

Н. АЛЬ БИТАР, А. И. ГАВРИЛОВ, В. ХАЛАФ

МЕТОДЫ НА ОСНОВЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ ПОВЫШЕНИЯ ТОЧНОСТИ ИНТЕГРИРОВАННОЙ НАВИГАЦИОННОЙ СИСТЕМЫ ПРИ ОТСУТСТВИИ СИГНАЛА ГНСС. АНАЛИТИЧЕСКИЙ ОБЗОР

Ограничения при использовании фильтра Калмана (ФК) послужили стимулом для изучения альтернативных методов интеграции инерциальных навигационных систем (ИНС) с глобальными навигационными спутниковыми системами (ГНСС), в основе которых лежат технологии искусственного интеллекта (ИИ). За последние два десятилетия появилось большое количество исследований, обосновывающих возможности использования технологий ИИ в области интегрированных навигационных систем. Были предложены различные способы объединения модулей ИИ с другими частями системы ИНС/ГНСС. В статье представлена новая классификация этих схем, основанная на функциональных характеристиках модулей ИИ в системе ИНС/ГНСС. Дается также краткое пояснение к каждой схеме с описанием ее преимуществ и недостатков. Рассматриваются некоторые аспекты, которые необходимо учитывать в будущих исследованиях в этой области.

Ключевые слова: инерциальные навигационные системы, глобальные навигационные спутниковые системы, искусственный интеллект, нейронные сети, фильтр Калмана.

Введение

ГНСС успешно используются в течение последних трех десятилетий. В основе действия этих систем – измерение расстояний от нескольких спутников с известным

Аль Битар Надер. Аспирант кафедры «Системы автоматического управления», Московский Государственный Технический Университет (МГТУ) им. Баумана (Россия).

Гаврилов Александр Игоревич. Кандидат технических наук, доцент кафедры «Системы автоматического управления», МГТУ им. Н.Э. Баумана.

Халаф Вассим. Начальник лаборатории навигации, Институт прикладных наук и технологий (Дамаск, Сирия).

положением на орбитах. Предполагается, что не менее трех спутников ГНСС всегда видны из большинства точек на поверхности Земли, а для круглосуточного определения местоположения наблюдателя в любом месте на поверхности Земли используется не менее четырех спутников ГНСС [1]. Основная цель ГНСС заключается в формировании сигнала, по которому специальный приемник в режиме реального времени точно определяет свое местоположение и скорость в трех измерениях. Благодаря этому можно получить информацию о текущем местоположении и направлении движения транспортного средства. Помимо глобальной доступности, ГНСС являются портативными системами с низким энергопотреблением, которые подходят для интеграции датчиков и способны обеспечить точную и недорогую навигацию неограниченному числу пользователей в любой точке планеты [2]. С момента внедрения ГНСС круг прикладных задач, для решения которых применяются эти системы, резко расширился и обеспечивает отслеживание перемещения людей, колонн грузовых автомобилей, поездов, судов или самолетов и определение скорости их движения, а также навигацию с использованием мобильных телефонов, картографирование городских объектов и т.д. [3]. Одним из наиболее важных свойств ГНСС является то, что ее точность не ухудшается со временем; это означает, что погрешность позиционирования (и определения скорости) ограничена. Сигнал ГНСС может быть потерян полностью или частично при движении через туннели или вблизи строительных объектов. Сильное электромагнитное излучение также ухудшает качество сигнала ГНСС [2]. Кроме того, на него влияет состояние тропосферы (температура, давление, влажность) и ионосферы. Еще одним недостатком ГНСС является использование энергии радиоволн для получения навигационных параметров. Таким образом, эти системы подвержены воздействию искусственных помех и спуфингу [1]. Еще одним ограничением применения ГНСС является невысокая скорость передачи данных (например, при использовании коммерческих приемников). На сегодняшний день ни одна сложная наземная или воздушная система навигации, для которой критически важно непрерывно и с высокой скоростью определять местоположение (и скорости), не может работать, используя исключительно ГНСС.

Что касается ИНС, то эти системы способны обеспечить высокоскоростную выработку данных о местоположении, скорости и ориентации в автономном режиме. ИНС состоят из двух основных блоков – инерциального измерительного модуля (ИИМ) и бортового (навигационного) компьютера. ИИМ обычно содержат триады гироскопов и акселерометров, расположенных ортогонально друг к другу и измеряющих соответственно угловую скорость и линейное ускорение. Для получения требуемых навигационных параметров (местоположение, скорость и ориентация) сигналы от этих устройств обрабатываются путем интегрирования исходных инерциальных измерений ИИМ. Процесс интегрирования осуществляется с помощью набора кинематических уравнений в навигационном компьютере [4]. Как правило, ИИМ подразделяют на две основные категории в зависимости от того, как платформа с датчиками привязана к несущему объекту [5]. К первой категории относятся карданные системы, в которых платформа изолирована от вращательного движения несущего объекта карданным подвесом с электродвигателем. Этот тип системы используется, в частности, в областях, где требуются очень точные оценки навигационных данных, например на кораблях и подводных лодках. Вторая категория – это бесплатформенные ИНС (БИНС), которые с технической точки зрения менее сложны,

чем платформенные, за счет жесткой фиксации датчиков на корпусе носителя [1]. В результате БИНС отличаются от платформенных систем меньшими габаритами и более высокой надежностью, а также более низкой стоимостью. Благодаря этому компактные, легкие и точные БИНС теперь можно устанавливать в небольшие устройства, такие как мобильные телефоны. ИИМ по точности инерциальных датчиков подразделяются на навигационные, тактические и коммерческие. Несмотря на то что последние достижения в области ИНС и компьютерных технологий позволили уменьшить размеры и повысить точность и стабильность ИНС, высококачественные ИИМ пока не могут широко использоваться в коммерческих наземных и воздушных навигационных системах из-за высокой стоимости и законодательных ограничений.

Разработка микроэлектромеханических систем (МЭМС [6]) открыла большие перспективы развития ИИМ. Благодаря миниатюрным размерам и весу, низкому энергопотреблению и при этом высокой надежности МЭМС нашли широкое применение в автотранспортной промышленности и других отраслях.

ИНС не может работать в автономном режиме из-за погрешностей датчиков и нарастающих во времени погрешностей интегрирования. В частности, это справедливо для БИНС, на показания инерциальных датчиков которой воздействует полный диапазон изменений курса и ориентации, а также угловая скорость движения транспортного средства.

Погрешности инерциальных датчиков могут быть как детерминированными, так и случайными. Детерминированные погрешности можно определить с помощью калибровочных процедур и затем удалить из необработанных измерений. Для определения случайных погрешностей необходимо создавать стохастические модели, чтобы свести к минимуму их негативное влияние на точность навигационного решения. Из-за этого точность выходных данных ИНС сохраняется только в течение ограниченного времени, особенно в недорогих БИНС на основе МЭМС, где ухудшение параметров происходит гораздо быстрее, чем в ИНС других типов.

Чтобы устранить недостатки ИНС или ГНСС, связанные с их автономным функционированием, и в то же время использовать их преимущества, их часто объединяют в одну систему, которая получила название интегрированной навигационно-спутниковой системы (ИНС/ГНСС). Она позволяет получать точные навигационные решения, при этом по сравнению с ГНСС и ИНС по отдельности обеспечиваются лучшие характеристики. ГНСС характеризуются постоянной, долговременной точностью, и их можно использовать для обновления составляющих местоположения и скорости, вырабатываемых ИНС, что позволит решить проблему накопления погрешностей ИНС с течением времени. В свою очередь, ИНС обеспечивает точную оперативную информацию, которую можно использовать для решения таких проблем, связанных с ГНСС, как блокирование сигнала, проскальзывание цикла и тактовые смещения [7]. Существует четыре уровня интеграции ИНС/ГНСС [8]: несвязанные, слабо-, сильно- и глубокосвязанные системы, которые классифицируются по «глубине» взаимодействия и объему передаваемой информации между ними. В раздельной схеме и ИНС и ГНСС работают независимо друг от друга, при этом выходные данные ИНС периодически корректируются по измерениям ГНСС, однако обратная связь, необходимая для обновления измерительной модели инерциальных датчиков, отсутствует. В слабосвязанных системах данные ГНСС обрабатываются вместе с информацией от ИНС, чтобы в итоге получить выходные данные инте-

грированной системы. Сильносвязанные системы характеризуются более глубоким уровнем интеграции, поскольку необработанные измерения ГНСС непосредственно объединяются с данными ИНС в специальном фильтре. В случае глубокосвязанной интеграции обе не работают независимо друг от друга: измерения ГНСС используются для оценки погрешностей ИНС, а измерения ИНС являются вспомогательной информацией для контуров слежения приемника ГНСС. При таком глубоком уровне интеграции требуется доступ ко встроенному программному обеспечению приемника, что обычно делается либо на заводе-изготовителе, либо за счет использования программируемых приемников [8]. По этой причине наиболее распространены слабо- и сильносвязанные системы.

Для интеграции данных ИНС и ГНСС используются различные алгоритмы обработки, из которых наиболее популярны байесовские методы фильтрации, такие как фильтры Калмана (ФК), в том числе обобщенный фильтр Калмана (ОФК) [9] и ансентный фильтр Калмана (АФК) [10]. Если динамические и стохастические модели погрешностей ГНСС и ИНС сформированы корректно, фильтр Калмана способен обеспечить очень точное позиционирование при условии наличия непрерывных сигналов ГНСС. При пропадании сигналов ГНСС ФК работает в режиме прогнозирования и корректирует измерения ИНС на основании модели погрешностей системы. ФК характеризуется вычислительной эффективностью, что особенно полезно для решения задач в режиме реального времени. Вместе с тем фильтр имеет и свои ограничения. Основным недостатком, связанным с использованием ФК для интегрированной ИНС/ГНСС, является необходимость иметь точную стохастическую модель каждой составляющей погрешности датчика [11]. Если системы навигационного класса и высококачественные системы тактического класса имеют стохастические погрешности, которые вполне можно смоделировать надлежащим образом, то моделирование погрешностей для недорогих систем тактического класса и ИИМ на основе МЭМС вызывает серьезные затруднения. Кроме того, ФК имеет ряд других существенных недостатков, к которым в частности относятся зависимость от датчиков и проблемы с наблюдаемостью [12–13].

Ограничения ФК дали толчок исследованиям альтернативных методов интеграции ИНС/ГНСС преимущественно на базе ИИ [14], которому уделяется все больше внимания при разработке технологий будущего, особенно это касается развития современных компьютерных технологий в области программно-технических средств. Было доказано, что ИИ является успешным и эффективным инструментом при решении определенных научно-технических задач, для которых не подходят традиционные методы [14]. Цель технологий ИИ, к которым относятся искусственные нейронные сети [15], нейро-нечеткие системы [16], вычисления с помощью эволюционных алгоритмов [17], экспертные системы [18], генетические алгоритмы [19] и др., заключается в обеспечении значительного уровня интеллекта и робастности в сложных и неопределенных системах, подобных некоторым биологическим [20]. По сравнению с ФК алгоритмы ИИ обладают рядом преимуществ, которые представлены в табл. 1.

