматоры, демонстрируют дополнительные преимущества. Одним из таких решений является гибридный алгоритм вейвлет-пороговой фильтрации и нейронной сети обратного распространения ошибки (Wavelet Threshold Back-Propagation Neural Network, WT-BPNN) [8]. В данном алгоритме используется массив из десяти МЭМС-гироскопов в конфигурации «вперед-назад» для улучшения выходной точности. При использовании такой схемы достигается значимое снижение параметров углового случайного блуждания и нестабильности нулевого смещения по сравнению с одиночными датчиками. Пространственно-статистическая избыточность массива позволяет усреднить несогласованные шумовые компоненты и повысить отношение сигнал/шум.

Гибридная фильтрация часто реализуется в форме каскадного алгоритма: на первом этапе реализуется предварительная фильтрация, далее следует нелинейное прогнозирование, после чего выполняется агрегирование данных массива и формирование итоговой оценки вектора ошибок или скорректированных измерений [9]. Такие решения особенно перспективны для приложений, в которых конструктивно возможна установка нескольких МЭМС-датчиков.

Физико-информированные нейронные сети (Physics-Informed Neural Networks, PINN) представляют собой класс моделей, в которых известные физические законы (дифференциальные уравнения движения, закон сохранения импульса и др.) явно включаются в функционал потерь L_{total} [10]:

$$L_{total} = \lambda_{data} L_{data} + \lambda_{init} L_{init} + \lambda_{phys} L_{phys},$$

где L_{data} — потери данных; L_{init} — потери начальных условий; L_{phys} — физические потери, λ_{data} , λ_{init} и λ_{phys} — параметры, управляющие относительной важностью каждого компонента функции потерь. Эти параметры настраиваются таким образом, чтобы обеспечить адекватное представление как эмпирических измерений, так и физических законов во время обучения нейронной сети.

Таким образом, сеть обучается не только по данным, но и по соблюдению физических ограничений.

Для использования PINN-подхода в инерциальной навигации предложены модели, в которых в качестве входных параметров сеть получает временные последовательности ускорений и угловых скоростей, а на выходе формирует оценки положения и ориентации, одновременно минимизируя несоответствие

кинематическим уравнениям движения. Такой подход позволяет существенно снизить потребность в размеченных данных высокой точности, повысить устойчивость к экстраполяции за пределы обучающего диапазона, обеспечить согласованность оценок по положениям, скоростям и ускорениям.

Экспериментальные результаты показывают, что PINN-подход обеспечивает до 85 % улучшения точности траекторной реконструкции по сравнению с альтернативными методами, основанными исключительно на данных, при испытаниях на реальных наборах данных (рис. 2).




Рис.2. Сравнение точности компенсации погрешностей алгоритмов относительно стохастических моделей

Для количественной оценки используется среднеквадратичная ошибка (Root Mean Square Error, RMSE). Точность компенсации погрешностей δ определяется как

$$\delta = \left(1 - \frac{RMSE}{RMSE_{true}} \right) \cdot 100 \%,$$

где $RMSE$ — среднеквадратичная ошибка после компенсации; $RMSE_{true}$ — среднеквадратичная ошибка исходного сигнала без обработки.

Архитектуры нового поколения. Развитие архитектур трансформеров, изначально предназначенных для обработки текстов, привело к появлению их модификаций для анализа временных рядов и пространственно-временных данных сенсоров. Ключевым элементом таких модификаций является механизм внимания, позволяющий модели адаптивно взвешивать вклад различных временных шагов в формирование текущей оценки. Приме-

нение модификации трансформера к задачам инерциальной навигации продемонстрировало значительное снижение ошибок оценки ориентации и положения до 13...38 % по сравнению с ошибками методов LSTM [11].

Современные работы демонстрируют возможность реализации калибровки МЭМС-сенсоров благодаря встраиванию параметров калибровки непосредственно в структуру навигационного фильтра и последующему обучению посредством обратного распространения ошибки, формируемой на основе эталонных измерений глобальной навигационной спутниковой системы (Global Navigation Satellite System, GNSS). В условиях доступности высококачественных спутниковых наблюдений формируется вектор ошибки положения и скорости, который далее используется как сигнал ошибки для обновления параметров калибровки датчиков. При потере сигнала GNSS система продолжает работать в инерциальном режиме, используя ранее адаптированные параметры, что обеспечивает более высокую точность по сравнению с традиционными схемами интеграции глобальной системы позиционирования (Global Positioning System, GPS) и инерциальной навигационной системы (Inertial Navigation System, INS), т. е. GPS/INS-схемами.