Применение методов ИИ в области интеграции ИНС/ГНСС стало предметом множества исследований. Ученые использовали различные подходы для объединения одного или нескольких модулей ИИ с остальной частью ИНС/ГНСС. Практически все конструктивные решения разделяются на две основные категории: 1) интеграция ИНС/ГНСС с использованием только ИИ, причем модуль ИИ замещает ФК; 2) ин-

теграция ИНС/ГНСС, при которой модуль ИИ комбинируется с ФК для повышения общей точности навигации. Каждая из этих двух категорий делится на подкатегории в соответствии с типами модулей ИИ или с входными/выходными данными модуля ИИ. В первом случае применяется раздельная схема интеграции ИНС и ГНСС, во втором – слабосвязанная.

Следует отметить, что сильно- и глубокосвязанные схемы интеграции используются в ряде областях, в которых нельзя обойтись без технологий ИИ, однако в данной работе рассматриваются только случаи раздельных (категория 1) и слабосвязанных (категория 2) схем интеграции. С сильно- и глубокосвязанными системами читатель может ознакомиться, например, в [21, 22].

Т а б л и ц а 1

Сравнение алгоритмов ИИ и ФК

Свойство	ФК	ИИ
Зависимость от модели	Математическая модель; детерминированная модель + стохастическая модель	Эмпирическая и адаптивная модель
Априорные знания	Необходимы (в основном измерения и ковариационные матрицы векторов состояний)	Не требуются, но необходимо предварительное обучение
Зависимость от датчиков	Для различных систем требуется перепроектирование или перенастройка параметров ФК	Алгоритм не зависит от системы
Линейность	Линейная обработка (ОФК)	Нелинейная обработка

Настоящая статья посвящена применениям технологий ИИ в области интегрированных навигационных систем для повышения точности при пропадании сигналов ГНСС. Основное внимание уделяется различным архитектурам систем 1 и 2 категорий с описанием преимуществ и недостатков каждой из них.

Остальная часть статьи организована следующим образом: в разделах II и III рассматриваются первая и вторая категории соответственно. В разделе IV приводится сравнительный анализ всех предлагаемых схем. Проблемы, связанные с применением ИИ в системах ИНС/ГНСС, анализируются в разделе V. В разделе VI подводятся итоги.

Интеграция ИНС/ГНСС с использованием ИИ

В данном случае модуль(и) ИИ применяется вместо ФК, при этом используются различные типы архитектур, а именно: архитектура коррекции местоположения (Position Update Architectures, PUA) [23], архитектура погрешности местоположения (Position-Position Error, или P- δ P) [24] и комбинированная архитектура P- δ P и V- δ V (Velocity-Velocity Error), или P- δ P + V- δ V [25].

А. Архитектура коррекции местоположения

Архитектура коррекции местоположения PUA впервые была предложена в [23]. Для комплексирования данных БИНС и ГНСС и воспроизведения динамической

модели движущегося транспортного средства, несущего обе системы, используется многослойная перцептронная нейронная сеть (Multilayer Perceptron Neural Network, MLPNN) [15] (далее будем именовать эту архитектуру PUA_MLP). Входные данные сети – скорость $V_{INS}(t)$ и азимут $\psi_{INS}(t)$, полученные от ИНС. Выходными данными сети являются два показателя: $\Delta E_{PUA}(t), \Delta N_{PUA}(t)$ – разницы координат между двумя различными последовательными периодами для северной и восточной составляющих координат, как показано на рис. 1, а. Пока доступен сигнал ГНСС, благодаря процессу обучения продолжает уменьшаться погрешность оценивания, что позволяет получить оптимальные значения весов нейронной сети, как показано на рис. 1, б. Когда сигнал ГНСС пропадает, MLPNN работает в режиме прогнозирования, чтобы получить оценки восточной и северной составляющих координат $\Delta E_{PUA}(t), \Delta N_{PUA}(t)$, как показано на рис. 1, с. Для обучения PUA_MLP используется метод обратного распространения [15]. Было показано, что схема PUA обеспечивает более высокую точность позиционирования, чем обычный метод интеграции с помощью ФК при пропадании сигнала ГНСС (когда сеть PUA и ФК работают в режиме прогнозирования). Вместе с тем возникали трудности с выбором наиболее подходящей внутренней структуры MLPNN (количество скрытых слоев и количество нейронов в каждом слое). Кроме того, период обучения MLPNN оказался достаточно длительным, что не подходит для работы в режиме реального времени.

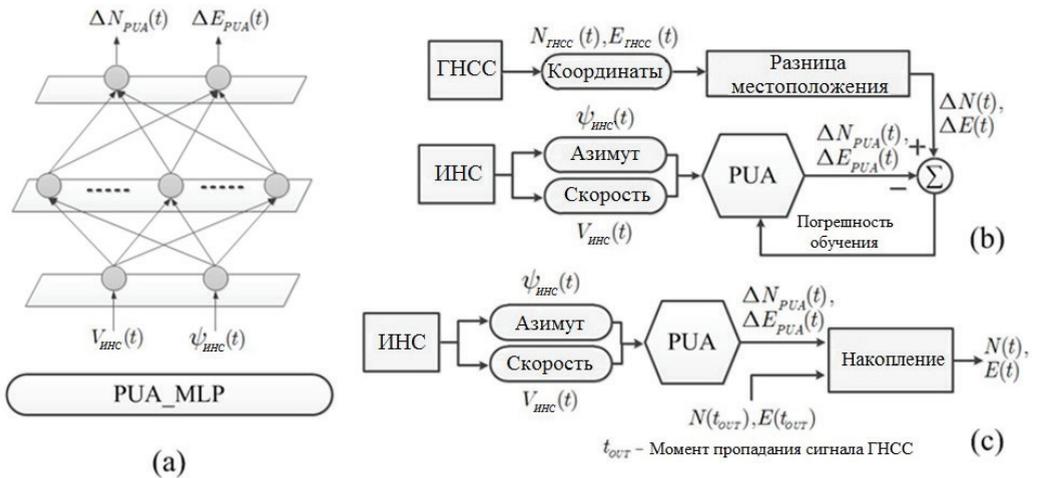


Рис. 1. Архитектура коррекции местоположения PUA с использованием MLPNN: а – топология MLPNN; б – режим обучения; с – режим прогнозирования

Для решения вышеупомянутых проблем в PUA_MLP [23] авторы работы [26] предложили заменить MLPNN в PUA сеть каскадной корреляции (Cascade-Correlation Network, CCN) [27]. Получившуюся архитектуру можно обозначить как PUA_CCN. Гибкость и непрерывное обучение, позволяющие осуществлять регуляцию весов и корректное изменение топологии, повышают эффективность CCN при интеграции ИНС/ГНСС по сравнению с сетями с фиксированной топологией, в том числе MLPNN. Создание интегрированных систем ИНС/ГНСС требует более гибкого подхода при отслеживании динамики движения транспортного средства и погрешности ИНС, особенно если при этом применяется недорогая система. Тех-

нология на основе CCN не требует априорных знаний или эмпирической проверки, чтобы реализовать предлагаемую архитектуру, поскольку способна построить свою архитектуру «на ходу», основываясь на изменениях динамики транспортного средства [26]. Результаты показали более высокую эффективность CCN по сравнению с MLPNN и ФК для интеграции ИНС/ГНСС. Предложенная схема на основе CCN продемонстрировала такие же характеристики, что схема на основе MLPNN, но с меньшим количеством скрытых нейронов.

В работе [28] авторы предложили заменить MLPNN в PUA алгоритмом типа «случайного леса» (Random Forest Regression, RFR) [29] – усовершенствованным методом классификации на основе решающих древовидных структур, получившим распространение благодаря своей надежности и гибкости при моделировании ввода–вывода функциональных соотношений [29]. Предложенная модель PUA_RFR обучалась при наличии сигналов ГНСС, затем использовалась для прогнозирования координат места во время потери сигнала. Показано, что модель PUA_RFR повышает точность автономной ИНС по сравнению с PUA_MLP. При этом модели PUA_CCN и PUA на основе RFR между собой не сравнивались.

Хотя все вышеупомянутые архитектуры PUA можно применить и для прогнозирования высоты, на которой будет находиться транспортное средство, их реализация была ограничена навигационными решениями в плоскости горизонта, подходящими для наземных транспортных средств, поскольку нет необходимости определять высоту их нахождения. Тем не менее это имеет большое значение для воздушных транспортных средств. Кроме того, архитектура PUA не способна оценить скорость и ориентацию объекта.

Б. Архитектура P- δP

Архитектура P- δP была впервые предложена в [24] при попытке разработать специальный модуль, который функционирует аналогично ФК, но не нуждается в динамических или стохастических моделях для ИНС. Интеграция ИНС/ГНСС на основе архитектуры P- δP базируется на оценке погрешности положения ИНС δP_{INS} путем обработки положения ИНС P_{INS} . Предлагаемая архитектура имеет два режима работы – коррекции и прогнозирования (рис. 2). Режим коррекции используется при доступности сигналов ГНСС для обновления внутренней структуры модуля ИИ, режим прогнозирования – для коррекции положения ИНС при потере сигнала ГНСС. Таким образом, при наличии сигнала ГНСС модуль P- δP обучается распознавать закономерности изменения погрешности координат, содержащейся во входных данных. В случае блокировки спутникового сигнала модуль P- δP имитирует последнее перемещение транспортного средства и обеспечивает прогноз погрешности его координат. Координаты ИНС P_{INS} и время являются входными сигналами для модуля, в то время как погрешность координат ИНС δP_{INS} является выходными параметрами модуля. Оценка погрешности координат ИНС δP_{INS} , обеспечиваемая модулем, затем сравнивается с разностью между исходными координатами ИНС и соответствующими координатами ГНСС $\delta P_{GNSS/INS}$, и результаты сравнения используются в качестве входных данных для алгоритма обучения и корректировки внутренней структуры модуля ИИ.

Три сети MLPNN применяются для моделирования трех составляющих погрешности координат в восточном, северном и вертикальном направлениях. Входной слой каждой сети имеет два входных нейрона для составляющих координат ИНС и времени, в то время как выходной слой имеет только один выходной нейрон для соответствующей погрешности координат ИНС. Сети MLPNN обучаются по алгоритму обратного распространения с правилом обучения Левенберга–Марквардта (LM) [30]. Результаты показали, что архитектура P-δP на основе MLPNN имеет преимущество перед ФК в точности позиционирования. Тем не менее в [24] не была приведена информация о том, учитывали ли при реализации ФК модели измерений инерциальных датчиков и ГНСС. Кроме того, следует отметить, что для проверки этого метода использовались измерения ИНС навигационного класса и не было представлено никакой информации о его эффективности при использовании тактических или недорогих ИНС на основе МЭМС. Сложность, связанная как с архитектурой MLPNN, так и с его алгоритмами онлайн-обучения, ограничивает возможности применения этого метода в режиме реального времени.