Современные тенденции и прикладные аспекты. Рост требований к автономности и задержке управления привел к активному внедрению алгоритмов прогнозирования и компенсации ошибок непосредственно на граничных устройствах, такие как автомобильные блоки, робототехнические контроллеры и носимые устройства.

С развитием киберфизических систем критически возрастает необходимость устойчивости МЭМС-датчиков к преднамеренным внешним воздействиям, включая акустические и вибрационные атаки. Система Gyro-Mag реализует подход, основанный на оценке выходных данных одного сенсора по измерениям другого и сравнении оцененных и реальных сигналов. Если отклонение превышает физически допустимый порог, система фиксирует атаку и переходит на оцененный сигнал, обеспечивая устойчивость функционирования. При этом достигается частота ложных срабатываний около 0,05 % и высокая устойчивость к длительным атакам до минуты при скромных вычислительных затратах.

Трансфертное обучение позволяет существенно сократить объем требуемых данных при адаптации прогнозирующих моделей к новым типам МЭМС-сенсоров или к новым режимам эксплуатации. Модель, предварительно обученная на одном классе датчиков, впоследствии дообучается на ограниченном наборе данных другого класса, сохраняя большую часть ранее сформированных представлений. Континуальное обучение рассматривается как перспективный механизм адаптации прогнозирующих моделей к медленной деграда-

ции характеристик сенсоров, обеспечивая актуальность калибровочных и прогнозирующих моделей на протяжении всего жизненного цикла устройства [12].

Перспективы развития. Генеративные модели обладают потенциалом для синтеза реалистичных наборов инерциальных и ошибочных данных, включая редкие и экстремальные сценарии, которые затруднительно воспроизвести в реальных испытаниях. Такие синтетические данные можно использовать для расширения обучающих выборок, моделирования предельных и отказных режимов работы, тестирования устойчивости навигационных алгоритмов в условиях «наихудшего случая».

Гибридные квантово-классические алгоритмы рассматриваются как перспективный инструмент для оптимизации параметров МЭМС-датчиков и структур прогнозирующих моделей. Квантовые компьютеры с их способностью параллельно исследовать экспоненциально большие пространства решений могут быть использованы для оптимизации физических параметров датчиков. Использование квантовых компьютеров совместно с классическими компьютерами позволяет более эффективно исследовать многомерные пространства параметров сенсоров и их конфигураций.

Одно из наиболее многообещающих направлений — континуальное обучение, когда прогнозирующая модель адаптируется к новым характеристикам датчика в процессе его использования. Это решает проблему деградации МЭМС-датчиков со временем, и характеристики ошибок изменяются. По мере внедрения МЭМС-навигации в критичные по безопасности приложения возникает спрос на интерпретируемые модели. Гибридные архитектуры, комбинирующие интерпретируемые физические компоненты с нейронными сетями, становятся все более важными.

Недостатки и ограничения. Несмотря на требовательность методов машинного обучения к объемам данных, получение размеченных наборов для МЭМС-датчиков сопряжено с фундаментальными трудностями. Эталонные траектории, выступающие в роли меток, требуют для своей генерации применения высокоточных и дорогостоящих датчиков, а также развертывания специализированной измерительной инфраструктуры, что обуславливает редкость и высокую стоимость. Прогнозирующие модели, обученные на данных конкретного типа МЭМС-датчиков, демонстрируют ограниченную способность к переносу на сенсоры других моделей или производителей.

Сложные модели глубокого обучения, такие как архитектуры-трансформеры и многослойные LSTM-сети, характеризуются высокой вычислительной стоимостью. Их развертывание на портативных устройствах с ограниченными энергетическими и вычислительными ресурсами требует применения ме-

тодов оптимизации. Однако применение этих методов зачастую приводят к инерциальной деградации прогнозной производительности модели

Эффективность PINN-архитектуры зависит от точности и полноты физических моделей. Применение упрощенных кинематических уравнений или пренебрежение ключевыми внешними факторами, такими как температурные дрейфы или вибрационные воздействия, может индуцировать систематические ошибки в прогнозе, нивелируя преимущества гибридного подхода.

Преимущества и недостатки методов сведены в таблицу.

Сравнение алгоритмов построения прогнозирующих моделей

Метод	Время обучения	Преимущества	Недостатки
LSSVM	Высокое	Применяется к нелинейным функциям	Не учитываются временные зависимости
LSTM	Среднее	Учитываются временных зависимостей	Чувствительность к параметрам. Требуется большой объем данных
WT-BPNN	Низкое	Высокая точность	Требуется массивы датчиков
PINN	Низкое	Физическая согласованность. Малые требования к данным	Зависимость от точности физической модели

Заключение. Современные алгоритмы построения прогнозирующих моделей для инерциальных навигационных систем на основе МЭМС характеризуются качественным переходом от жестко регламентированных линейных стохастических моделей к гибким, данных-ориентированным и физико-информированным архитектурам. Апробация таких подходов, как сети долгой краткосрочной памяти, гибридные вейвлет-нейросетевые схемы, физико-информированные нейронные сети и архитектуры трансформеров, демонстрирует значительное подавление различных компонентов погрешностей, а также существенное повышение робастности и обобщающей способности итоговых навигационных решений.

В качестве наиболее продуктивных направлений развития можно назвать конвергенцию гибридных подходов, интегрирующих априорные знания в виде физических моделей движения и сенсорных характеристик, аппарат статистической теории фильтрации и современные архитектуры глубокого обучения. Ключевой задачей при этом становится адаптация таких гибридных моделей к конкретным классовым и эксплуатационным особенностям МЭМС-датчиков.

К числу актуальных научно-технических вызовов ближайшей перспективы относятся:

- дефицит репрезентативных эталонных данных высокой точности, необходимых для обучения;
- разработка масштабируемых методов адаптации моделей к долговременной деградации характеристик сенсоров;
- обеспечение устойчивости к преднамеренным искажающим воздействиям;
- создание интерпретируемых и верифицируемых моделей, пригодных для сертификации в областях, критичных к безопасности.

Дальнейшее развитие области будет обусловлено интеграцией генеративных состязательных сетей и диффузионных моделей для синтеза тренировочных навигационных данных, развитием методологий континуального и федеративного обучения на граничных устройствах, а также внедрением гибридных квантово-классических оптимизационных процедур для ускорения тренировки сложных архитектур. Совокупное развитие указанных направлений формирует теоретико-методологический базис для создания нового поколения МЭМС-инерциальных систем, обладающих существенно улучшенными показателями точности, надежности и адаптивности в широком диапазоне эксплуатационных условий.

Литература

- [1] Нгуен Ч.И., Нгуен К.Х., Ха М.Т. Алгоритм калибровки микроэлектромеханических инерциальных датчиков. *Известия вузов России. Радиоэлектроника*, 2022, т. 25, № 4, с. 90–104. <https://doi.org/10.32603/1993-8985-2022-25-4-90-104>
- [2] Levin M., Klein I. Orientation-Free Neural Network-Based Bias Estimation for Low-Cost Stationary Accelerometers. *Arxiv:2511.13071*, 2025. <https://doi.org/10.48550/arXiv.2511.13071>
- [3] Шэнь Кай. Разработка методов оценивания и прогнозирования навигационных систем летательных аппаратов. *Автоматизация. Современные технологии*, 2015, № 7, с. 13–18.
- [4] Ru X., Gu N., Shang H., Zhang H. MEMS Inertial Sensor Calibration Technology: Current Status and Future Trends. *Micromachines*, 2022, vol. 13, no. 6, art. no. 879. <https://doi.org/10.3390/mi13060879>
- [5] Zhang X., Li Y., Mumford P., Rizos C. Allan Variance Analysis on Error Characteristics of MEMS Inertial Sensors for an FPGA-Based GPS/INS System. *Proceedings of the International Symposium on GPS/GNSS*. Tokyo, Japan, 2008, pp. 127–133.