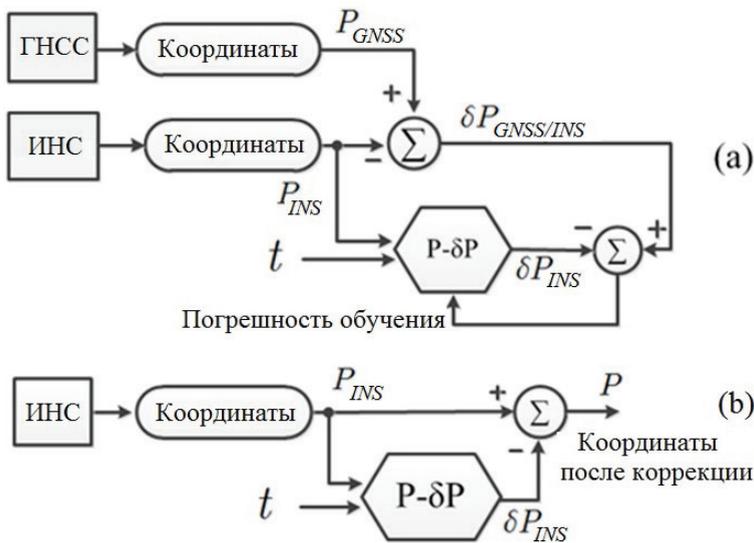


Рис. 2. Архитектура P-δP: a – режим обучения; b – режим прогнозирования

В [31] было предложено заменить MLPNN в архитектуре P-δP радиально-базисной функцией нейронной сети (РБФНС) [15]. В отличие от MLPNN, РБФНС имеет более простую архитектуру, состоящую только из трех слоев (входной, скрытый и выходной), и, следовательно, более простые и быстрые процедуры обучения. Полученные результаты продемонстрировали также превосходство предложенного метода над ФК в точности позиционирования.

Основным недостатком как архитектур P-δP на базе РБФНС, так и MLPNN является то, что обучение осуществляется с использованием всех данных ИНС и ГНСС, доступных до отключения ГНСС, что нецелесообразно и практически невозможно реализовать в режиме реального времени из-за длительности обучения.

Позднее те же авторы в работе [32] предложили процедуру обучения, основанную на методе скользящего окна. Для каждого из трех модулей РБФНС из обеих

систем был получен ряд выборок (называемых окном W) составляющих координат ИНС P_{INS} и соответствующих координат ГНСС P_{GNSS} . Модуль РБФНС устанавливается и обновляется в этом окне. Для задач в режиме реального времени модуль РБФНС обучается до того момента, пока не будет достигнута определенная минимальная среднеквадратическая погрешность или пока не завершится определенное количество периодов обучения (определяется эмпирически). Окно данных сдвигается в прямом направлении на 1 с (время опроса ГНСС) для получения новых данных как от ИНС, так и от ГНСС. Очень важно правильно выбрать размер окна, чтобы обеспечить желаемую точность одновременно с робастностью системы в режиме реального времени. Выбор наилучшего размера окна зависит от типа ИНС и продолжительности отключений ГНСС. По этой причине в действительности сложно подобрать оптимальный размер окна для работы в режиме реального времени.

Для эффективной борьбы с неопределенностью, неточностью и расплывчатостью входных данных в динамических средах авторы работы [33] предложили использовать нечеткие системы для создания нечеткого модуля для интеграции ИНС/ГНСС. В предлагаемом модуле используется адаптивная сеть на основе системы нечеткого вывода ANFIS [16] для оценки погрешностей ИНС δP_{INS} с использованием архитектуры Р- δ Р. Схематическое представление предлагаемого модуля ANFIS для синтеза данных представлено на рис. 3.

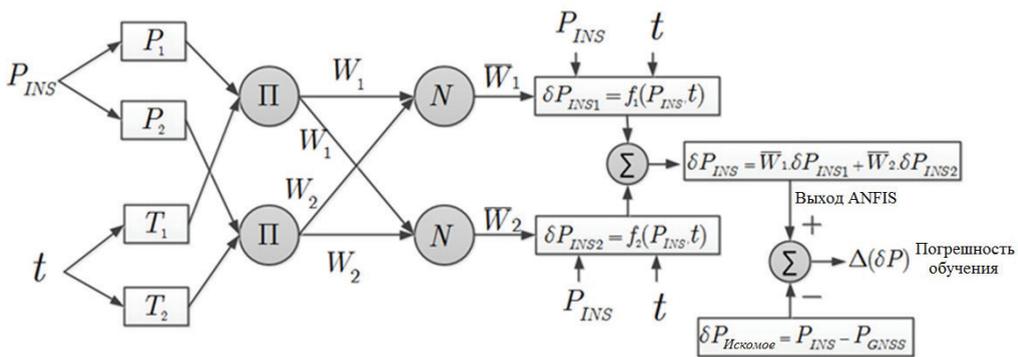


Рис. 3. Р- δ Р архитектура с ANFIS; P_1, P_2, T_1, T_2 – нечеткие множества; W_1, W_2 – веса, которые обозначают интенсивность нечеткого правила; Π – слой умножения для применения нечеткого оператора Т. Оператор нормы (минимум или произведение), N – фиксированный узловый слой для вычисления нормированных интенсивностей (\bar{W}_1, \bar{W}_2); $f_1(*), f_2(*)$ – нелинейные функции

Модель ANFIS делит входные данные на нечеткие подпространства P_1, P_2, T_1, T_2 и отображает выходные данные с помощью набора линейных функций. При наличии сигнала ГНСС система ANFIS обучается наносить на карту погрешности между определением координат по данным ИНС и ГНСС. Нечеткая система используется для предсказания составляющих координат ИНС при отключении ГНСС. Число и форма функций принадлежности были определены предварительно, а их исходный разброс и перекрытие – с помощью алгоритма нечеткой кластеризации [34]. Результаты показали, что модуль ANFIS может обеспечить достаточный уровень точности при краткосрочных отключениях ГНСС. Вместе с тем эта система показала низкую эффективность при длительных отключениях ГНСС. Характеристики также ухудшались при значительной динамике транспортного средства, существенно отличавшейся от

той, что наблюдалась в процессе обучения системы. Некоторые ограничения, связанные с оптимизацией параметров ANFIS (например, количество функций принадлежности) во время работы системы, создавали огромную вычислительную нагрузку при реализации в режиме реального времени.

В работе [35] было предложено оптимизировать архитектуру P-δP на основе ANFIS путем реализации временного метода перекрестной проверки на достоверность работы с окнами в процессе обновления параметров ANFIS. Этот метод предполагал использование неперекрывающегося движущегося окна вместо скользящего, описанного в [32]. Неперекрывающееся движущееся окно не обладает избыточностью информации, характерной для сигналов ИНС при использовании скользящего окна, и, таким образом, не требует длительного времени для обработки данных по сравнению со скользящим окном. Перекрестная проверка – это метод дробления данных, который позволяет итеративно разбивать выборки на два набора данных. Первый набор может использоваться в обучении, а второй – для тестирования модели. Процесс обучения предлагаемой системы на основе ANFIS схематично представлен на рис. 4. Результаты вычислений указывают на то, что предложенный в [35] модуль ANFIS, в отличие от построенных на ИИ предыдущих модулей обработки данных, имеет весьма низкие погрешности определения координат ИНС при относительно длительных отключениях ГНСС. Тем не менее точность системы сильно зависит от размера используемого временного окна. Этот метод показал весьма ограниченные результаты применительно к навигационной системе ИНС/ГНСС на МЭМС из-за высокого уровня шума и нестабильности смещения нуля инерциальных датчиков МЭМС. Показано, что при выборе размера окна необходимо учитывать ряд факторов. Большие размеры окон гарантируют, что система имитирует большую динамику движения. Это обеспечивает более высокую точность при длительных отключениях ГНСС. Вместе с тем небольшой размер окна может гарантировать соответствующее обновление модуля ANFIS.

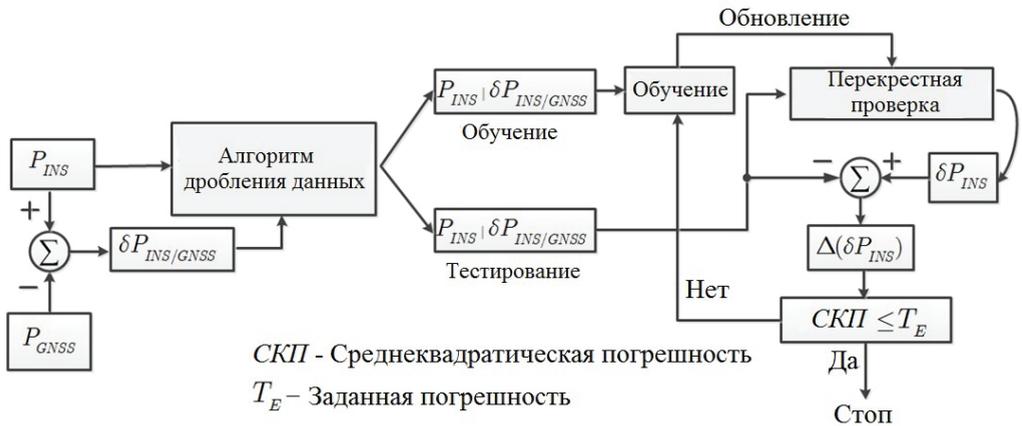


Рис. 4. Обучение сети ANFIS с использованием перекрестной проверки в архитектуре P-δP на основе ANFIS

Основным недостатком архитектуры P-δP является невозможность оценки погрешностей определения скорости и ориентации при отключении сигнала ГНСС. Помимо этого, трудоемкий процесс обучения ИС затрудняет его применение в ре-

жиме реального времени. Другая проблема, связанная с архитектурой P-δP, заключается в том, что по сравнению с ФК погрешности трех координат обрабатываются независимо, тогда как эти погрешности имеют взаимную корреляцию, особенно при использовании БИНС.

В. Комбинированная архитектура P-δP и V-δV

Комбинированная архитектура P-δP и V-δV предложена в работе [25], где для обеспечения оценки погрешности скорости к модулю P-δP, описанному ранее в [35], добавлен модуль скорости V-δV. Система содержит два модуля ANFIS: первый обрабатывает скорость ИНС, обеспечивая оценку определения ее погрешности, в то время как второй обрабатывает координаты ИНС и выдает их погрешности. Эти два модуля, соответственно, обновляются с использованием скорости и положения ГНСС, как показано на рис. 5.

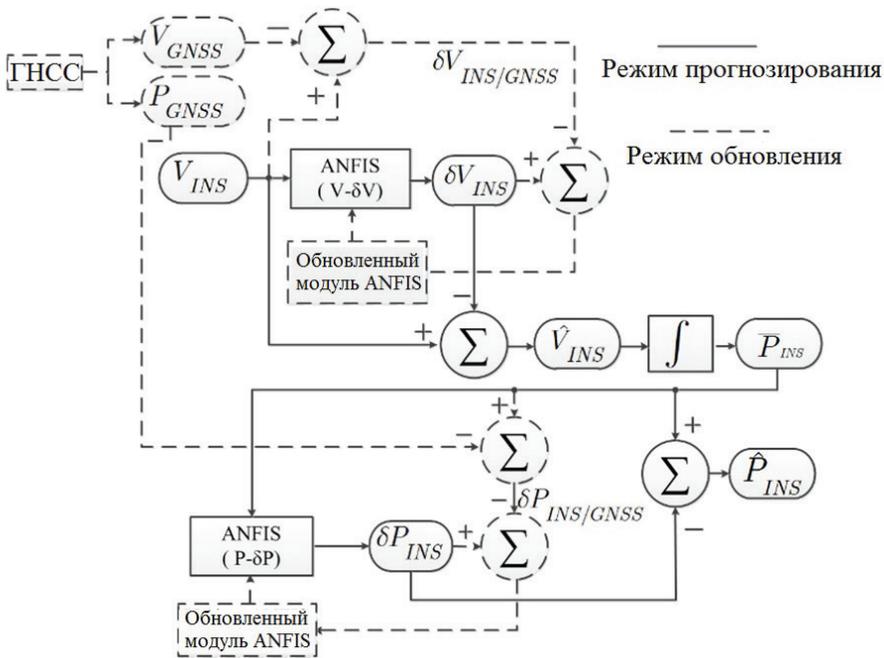


Рис. 5. Обновление данных о координатах и скорости на основе ANFIS для интеграции ИНС/ГНСС

Результаты показали, что предложенная архитектура на основе ANFIS (P-δP + V-δV) [25] по сравнению с предыдущими модулями обработки данных на основе ИИ имеет весьма низкие погрешности определения координат ИНС при относительно длительных отключениях ГНСС как для навигационных, так и для тактических классов ИНС.

В работе [36] оптимизирована ANFIS-ориентированная архитектура (p-Δ p + B-Δ в) с помощью генетического алгоритма (GA) [19]. Получившийся в результате модуль назван GANFIS [36]. Позднее в работе [37] было предложено использовать для оптимизации метод роя частиц (Particle Swarm Optimization, PSO) [38], по аналогии полученный модуль назван PANFIS. GANFIS показал несколько более высокую точность, чем основанный на алгоритме обратного распространения модуль ANFIS

(называемый BANFIS), в отношении погрешностей определения скорости и координат. Алгоритм GANFIS также обладает быстрой сходимостью и меньшей вычислительной сложностью по сравнению с BANFIS [36]. Алгоритм PANFIS обеспечивал чуть более высокую точность, чем GANFIS. Кроме того, время, необходимое для обучения, которое считается одним из наиболее важных факторов при работе в режиме реального времени, подтверждает превосходство PANFIS над GANFIS: оно значительно меньше [37].

Одним из недостатков комбинированной архитектуры $P-\delta P$ и $V-\delta V$ является невозможность оценки угловых погрешностей при пропадании сигнала ГНСС. Функционирование в режиме реального времени также является непростой задачей.

Архитектуры, основанные только на ИИ, имеют некоторые недостатки: они используют разделенную схему для интеграции ИНС и ГНСС без обратной связи, необходимой для обновления модели измерений инерциальных датчиков. Отсутствие обратной связи в этих архитектурах может не иметь существенного влияния при использовании ИНС высокого класса, поскольку модели измерений инерциальных датчиков хорошо описаны. Тем не менее это имеет крайне важное значение в случае недорогих МЭМС-ИНС, где эта модель недостаточно хорошо описана и резко меняется со временем.

Интеграция ИНС/ГНСС с использованием ИИ и ФК

Общее свойство архитектур с ИИ, упомянутых ранее (например, PUA, $P-\delta P$), заключается в том, что все они предназначены для использования вместо ФК. Фактически замена ФК модулем ИИ хорошо работала для ИНС навигационного класса. Тем не менее эти методы показали невысокую эффективность применительно к навигационным системам ИНС/ГНСС на МЭМС из-за высокого уровня шума и нестабильности смещения нуля инерциальных датчиков. В результате ФК сохраняется в качестве основного инструмента оценки состояния при интеграции ИНС/ГНСС, таким образом, логичным шагом стал метод интеграции, который использует как ФК, так и модуль ИИ в одной и той же системе, чему было посвящено большое количество исследований. Полученные архитектуры варьировались в зависимости от типа модуля ФК и ИИ и способа их объединения. При этом было обнаружено, что лучший способ понять принцип действия этих архитектур – разделить их в соответствии с функцией модуля ИИ внутри объединенной архитектуры ФК–ИИ. С учетом положения модуля ИИ внутри объединенной архитектуры ФК–ИИ их можно разделить на две основные подкатегории:

- 1) ФК, компенсированный искусственным интеллектом (AI Compensated KF, AICKF), где модуль ИИ используется для оценки и компенсации погрешностей состояний ФК во время отключений ГНСС;
- 2) ФК, дополненный искусственным интеллектом (AI Aided KF, AIAKF), где модуль ИИ используется для прогнозирования измерений (разница между выходами ИНС и ГНСС) для ФК во время отключений ГНСС.

В данной архитектуре ИНС и ГНСС интегрированы с помощью слабосвязанной схемы. Данные о координатах и скорости, полученные от ГНСС, используются для выработки оценок координат и скорости ИНС в ФК. Для дальнейшего повышения точности навигационного решения оценки погрешностей подаются обратно в урав-

нения ИНС, что уменьшает погрешности, влияющие на ИИМ. Для удобства восприятия обратная связь не будет показана на следующих схемах в режиме доступности сигнала ГНСС (режим обучения).

Как уже отмечалось, ФК остается основным компонентом интегрированной системы ИНС/ГНСС, в то время как модуль ИИ выполняет вспомогательную функцию. Далее дается подробное объяснение каждой подкатегории.

А. ФК, компенсированный ИИ в интегрированной системе ИНС/ГНСС

Идея компенсации погрешностей ФК появилась потому, что при отключениях ГНСС ФК обеспечивает более высокую точность по сравнению с ИНС только в том случае, если модели шума датчиков не являются точными. На самом деле неточные оценки состояния ФК возникают по многим причинам, в частности из-за неточного описания шумов системы, погрешности измерений и неопределенности в динамических моделях и неправильной настройки параметров ФК. В настоящее время шумы датчиков моделируются методом вариации Аллана [39]. Оценка вариации Аллана может быть оптимистичной по ряду причин, большинство из которых связано с тем, что статическая оценка производится в лаборатории, где на работу датчиков не влияют изменения температуры, динамика объекта и прогрев при запуске. По этой причине оценка вариации Аллана часто является отправной точкой для настройки методом последовательных приближений, после которой, тем не менее, используемые параметры часто близки к оптимальным, но не обязательно идеальны.

В литературе описано много концепций, связанных с использованием модулей ИИ для компенсации погрешностей ФК. Архитектуры варьировались в зависимости от типа модулей ИИ и конфигураций входов/выходов этих модулей. Первая архитектура, предполагающая применение модуля ИИ для компенсации погрешностей ФК в интегрированной системе ИНС/ГНСС, была предложена в работе [40]. Эта архитектура использует два ФК – навигационный и имитационный (рис. 6). Использование двух параллельных фильтров позволяет обеспечить итоговый результат. Имитационный фильтр при этом не пропускает сигналы ГНСС, тем самым имитируя ее сбой. Это позволяет системе обучаться шаг за шагом путем сравнения выходных данных о местоположении от двух фильтров, чтобы сформировать расчетные погрешности для обучения модуля ИИ. Когда сигнал ГНСС доступен, навигационный ФК генерирует эталонное решение, а имитационный ФК – прогнозное решение, поскольку работает только в режиме прогнозирования из-за моделируемых отключений ГНСС. Рассогласование, рассчитываемое путем вычитания эталонного решения из прогнозного, затем используется в качестве расчетного значения для обучения модуля ИИ (рис. 6, а). Три MLPNN были использованы для расчета трех составляющих местоположения. Входами северной и восточной сетей являются горизонтальные ускорения f_x^b, f_y^b , скорость изменения курса ω_z^b и время отсутствия сигналов ГНСС t . Входы вертикальной сети – это вертикальное ускорение f_z^b , крен и скорость крена и тангажа ω_x^b, ω_y^b . Сети обучаются с использованием алгоритма обратного распространения. Когда происходит реальное отключение ГНСС, в режиме прогнозирования работает только навигационный ФК, а модули ИИ прогнозируют погрешность определения координат. Чтобы правильно рассчитать координаты, спрогнозированная погрешность определения координат вычитается из их прогнозного значения (рис. 6, б).

Предложенная архитектура позволила в целом повысить точность во время отключений ГНСС на 60 с по сравнению со стандартным ФК, когда используются данные измерений МЭМС ИИМ и одного приемника ГНСС. Тем не менее результаты не продемонстрировали стабильные точность и улучшения по сравнению с ФК во время любых сбоях ГНСС [40]. Помимо этого, результаты были получены на относительно простой траектории с прямыми линиями и поворотами на 90°. Наконец, сложность архитектуры сетей MLP ограничивает возможности ее применения в режиме реального времени.

В работе [41] предложено использовать ANFIS вместо MLPNN для компенсации ошибок ФК. Вместо трех различных модулей используется ANFIS с 10 входами и 3 выходами, а вместо ГНСС – дифференциальная ГНСС, как в [40]. Входными данными сети ANFIS были: время, прошедшее с момента потери сигнала ГНСС, три линейных ускорения, три угловые скорости и три угла ориентации, а выходными – составляющие погрешности определения координат. Применение двух параллельных ФК позволяет ввести имитированные пропуски ГНСС в один фильтр (имитационный ФК), чтобы сформировать набор обучающих данных для сети ANFIS. Для обучения в режиме реального времени используется скользящее окно с алгоритмом обратного распространения. Предложенная система ANFIS–ФК оказалась лучше, чем ФК при отключениях сигнала ГНСС на 30 с. Тем не менее эти результаты также получены на траектории, состоявшей в основном из прямых участков с поворотами на 90° [41].

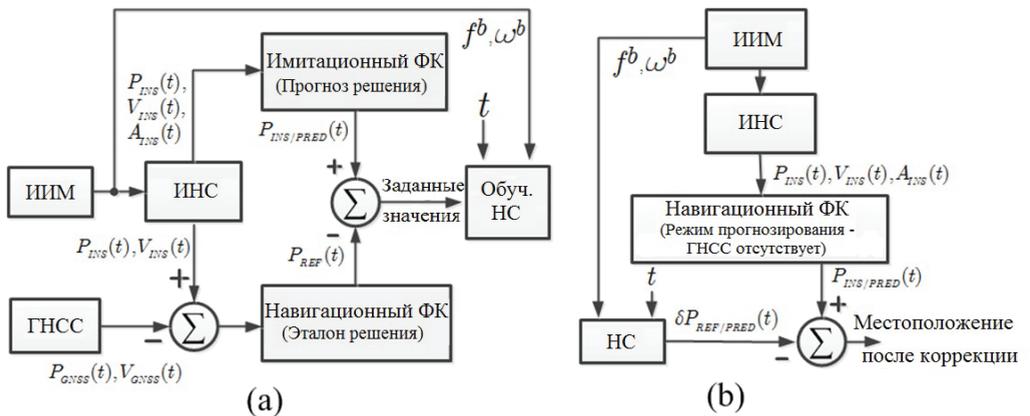


Рис. 6. Компенсация погрешностей ФК при отключениях сигнала ГНСС:
 а – режим обучения; б – режим прогнозирования

В [42] предложено использовать архитектуру P-δP на основе ANFIS, описанную ранее для моделирования погрешностей ФК. Три модуля ANFIS P-δP применялись с целью обеспечения полного навигационного решения для трех составляющих местоположения. Модули ANFIS были также оптимизированы путем реализации метода перекрестной проверки на основе временного окна во время обновления параметров ANFIS. Этот метод предполагал использование неперекрывающегося скользящего окна. Компенсация ФК модулями P-δP на базе ANFIS показала лучшие результаты по сравнению с ФК при отключениях сигнала ГНСС на 45 с [42]. При этом они были получены на действительно сложных траекториях [40–41]. Надо отметить, что хотя в данном случае использовались три модуля ANFIS (каждый из них имеет два входа и один выход), эта архитектура проще, чем описанная в [40], где

применяется один модуль ANFIS с десятью входами и тремя выходами, поэтому она более пригодная для использования в режиме реального времени.