- [6] Xing H., Hou B., Lin Z., Guo M. Modeling and Compensation of Random Drift of MEMS Gyroscopes Based on Least Squares Support Vector Machine Optimized by Chaotic Particle Swarm Optimization. *Sensors*, 2017, vol. 17, no. 10, art. no. 2335. <https://doi.org/10.3390/s17102335>
- [7] Jiang C., Chen S., Chen Y., Zhang B., Feng Z., Zhou H., Bo Y. A MEMS IMU De-Noising Method Using Long Short Term Memory Recurrent Neural Networks (LSTM-RNN). *Sensors*, 2018, vol. 18, no. 10, art. no. 3470. <https://doi.org/10.3390/s18103470>
- [8] Liang S., Guo T., Chen R., Li X. Hybrid Filtering Compensation Algorithm for Suppressing Random Errors in MEMS Arrays. *Micromachines*, 2024, vol. 15, no. 5, art. no. 558. <https://doi.org/10.3390/mi15050558>
- [9] Xiao C., Zhu Q., Hu H., Zhang X., Chen X., Song X. Using AKF-PSR to Compensate Random Drift Errors of Low-Cost MEMS Gyroscopes. *IEEE Sensors Journal*, 2019, vol. 19, no. 16, pp. 6802–6810. <https://doi.org/10.1109/JSEN.2019.2912400>
- [10] Alam M.M., Soares A., Rodrigues-Jr J.F., Spadon G. Physics-Informed Neural Networks for Vessel Trajectory Prediction: Learning Time-Discretized Kinematic Dynamics via Finite Differences. *Arxiv:2506.12029*, 2025. <https://doi.org/10.48550/arXiv.2506.12029>
- [11] Wu Y., Wang C., Yin L., Guo S., Qin Y. Accurate and Steady Inertial Pose Estimation through Sequence Structure Learning and Modulation. *Advances in Neural Information Processing Systems*, 2024, vol. 37, pp. 42468–42493. <https://doi.org/10.52202/079017-1345>
- [12] Abdallah M., Joung B.G., Lee W.J., Mousoulis C., Raghunathan N., Shakouri A., Sutherland J.W., Bagchi S. Anomaly Detection and Inter-Sensor Transfer Learning on Smart Manufacturing Datasets. *Sensors*, 2023, vol. 23, no. 1, art. no. 486. <https://doi.org/10.3390/s23010486>

Поступила в редакцию 06.02.2026

Набиева Зарина Зуфаровна — студентка кафедры «Технологии приборостроения», МГТУ им. Н.Э. Баумана, Москва, Российская Федерация.

Научный руководитель — Селезнева Мария Сергеевна, кандидат технических наук, доцент кафедры «Технологии приборостроения», МГТУ им. Н.Э. Баумана, Москва, Российская Федерация.

Ссылку на эту статью просим оформлять следующим образом:

Набиева З.З. Современные алгоритмы построения прогнозирующих моделей для инерциальных навигационных систем, содержащих МЭМС-датчики. *Политехнический молодежный журнал*, 2026, № 4(105). URL: <https://ptsj.bmstu.ru/catalog/iemim/imm/1124.html>

MODERN ALGORITHMS FOR CONSTRUCTING PREDICTIVE MODELS IN MEMS-BASED INERTIAL NAVIGATION SYSTEMS

Z.Z. Nabieva

nabzarina03@yandex.ru

Bauman Moscow State Technical University, Moscow, Russian Federation

This article presents a review of modern algorithms for constructing predictive models for inertial navigation systems (INS) using microelectromechanical-system (MEMS) sensors. It is shown that the transition from linear and quasilinear models to fully nonlinear architectures significantly enhances the accuracy of approximation and short-term prediction of drift, bias, and noise components in MEMS sensors, including operation under complex thermal and dynamic conditions. Promising research directions are outlined, including the use of generative models for the synthesis of navigation and error signals, the development of quantum-classical hybrid algorithms for sensor parameter optimization, and the implementation of adaptive multi-level architectures that integrate physical, statistical, and neural network components into a unified predictive system.

Keywords: inertial navigation systems, micro-electromechanical systems, predictive models, MEMS sensor error, error correction, error prediction, machine learning, multilayer neural networks

Received 06.02.2026

Nabieva Z.Z. — Student, Department of Instrument Production Techniques, Bauman Moscow State Technical University, Moscow, Russian Federation.

Scientific advisor — Selezneva M.S., Ph. D. (Eng.), Associate Professor, Department of Instrument Production Techniques, Bauman Moscow State Technical University, Moscow, Russian Federation.

Please cite this article in English as:

Nabieva Z.Z. Modern algorithms for constructing predictive models in MEMS-based inertial navigation systems. *Politekhnicheskii molodezhnyy zhurnal*, 2026, no. 4(105). (In Russ.). URL: <https://ptsj.bmstu.ru/catalog/iemim/imm/1124.html>