В работе [43] предложен новый подход к компенсации погрешностей ФК, в основе которого лежит метод наименьших квадратов на основе опорных векторов LS-SVM [44] вместо традиционных нейронных сетей (MLPNN, РБФНС, ANFIS ...). Входные и выходные параметры LS-SVM выбираются на основе корреляций между динамическими изменениями и состояниями ФК. Установлено, что существует относительно высокая взаимозависимость между погрешностями скорости и ориентации и смещениями нуля горизонтального акселерометра и составляющими вектора ориентации и скорости. При этом речь идет только о наземных транспортных средствах, вертикальное перемещение которых можно проигнорировать, поэтому на входе модуля LS-SVM использовались изменения северной и восточной составляющих скорости (\ddot{V}_N, \ddot{V}_E) и угла курса $\ddot{\psi}$, а на выходе – погрешности определения скорости ФК ($\delta V_N, \delta V_E$) и ориентации δA . Предложенный алгоритм позволил повысить точность определения ориентации, скорости и координат по сравнению с ФК при отключениях ГНСС не только на 30 с, но и на 15 с. Это свидетельствует о том, что рассматриваемый алгоритм более эффективен при коротких отключениях. Кроме того, он оказался несколько точнее при определении ориентации, чем та же самая архитектура, но с использованием MLPNN вместо LS-SVM. Результаты были основаны на данных полевых испытаний ИИМ тактического класса. Характеристики предлагаемой архитектуры не проверялись по измерениям ИИМ на МЭМС.

Авторы работы [45] предложили новую модель, в основе которой – следящий фильтр Калмана (Strong Tracking Kalman filter, STKF) [46] и вейвлет-нейронная сеть (Wavelet Neural Network, WNN) [47]. Алгоритм STKF, предложенный ранее в работе [46], может быть использован для решения задачи оценки состояния нелинейных систем с белым шумом. По сравнению с обычным ФК он отличается следующими преимуществами:

- 1) хорошей устойчивостью к изменениям фактических параметров системы;
- 2) более низкой чувствительностью к шумам системы и измерений, а также к исходным данным о статистических свойствах системы [46].

Предложенную модель можно обозначить как $\delta P(P) - \delta P(C)$, где $\delta P(P)$ – погрешности ранее оцененного положения, а $\delta P(C)$ – погрешности текущего положения STKF (рис. 7, а). Функция WNN моделирует оцениваемые погрешности в виде временных рядов. WNN имеет ту же структуру, что и традиционные ANN. Она состоит из входного слоя, скрытого слоя (вейвлет-слоя) и линейного выходного слоя. Скрытый слой содержит нейроны с функциями вейвлет-активации. По сравнению с традиционной ANN WNN демонстрирует более высокую точность прогнозирования, скорость сходимости и отказоустойчивость для сложных нелинейных и неопределенных систем [45].

Модель STKF/WNN с 10-шаговой WNN обладает преимуществами по сравнению с ФК/РБФНС и STKF/РБФНС при той же самой конфигурации входных/выходных параметров. Как показали результаты экспериментов, точность позиционирования значительно улучшалась при отключениях ГНСС даже на 60 с [45]. Сравнение конфигурации $\delta P(P) - \delta P(C)$ с обычной конфигурацией $P - \delta P$ для той же модели STKF/WNN продемонстрировало ее большую эффективность при отключениях ГНСС на 40 с (хотя отключений было только два).

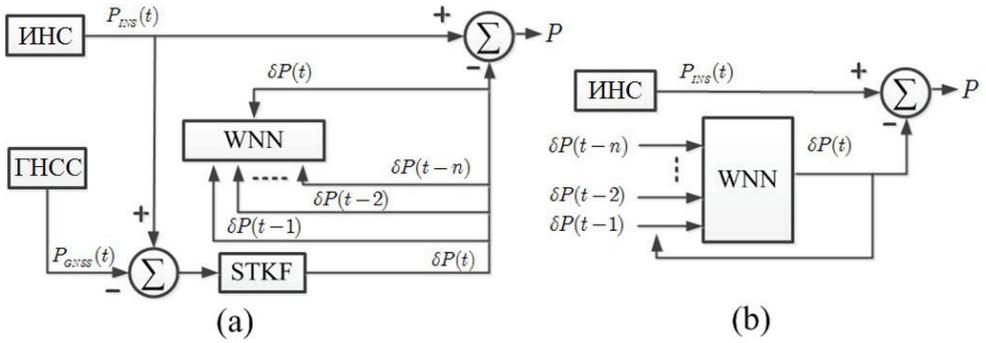


Рис. 7. Гибридная система WNN/STKF: а – режим обучения; б – режим прогнозирования

В работе [48] описывается недорогая распределенная слабосвязанная интегрированная ИНС/ГНСС на основе гибридного экстраполятора, объединяющая РБФНС и ФК (рис. 8). Когда сигналы ГНСС доступны, система обработки данных распределенного ФК работает нормально и обучаются 6 сетей РБФНС (с одним входом и одним выходом). Входные данные – три составляющие местоположения и скорости ИНС, соответственно, выходные данные – 6 сетей РБФ, представляющие собой обновленные составляющие от двух ФК (рис. 8, а). Когда сигналы ГНСС недоступны, 6 РБФНС функционируют в качестве экстраполяторов и вырабатывают прогнозные значения составляющих ориентации и скорости от ФК (рис.8, б). Было проведено сравнение предложенной распределенной системы с двумя другими, в которых используются только модули ИИ (без ФК), а именно предиктор на базе РБФНС и линейная сеть с временной задержкой (time delay linear network TDLN), или просто предиктор на базе TDLN. Предложенная система была протестирована с использованием МЭМС ИИМ и показала лучшие результаты, чем две другие системы [48].

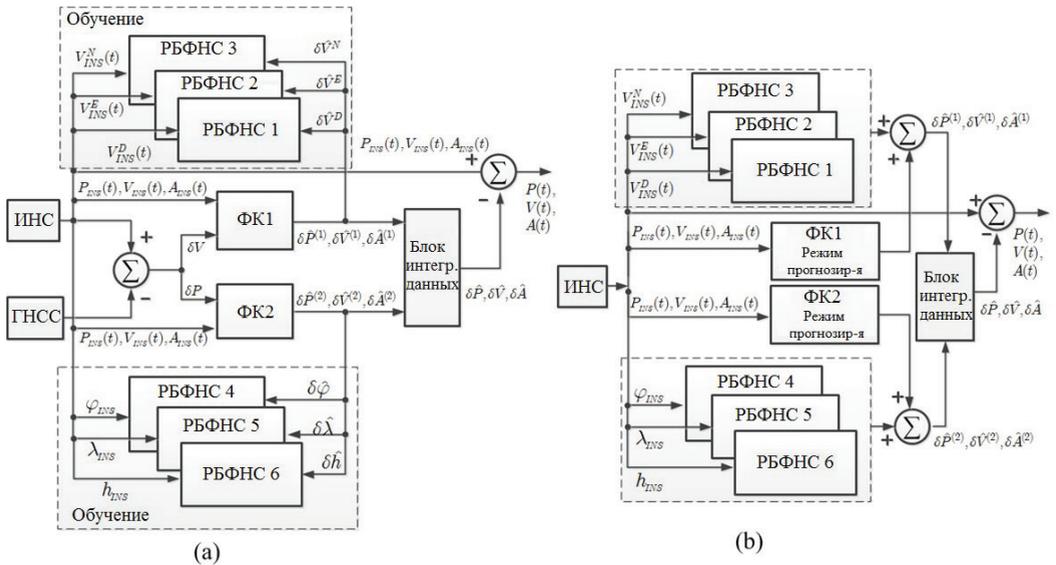


Рис. 8. Распределенная интегрированная навигационная система ИНС/ГНСС на гибридном предикторе: а – обучение; б – прогнозирование

Б. ФК, дополненный ИИ в интегрированной системе ИНС/ГНСС

Здесь интеграция ИНС и ГНСС осуществляется с помощью ФК, а также модуля ИИ, который используется, когда пропадает сигнал ГНСС. Основное различие между АIAKF и АICKF заключается в том, что в первом случае при отсутствии сигнала ГНСС фильтр Калмана продолжает работать как в режиме коррекции измерений, так и в режиме прогнозирования, а во втором – только в режиме прогнозирования.

В работе [49] предложена модель, в которой модуль ИИ дополняет ФК и используется для прогноза погрешности измерений в ФК при отключениях ГНСС. Предлагаемая система функционирует в двух режимах: режиме обучения, пока сигнал ГНСС доступен, и режиме прогнозирования, когда сигнал ГНСС отсутствует. На этапе обучения ФК вырабатывает навигационные решения и обновляет переменные состояния фильтров с помощью измерений ГНСС. В то же время измерение ФК $\delta P_{GNSS/INS}$ (погрешность позиционирования с учетом измерений ГНСС) отбирается как эталонный параметр для нейронной сети. В процессе обучения непрерывно сопоставляются выходные параметры нейронной сети с эталонными с одновременной корректировкой параметров в нейронной сети каждый раз, как обновляются измерения в ФК (см. рис. 9, а). При отключениях ГНСС выходной параметр нейронной сети $\delta \hat{P}_{GNSS/INS}$ (прогнозируемая погрешность позиционирования) используется в качестве измерения в ФК, чтобы сохранить его рабочее состояние таким же, как если бы сигнал ГНСС был доступен. Чтобы продемонстрировать полностью динамику движения транспортного средства, в качестве входных параметров нейронной сети выбираются углы ориентации, изменения скорости транспортного средства и углов ориентации ΔA в каждый период дискретизации (см. рис. 9, б).

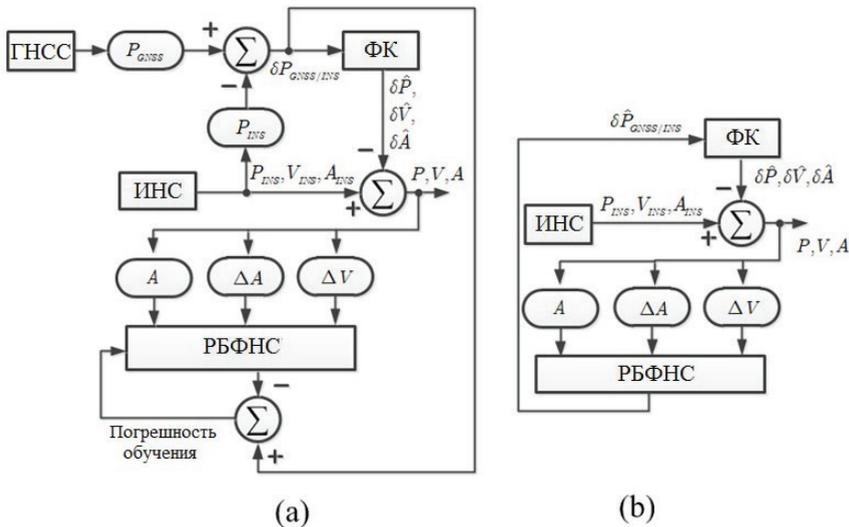


Рис. 9. Структура гибридной системы, использующей ФК, дополненной РБФНС: а – режим обучения; б – режим прогнозирования

Три отдельных РБФНС применяются для прогнозирования погрешностей позиционирования в трех ортогональных направлениях. Обучение РБФНС осуществля-

лось с помощью алгоритмов обратного распространения и сопряженного градиента, что предполагает использование технологии неперекрывающегося окна размерностью 60 с. Предложенная система показала лучшие результаты в сравнении с ФК при определении местоположения, скорости и ориентации во время отключений ГНСС на 60 с. В ходе натурных испытаний были задействованы ИИМ тактического класса и дифференциальная ГНСС [49]. Тем не менее при отключениях ГНСС в ФК были спрогнозированы только позиционные измерения, из чего следует, что ФК не полностью работоспособен, поскольку скоростные измерения не прогнозируются.

В работе [50] предложен гибридный метод прогнозирования, который позволяет устранить последствия отключений ГНСС за счет использования РБФНС и анализа временных рядов. Этот метод применялся в качестве дополняющего ФК, поскольку с его помощью прогнозировались ГНСС-коррекции. Структура системы гибридного экстраполятора при наличии сигнала ГНСС показана на рис. 10, а.

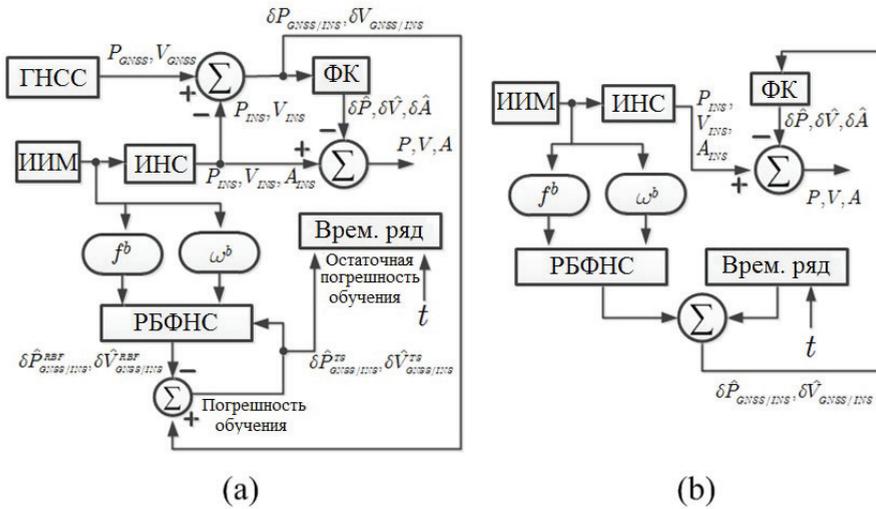


Рис. 10. Структура системы гибридного экстраполятора:
 а – при наличии сигналов ГНСС; б – при отключениях ГНСС

При наличии спутниковых сигналов ГНСС-измерения обеспечиваются путем вычитания данных о местоположении и скорости от ИНС и ГНСС. Таким образом, гибридная система прогнозирования работает в режиме обновления данных. В процессе обучения РБФНС полученная разность ($\delta P_{GNSS/INS}, \delta V_{GNSS/INS}$) рассматривается как эталонный параметр для нейронной сети, а выходные данные гироскопов и акселерометров (f^b, ω^b) – как входные. Пока сигналы ГНСС доступны, структура и параметры РБФНС непрерывно обновляются за счет эталонных параметров. Более того, прогноз по модели РБФНС ($\delta \hat{P}_{GNSS/INS}^{RBF}, \delta \hat{V}_{GNSS/INS}^{RBF}$), вычитаемый из разности эталонных данных ($\delta P_{GNSS/INS}, \delta V_{GNSS/INS}$), дает остаточную погрешность, которая в то же время моделируется на основе теории временных рядов. При возникновении сбоев ГНСС гибридная система прогнозирования переключается в режим прогнозирования. Как показано на рис. 10, б, РБФНС использует результаты измерений гироскопов и акселерометров в качестве входных данных для получения прогноза ($\delta \hat{P}_{GNSS/INS}^{RBF}, \delta \hat{V}_{GNSS/INS}^{RBF}$). Меж-

ду тем прогноз $(\delta\hat{P}_{GNSS/INS}^{TS}, \delta\hat{V}_{GNSS/INS}^{TS})$ формируется с помощью модели временно-го ряда. На основании этих двух результатов вырабатывается оптимальный прогноз $(\delta\hat{P}_{GNSS/INS}, \delta\hat{V}_{GNSS/INS})$, который используется для обновления результатов измерений в ФК при отключениях ГНСС. Предлагаемый метод продемонстрировал лучшие результаты по сравнению с методами на основе только ФК и РБФНС для всех периодов отсутствия сигналов ГНСС (от 50 до 600 с), однако они были получены в ходе экспериментов, где были задействованы лишь ИИМ навигационного класса. Никакой информации об экспериментах, проведенных с использованием устройств более низкого класса (например, МЭМС), предоставлено не было. Кроме того, сложность предлагаемой системы не позволяет применять ее в режиме реального времени.

В работе [51] предложен гибридный метод прогнозирования, который сочетает алгоритм экстремального обучения (extreme learning machine, ELM) [52] и ФК. ELM применяется для прогнозирования наблюдений ФК во время отключений ГНСС и представляет собой быстрый алгоритм обучения, предназначенный для однослойных нейронных сетей с прямой связью. По сравнению с РБФНС для ELM не нужно настраивать входные веса и скрытые смещения, что позволяет значительно сократить время. Это важно для решения прикладных задач в режиме реального времени. Как показали исследования, в некоторых случаях ELM не только значительно ускоряет процесс обучения, но и повышает общую производительность [52]. Гибридная система прогнозирования показана на рис. 11.

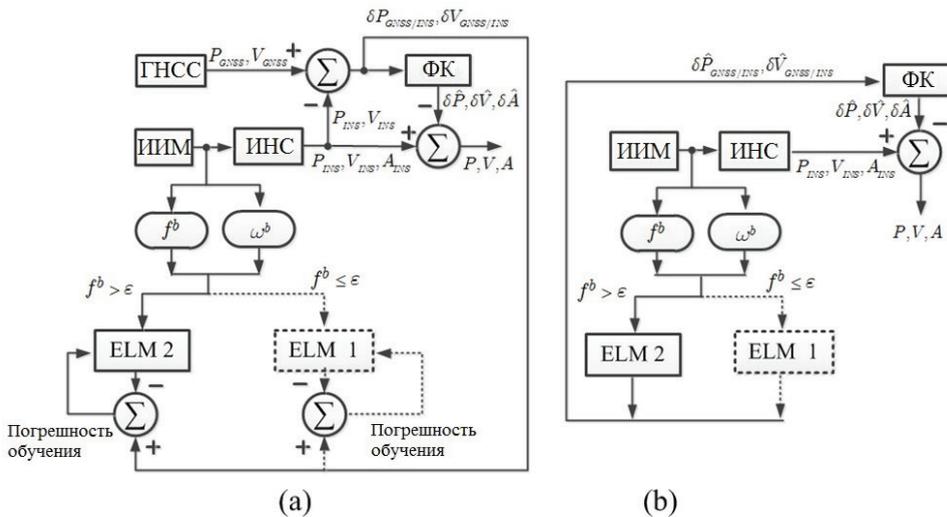


Рис. 11. Гибридная система прогнозирования ELM/ФК:
 а – режим обучения; б – режим прогнозирования

Когда сигналы ГНСС поступают непрерывно, ELM функционирует в режиме обучения. Измерения гироскопа и акселерометра выбираются в качестве входных сигналов ELM, а вектор наблюдения ФК $(\delta P_{GNSS/INS}, \delta V_{GNSS/INS})$ рассматривается в качестве эталонных параметров на входе нейронной сети, как показано на рис. 11, а. Используются два модуля ELM, активируемых в зависимости от амплитуды измеренного ускорения. При возникновении отключений ГНСС ELM-сети переключаются

в режим прогнозирования (см. рис. 11, б). Данные измерений гироскопов и акселерометров передаются в ELM для формирования прогноза вектора наблюдения ФК ($\delta\hat{P}_{GNSS/INS}, \delta\hat{V}_{GNSS/INS}$), который используется для обновления результатов измерений в ФК. Полученные результаты показывают, что предложенный алгоритм позволяет повысить точность по сравнению со схемами на основе только RBF и только ФК при двух отключениях ГНСС (на 50 и 100 с) в случае недорогой интегрированной навигационной системы БИНС/ГНСС [51].

В [53] предложен гибридный алгоритм обработки данных, позволяющий получить псевдоинформацию о местоположении, чтобы поддержать интегрированную навигационную систему при отключениях ГНСС. Предлагаемая модель на основе MLPNN соотносит данные о скорости, угловой скорости и кажущемся ускорении ИНС с приращениями координат по данным ГНСС (рис. 12). Модель обозначена как $O_{INS} - \Delta P_{GNSS}$. При наличии данных от ГНСС модуль MLPNN находится в режиме обучения (рис. 12, а). Данные на текущем и предыдущем шаге о кажущемся ускорении, угловых скоростях и скорости передаются в модуль MLPNN в качестве входных данных, в то время как приращения координат по данным ГНСС задаются в качестве ожидаемого выхода. Приращение координат по данным ГНСС может быть накоплено для получения псевдокоординат ГНСС, которые затем используются в качестве входных данных в ФК для формирования вектора наблюдения с учетом данных о координатах, вырабатываемых ИНС. Гибридная система будет непрерывно предоставлять информацию, как это происходит и при наличии ГНСС (рис. 12, б). Модель $O_{INS} - \Delta P_{GNSS}$ продемонстрировала лучшие результаты, чем модель, описанная в [31, 41, 42], при одном отключении ГНСС на 300 с. В ходе эксперимента использовался ИИМ тактического класса, информации об эффективности предложенной архитектуры с использованием ИИМ на МЭМС нет.

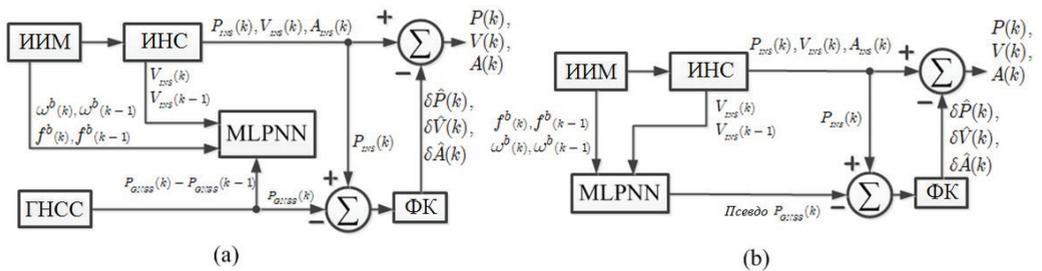


Рис. 12. Гибридный алгоритм обработки для интегрированной системы ГНСС/ИНС: а – режим обучения; б – режим прогнозирования

В [54] предложен способ обработки данных, дополнительно использующий робастный метод наименьших квадратов на основе опорных векторов (robust least squares support vector machine, RLS-SVM) для прогнозирования псевдокоординат ГНСС во время ее отключений. Эта система аналогична $O_{INS} - \Delta P_{GNSS}$ в части функции модуля ИИ, но вместо MLPNN используется RLS-SVM, входными данными которого являются значения кажущегося ускорения, скорости и рыскания вместо текущих и предыдущих значений кажущегося ускорения, угловых скоростей и скорости в $O_{INS} - \Delta P_{GNSS}$. Предложенный алгоритм способен более точно спрогнозировать

приращения координат, чем описанный выше метод на основе LS-SVM [43]. При этом результаты получены только для ИИМ тактического класса и при отключении ГНСС на 300 с.

Общим недостатком всех архитектур категории АІСКF является то, что они используют одни и те же данные (ковариационные матрицы) ФК как при наличии, так и при отсутствии сигнала ГНСС. Это ошибочный подход, поскольку измерения, вырабатываемые модулями ИИ, имеют характеристики, отличающиеся от характеристик измерений ГНСС. Один из вариантов решения этой проблемы – привязать ковариационные матрицы к погрешностям обучения и прогнозирования модуля ИИ.

Сравнение различных архитектур

В табл. 2 приведены преимущества и недостатки всех схем, описанных в данной статье. В последних двух столбцах приведены сведения о способности данной архитектуры функционировать в режиме реального времени и обеспечить более высокую точность по сравнению с другими схемами или/и ФК. Способность работать в режиме реального времени может рассматриваться как уровень сложности модуля в части конфигураций входных/выходных данных, количества слоев и нейронов (случай ANN) и алгоритмов обучения (действующих автономно, в режиме реального времени, скользящего окна и т.д.). Индекс, отражающий повышение точности, берется из литературы. В действительности трудно оценить общую производительность предлагаемых архитектур, поскольку все они тестировались различными способами.

Таблица 2

Сравнение различных архитектур на основе искусственного интеллекта в системе ИНС/ГНСС;
✓ – да; ✗ – нет

Архитектура	Общая категория			Выходные данные при откл. ГНСС			Класс ИНС			Способность работы в режиме реального времени	Повышение точности
	Только ИИ	АІСКF	АІАKF	Координаты	Скорость	Ориентация	Навигацион.	Тактические	МЭМС		
PUA_MLP	✓	✗	✗	✓	✗	✗	✗	✓	✗	★	★
PUA_CNN	✓	✗	✗	✓	✗	✗	✓	✗	✓	★★	★★
PUA_RFR	✓	✗	✗	✓	✗	✗	✗	✗	✓	★★★	★★★
P-δP (MLPNN)	✓	✗	✗	✓	✗	✗	✓	✗	✗	★	★
P-δP (РБФНС)	✓	✗	✗	✓	✗	✗	✓	✓	✗	★★★	★★
P-δP (ANFIS)	✓	✗	✗	✓	✗	✗	✓	✗	✗	★★	★★
P-δP+V-δV (ANFIS)	✓	✗	✗	✓	✓	✗	✓	✗	✗	★★	★★
P-δP+V-δV (GANFIS)	✓	✗	✗	✓	✓	✗	✓	✗	✗	★	★★★

P- δ P+V- δ V (PANFIS)	✓	✗	✗	✓	✓	✗	✓	✗	✗	★	★★★
MLPNN+ОФК	✗	✓	✗	✓	✗	✗	✗	✗	✓	★★	★★
ANFIS+ОФК использующий P- δ P	✗	✓	✗	✓	✗	✗	✗	✗	✓	★★	★★★
LS-SVM+ОФК	✗	✓	✗	✓	✗	✗	✗	✓	✓	★★★★	★★
WNN+STKF	✗	✓	✗	✓	✗	✗	✗	✓	✗	★★★	★★★
RBFNN+ОФК	✗	✓	✗	✓	✗	✗	✗	✗	✓	★★★	★★
RBFNN+ОФК	✗	✓	✗	✓	✓	✓	✗	✗	✓	★★★	★★★
RBFNN+ОФК	✗	✗	✓	✓	✓	✓	✗	✓	✗	★★★	★★★★
RBFNN+ОФК+ временные ряды	✗	✗	✓	✓	✓	✓	✓	✗	✗	★★★★	★★★★
ELM+ОФК	✗	✗	✓	✓	✓	✓	✗	✗	✓	★★	★★★
O- Δ P (MLPNN+ОФК)	✗	✗	✓	✓	✓	✓	✗	✓	✗	★★★	★★★
RLS-SVM+ОФК	✗	✗	✓	✓	✓	✓	✗	✓	✗	★★★	★★★

В экспериментах были задействованы разные классы ИНС, они также проходили при разных количестве отключений ГНСС и продолжительности отсутствия ее сигналов. Тем не менее, как видно из табл. 2, АІАКФ обладает рядом преимуществ по сравнению с АІСКФ и методами только на базе ИИ в отношении количества обновлений выходных данных ГНСС во время ее отключений. Это важно для многих приложений, которые требуют непрерывно поступающей информации о координатах, скорости и пространственном положении. Еще одним достоинством АІАКФ является способность вырабатывать информацию о точности при отсутствии сигналов ГНСС благодаря расчету ковариационной матрицы в ФК. Алгоритмы двух других категорий (АІСКФ и только ИИ) не предоставляют таких данных. Что касается ИНС, то результаты экспериментов показали, что гибридный метод прогнозирования [50] (РБФНС + ОФК+ временные ряды) обеспечивает более высокую точность для ИНС навигационного класса, а метод [51] (ELM+ОФК) – для ИНС на МЭМС. Для ИНС тактического класса наиболее высокую точность обеспечивают алгоритмы ANFIS + ОФК с использованием P- δ P [42], O- Δ P [53] и RLS-SVM+ОФК [54]. Алгоритмы LS-SVM+ОФК [43] и ELM+ОФК [51] обладают наилучшими характеристиками для работы в режиме реального времени.

Выводы

В этом разделе проанализированы некоторые вопросы, касающиеся применения методов ИИ в системах ИНС/ГНСС.

А. Выбор входных и выходных данных для модулей ИИ

Проблема выбора оптимальной конфигурации входных и выходных данных для модулей ИИ глубоко не рассматривалась. Фактически большинство авторов предлагают собственный вариант конфигурации входных и выходных данных, не обосновывая его.

вывая свой выбор и не проводя сравнений с другими конфигурациями. В качестве исключения можно назвать работы [43, 49], в которых входные и выходные параметры выбираются на основе перекрестных корреляций между ними. Между тем этот вопрос следует рассмотреть подробно, поскольку он имеет непосредственное отношение к точности системы, а также к способности функционировать в режиме реального времени. Чем меньше конфигураций входных и выходных параметров, тем проще внутренняя структура, а следовательно, короче период обучения. Наоборот, большее число конфигураций означает наличие более сложной структуры и, соответственно, более длительного периода обучения, что затрудняет использование системы в режиме реального времени.

Б. Фильтр Калмана

Как известно, ФК обладает целым рядом достоинств, таких как простота реализации и способность функционировать в режиме реального времени. По этой причине он используется в качестве основного компонента в интегрированных системах ИНС/ГНСС. При этом в исследованиях, описывающих применение модулей ФК и ИИ, в качестве единственно возможного варианта предлагался обобщенный фильтр Калмана. Исключением является работа [45], где в качестве инструмента обработки информации предлагается STKF. Другие варианты, например ансамбльный ФК, обладающий меньшей чувствительностью к нелинейностям моделей процессов и наблюдений по сравнению с обобщенным ФК, не рассматриваются.

В. Модуль искусственного интеллекта

Технология искусственного интеллекта развивается очень быстро, и новые методы успешно применяются во многих областях. Современная тенденция заключается в использовании новых интеллектуальных алгоритмов, таких как ELM, SVM, RFR и др., которые способны быстро обучаться и обладают более высокой производительностью по сравнению с обычными ANN (MLP, RBF, ANFIS и др.).

Г. Алгоритмы обучения

В основе алгоритмов обучения модулей ИИ во всех вышеупомянутых архитектурах лежит так называемое пакетное обучение, при котором параметры модуля ИИ обновляются после накопления пакета данных (окна). Недостаток этого метода заключается в том, что процесс обучения не может начаться, пока не будет накоплено определенное количество обучающих выборок, что затрудняет использование алгоритма в режиме реального времени. Наиболее подходящим для модуля ИИ в системах ИНС/ГНСС фактически является интерактивное обучение – наиболее распространенный метод машинного обучения, поскольку нет вычислительных возможностей обработать быстро большой массив данных. Этот метод используется также в тех случаях, когда возникает необходимость в оперативной адаптации алгоритма к новым наборам данных или когда сами данные являются функцией времени. В процессе онлайн-обучения модуль ИИ будет функционировать точно так же, как и ФК, а его параметры будут постепенно обновляться с каждым новым пакетом.

Д. Условия обучения

Все предлагаемые архитектуры работают в двух режимах – режиме обучения при наличии сигнала ГНСС и режиме прогнозирования при его отсутствии. Тем не менее в процессе обучения эти методы не учитывают качество измерений ГНСС, которое может снижаться в условиях городской среды. Это влияет на результаты обучения модуля ИИ по причине неопределенности эталонных данных.

Е. Компенсированный ФК по сравнению с дополненным

В системах ИНС/ГНСС по-прежнему применяются оба ФК – как дополненный, так и компенсированный ИИ, хотя нет никаких сведений, какой из них лучше с точки зрения повышения точности. В будущем необходимо найти ответ именно на этот вопрос: это позволит сосредоточить усилия исследователей на одном направлении вместо двух и сэкономит много времени.

Заключение

Чтобы решить проблему отсутствия сигнала ГНСС в слабосвязанных системах ИНС/ГНСС, применяются различные методы на основе искусственного интеллекта. В настоящем обзоре представлено описание ряда архитектур с кратким пояснением для каждой. Подробно обсуждаются вопросы, связанные с применением искусственного интеллекта в системах ИНС/ГНСС. Приводится сравнение различных архитектур. Даются рекомендации для будущих исследований в области применения технологий на основе искусственного интеллекта в интегрированных системах ИНС/ГНСС.

ЛИТЕРАТУРА

1. Grewal, M.S., Weill, L.R., & Andrews, A.P., *Global positioning systems, inertial navigation, and integration*, John Wiley & Sons, 2007.
2. Farrell, J., & Barth, M., *The global positioning system and inertial navigation*, New York, Mcgraw-hill, 1999, vol. 61.
3. Chiang, K. W., Noureldin, A., & El-Sheimy, N., Multisensor integration using neuron computing for land-vehicle navigation. *GNSS solutions*, 2003, 6(4), 209–218.
4. Salychev, O.S., *Inertial systems in navigation and geophysics*, Moscow, Russia, Bauman MSTU Press, 1998, pp. 11–98.
5. Jekeli, C., *Inertial navigation systems with geodetic applications*, Walter de Gruyter, 2012.
6. Vörsmann, P., Kaschwich, C., Krüger, T., Schnetter, P., & Wilkens, C.S., MEMS based integrated navigation systems for adaptive flight control of unmanned aircraft – State of the art and future developments, *Gyroscopy and Navigation*, 2012, 3(4), 235–244.
7. Schwarz, K. P., El-Sheimy, N., & Liu, Z., Fixing GNSS cycle slips by INS/GNSS–methods and experiences, *Proc. KIS94*, 1994, 265–275.
8. Angrisano, A., *GNSS/INS integration methods*, Dottorato di ricerca (PhD) in Scienze Geodetiche e Topografiche Thesis, Università degli Studi di Napoli PARTHENOPE, Naples, 21, 2010.
9. Crassidis, J.L., & Junkins, J.L., *Optimal estimation of dynamic systems*, Chapman and Hall/CRC, 2004.
10. Julier, S.J., & Uhlmann, J.K., Unscented filtering and nonlinear estimation, *Proceedings of the IEEE*, 2004, 92(3), 401–422.
11. Vanicek, P., & Omerbasic, M., Does a navigation algorithm have to use a Kalman filter?, *Canadian aeronautics and space journal*, 1999, 45(3), 292–296.
12. Hong, S., Lee, M.H., Chun, H.H., Kwon, S.H., & Speyer, J.L., Observability of error states in GNSS/INS integration, *IEEE Transactions on Vehicular Technology*, 2005, 54(2), 731–743.

13. Tang, Y., Wu, Y., Wu, M., Wu, W., Hu, X., & Shen, L., INS/GNSS integration: Global observability analysis, *IEEE Transactions on Vehicular Technology*, 2008, 58(3), 1129–1142.
14. Cawsey, A., *The essence of artificial intelligence*, Prentice Hall PTR, 1997.
15. Symon, H., *Neural networks: a comprehensive foundation*, Prentice-Hall, 1999.
16. Jang, J.S., ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 1993, 23(3), 665–685.
17. Eiben, A.E., & Smith, J.E., *Introduction to evolutionary computing*, Berlin, Springer, vol. 53, p. 18. 2003.
18. Giarratano, J. C., & Riley, G., *Expert systems: Principles and programming*, Brooks/Cole Publishing Co, 1989.
19. Mitchell, M., *An introduction to genetic algorithms*, MIT Press, 1998.
20. Uhr, L., & Honavar, V. (Eds.), *Artificial intelligence and neural networks: steps toward principled integration*, Academic Press, 1994.
21. Wang, X., Li, K., Gao, P., & Wang, W., Reinforced ultra-tightly coupled GNSS/INS system for challenging environment, *Mathematical Problems in Engineering*, 2014.
22. Refan, M. H., Dameshghi, A., & Kamarzarrin, M., Utilizing hybrid recurrent neural network and genetic algorithm for predicting the pseudo-range correction factors to improve the accuracy of RTDGNSS, *Gyroscopy and Navigation*, 2015, 6(3), 197–206.
23. El-Sheimy, N., Chiang, K. W., & Noureldin, A., The utilization of artificial neural networks for multisensor system integration in navigation and positioning instruments, *IEEE Transactions on instrumentation and measurement*, 2006, 55(5), 1606–1615.
24. Noureldin, A., Osman, A., & El-Sheimy, N., A neuro-wavelet method for multi-sensor system integration for vehicular navigation, *Measurement science and technology*, 2003, 15(2), 404.
25. Noureldin, A., El-Shafie, A., & El-Sheimy, N., Adaptive neuro-fuzzy module for inertial navigation system/global positioning system integration utilising position and velocity updates with real-time cross-validation, *IET Radar, Sonar & Navigation*, 2007, 1(5), 388–396.
26. Chiang, K. W., Noureldin, A., & El-Sheimy, N., Constructive neural-networks-based MEMS/GNSS integration scheme, *IEEE transactions on aerospace and electronic systems*, 2008, 44(2), 582–594.
27. Fahlman, S. E., & Lebiere, C., The cascade-correlation learning architecture, *Advances in neural information processing systems*, 1990, pp. 524–532.
28. Adusumilli, S., Bhatt, D., Wang, H., Bhattacharya, P., & Devabhaktuni, V., A low-cost INS/GNSS integration methodology based on random forest regression, *Expert Systems with Applications*, 2013, 40(11), 4653–4659.
29. Breiman, L., *Random forests. Machine learning*, 2001, 45(1), 5–32.
30. Moré, J.J., The Levenberg-Marquardt algorithm: implementation and theory, *Numerical analysis*, Springer, Berlin, Heidelberg, 1978, pp. 105–116.
31. Sharaf, R., Noureldin, A., Osman, A., & El-Sheimy, N., Online INS/GNSS integration with a radial basis function neural network, *IEEE Aerospace and Electronic Systems Magazine*, 2005, 20(3), 8–14.
32. Sharaf, R., & Noureldin, A., Sensor integration for satellite-based vehicular navigation using neural networks, *IEEE transactions on neural networks*, 2007, 18(2), 589–594.
33. Taha, M.R., Noureldin, A., & El-Sheimy, N., Improving INS/GNSS positioning accuracy during GNSS outages using fuzzy logic, *Proceedings of the 16th International Technical Meeting of the Satellite Division of The Institute of Navigation (ION GNSS/GNSS 2003)*, 2001, pp. 499–508.
34. Bezdek, J.C., *Objective function clustering, Pattern recognition with fuzzy objective function algorithms*, Springer, Boston, MA, 1981, pp. 43–93.
35. Noureldin, A., El-Shafie, A., & Taha, M. R., Optimizing neuro-fuzzy modules for data fusion of vehicular navigation systems using temporal cross-validation, *Engineering Applications of Artificial Intelligence*, 2007, 20(1), 49–61.
36. Hasan, A.M., Samsudin, K., Ramli, A.R., & Azmir, R.S., Automatic estimation of inertial navigation system errors for global positioning system outage recovery, *Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering*, 2011, 225(1), 86–96.
37. Hasan, A.M., Samsudin, K., & Ramli, A.R., Optimizing of ANFIS for estimating INS error during GNSS outages, *Journal of the Chinese Institute of Engineers*, 2011, 34(7), 967–982.
38. Kennedy, J., *Particle swarm optimization. Encyclopedia of machine learning*, 2010, 760–766.
39. Hou, H., & El-Sheimy, N., Inertial sensors errors modeling using Allan variance, *Proceedings of the 16th International Technical Meeting of the Satellite Division of the Institute of Navigation (ION GNSS/GNSS 2003)*, 2001, pp. 2860–2867.

40. Goodall, C., Syed, Z., & El-Sheimy, N., Improving INS/GNSS navigation accuracy through compensation of Kalman filter errors, *IEEE Vehicular Technology Conference*, 2006, pp. 1–5
41. Abdel-Hamid, W., Noureldin, A., & El-Sheimy, N., Adaptive fuzzy prediction of low-cost inertial-based positioning errors, *IEEE Transactions on Fuzzy Systems*, 2007, 15(3), 519–529.
42. Noureldin, A., Karamat, T.B., Eberts, M.D., & El-Shafie, A., Performance enhancement of MEMS-based INS/GNSS integration for low-cost navigation applications, *IEEE Transactions on vehicular technology*, 2009, 58(3), 1077–1096.
43. Xu, Z., Li, Y., Rizos, C., & Xu, X., Novel hybrid of LS-SVM and Kalman filter for GNSS/INS integration, *The Journal of Navigation*, 2010, 63(2), 289–299.
44. Vapnik, V., The support vector method of function estimation. In *Nonlinear Modeling*, Springer, Boston, MA, 1998, pp. 55–85.
45. Chen, X., Shen, C., Zhang, W. B., Tomizuka, M., Xu, Y., & Chiu, K., Novel hybrid of strong tracking Kalman filter and wavelet neural network for GNSS/INS during GNSS outages, *Measurement*, 2013, 46(10), 3847–3854.
46. Boutayeb, M., & Aubry, D., A strong tracking extended Kalman observer for nonlinear discrete-time systems, *IEEE Transactions on Automatic Control*, 1999, 44(8), 1550–1556.
47. Zhang, J., Walter, G. G., Miao, Y., & Lee, W. N. W., Wavelet neural networks for function learning, *IEEE transactions on Signal Processing*, 1995, 43(6), 1485–1497.
48. Wang, X., Chen, J. X., & Ni, W., A hybrid prediction method and its application in the distributed low-cost INS/GNSS integrated navigation system, *IEEE 18th International Conference on Information Fusion (Fusion)*, 2015, pp. 1205–1212.
49. Wang, J.J., Wang, J., Sinclair, D., & Watts, L., Neural network aided Kalman filtering for integrated GNSS/INS geo-referencing platform, *Proc. 5th Int. Symp. Mobile Mapping Technol.*, 2007, pp. 1–6.
50. Chen, L., & Fang, J., A hybrid prediction method for bridging GNSS outages in high-precision POS application, *IEEE Transactions on Instrumentation and Measurement*, 2014, 63(6), 1656–1665.
51. Jingsen, Z., Wenjie, Z., Bo, H., & Yali, W., Integrating Extreme Learning Machine with Kalman Filter to Bridge GNSS Outages, *IEEE 3rd International Conference on Information Science and Control Engineering (ICISCE)*, 2016, pp. 420–424.
52. Huang, G. B., Wang, D. H., & Lan, Y., Extreme learning machines: a survey, *International journal of machine learning and cybernetics*, 2011, 2(2), 107–122.
53. Yao, Y., Xu, X., Zhu, C., & Chan, C.Y., A hybrid fusion algorithm for GNSS/INS integration during GNSS outages, *Measurement*, 2017, 103, 42–51.
54. Yao, Y., & Xu, X., A RLS-SVM aided fusion methodology for INS during GNSS outages, *Sensors*, 2017, 17(3), 432.

Al Bitar, N., Gavrilov, A.I. (Department of Automatic Control Systems, Bauman Moscow State Technical University, Moscow, Russia), Khalaf, W. (Department of Electronic & Mechanical Systems, Higher Institute for Applied Sciences and Technology, Damascus, Syria)

Artificial Intelligence Based Methods for Accuracy Improvement of Integrated Navigation Systems During GNSS Signal Outages: an Analytical Overview, *Giroskopiya i Navigatsiya*, 2019, vol. 27, no. 4 (107), pp. 3–28

Abstract. The limitations of Kalman filter (KF) have motivated researchers to consider alternative methods of integrating inertial navigation systems (INS) and global navigation satellite systems (GNSS), predominantly based on artificial intelligence (AI). Over the past two decades, a great number of research gained in order to validate the possibility of using AI methods in the field of integrated navigation systems. Different approaches have been proposed for combining AI modules with the other parts of the INS/GNSS system. The article suggests a new classification of the resulting schemes based on the functionality of AI modules in the INS/GNSS system. The paper also provides a brief explanation of each scheme with its advantages and disadvantages. Some aspects that need to be considered in future research in this field are also highlighted.

Key words: inertial navigation systems, global navigation satellite systems, artificial intelligence, neural networks, Kalman filter.

Материал поступил 29.05.2019