

М. АЛЬ-МАНСУР, И. ЧУАИБ, А. ДЖАФАР

КЛАССИФИКАЦИЯ МАНЕВРОВ ПОДВИЖНОГО ОБЪЕКТА С ШЕСТЬЮ СТЕПЕНЯМИ СВОБОДЫ МЕТОДОМ ЛОГИСТИЧЕСКОЙ РЕГРЕССИИ

Представлен новый онлайн-алгоритм классификации маневров подвижного объекта с шестью степенями свободы на основе данных бортового микромеханического инерциального измерительного модуля (ИИМ) (трех акселерометров и трех гироскопических датчиков угловой скорости). Классификация может быть как дискретной (то есть резкий маневр, плавный маневр или отсутствие маневра), так и непрерывной (величина, указывающая на интенсивность маневра).

В основе предлагаемого алгоритма лежат метод главных компонент и метод машинного обучения, известный как логистическая регрессия, которая представляет собой модель дискриминативной вероятностной классификации. Результаты полунатурного моделирования с использованием данных микромеханического ИИМ, взятых из реальных экспериментов с беспилотными летательными аппаратами (БЛА), показали эффективность предложенного алгоритма и его пригодность для широкого спектра применений.

Ключевые слова: маневры, машинное обучение, статистические классификаторы, логистическая регрессия, метод главных компонент, беспилотный летательный аппарат.

Введение

Маневр является неотъемлемой частью движения любого подвижного объекта, в особенности это относится к воздушным, наземным и подводным транспортным средствам [1, 2]. Выполнение маневра напрямую связано с откликом объекта на команды системы управления. Интенсивность маневров играет важнейшую роль в обеспечении безопасности объекта, поскольку при резком маневре достаточно сложно удерживать несколько параметров в допустимых пределах [1, 3]. К таким параметрам относятся: угловая скорость объекта и линейное ускорение, нормальная перегрузка, перепады давления и изгибы, образующиеся на корпусе объекта, теплообразование на наружных поверхностях, силы торможения и трения, возникающие при маневрировании, и т.п. [1]. Можно выделить несколько уровней интенсивности маневров – начиная с состояния отсутствия маневра (равномерное линейное движение) и заканчивая маневрами, способными привести к разрушению объекта [3].

Аль-Мансур Мехьяр. Аспирант, факультет электронных и механических систем, Институт прикладных наук и технологий (HIAST), Дамаск, Сирия.

Чуаиб Ибрахим. Доктор наук, профессор, HIAST

Джафар Асеф. Доктор наук, профессор, HIAST.

Научный редактор перевода д.т.н. О.А. Степанов.

Гироскопия и навигация. Том 26, №2 (101), 2018

Определение интенсивности маневра подвижного объекта в режиме реального времени является весьма важной задачей, которая напрямую связана и с угловой скоростью, и с линейным ускорением объекта. Однако проблема классификации маневров до сегодняшнего дня должным образом, по мнению авторов, не обсуждалась в научной литературе, что объясняется сложностью поиска прямой математической модели, способной охарактеризовать интенсивность маневров. Это может быть обусловлено несколькими причинами, в том числе сильным шумом выходного сигнала датчика, как в нашем случае, не говоря уж о том, что классификация маневров является процессом относительным, который зависит от того, кто принимает решение, и от характеристик движущегося объекта, поскольку один и тот же маневр может считаться резким для одного объекта и плавным – для другого. Определение интенсивности маневров подвижного объекта в режиме реального времени имеет ряд преимуществ: автопилот может автоматически принимать важные решения, выявлять нештатные ситуации и ошибочные команды и вносить соответствующие коррективы. Такую функцию можно назвать алгоритмом выявления неисправности [3, 4, 5]. В то же время процесс классификации маневров может осуществляться для обнаружения отсутствия движения [6], которое полезно при выставке инерциальной навигационной системы. Кроме того, обсуждаемый алгоритм может использоваться и для разработки адаптивного закона управления.

В предлагаемой работе построен онлайн-алгоритм, с помощью которого можно классифицировать маневры подвижного объекта с шестью степенями свободы по трем уровням («нет маневра», «плавный маневр», «резкий маневр») на основе данных бортового микромеханического ИИМ (три акселерометра и три гироскопических датчика угловой скорости). В связи с тем что данным таких ИИМ присущи погрешности, а взаимосвязь этих погрешностей и маневров зависит не только от последней выборки, но и от характера изменения данных на более продолжительном промежутке времени, в основу классификатора положено скользящее окно данных, имеющее фиксированный размер. Размер окна выбирают таким образом, чтобы можно было наблюдать все изменения, имеющие место на подвижном объекте, с учетом времени выборки и максимальной скорости объекта. Это означает, что скользящее окно не должно содержать более одного маневра.

Следует учитывать, что данные чувствительных элементов ИИМ коррелированы между собой. Это происходит по нескольким причинам. Одна из них заключается в неортогональности установленных чувствительных элементов. Такую корреляцию можно охарактеризовать и обозначить коэффициентом корреляции ρ и матрицей ковариаций R [15].

Для решения задачи классификации в работе предлагается метод главных компонент (МГК), применяемый к скользящему окну [7, 16]. В результате применения МГК данные ИИМ принимают новую форму, и их удобно использовать для решения задачи классификации. В работе для этого предлагается обучаемый классификатор, который можно построить на основе априорных данных (обучающего набора данных) и использовать в дальнейшем в рабочем режиме.

При выборе метода классификации основное внимание уделяется вероятностным классификаторам [9]. Когда классы имеют тенденцию к совпадению и их сложно выделить, желательно избегать неточностей, связанных с принятием решений. Для этого необходимо использовать один из двух базовых методов [10]. Первый – метод генеративных классификаторов типа байесовского, в котором модель строится по данным наблюдений для каждого класса. Второй метод – дискриминативных классификаторов, например логистической регрессии, –

определяет, какие особенности входных данных наиболее полезны для распознавания различных вероятных классов. В настоящей работе применяется именно метод логистической регрессии.

Статья построена следующим образом. Сначала описываются основные идеи, положенные в основу алгоритма классификации, затем – сам алгоритм и его реализация. Далее приводятся результаты моделирования и их обсуждение. В заключение делаются выводы и даются рекомендации. В приложении описываются основные положения метода логистической регрессии.

Основные идеи

Как было отмечено во введении, в основе предлагаемого алгоритма лежат две основные идеи. Поясним далее суть этих идей.

Метод главных компонент

Данные ИИМ трудно использовать непосредственно для классификации интенсивности маневров. Это связано с несколькими факторами, в том числе наличием погрешностей измерений, наличием корреляции между выходными данными чувствительных элементов ИИМ, а также зависимостью маневра не только от последней выборки, но и от характера изменения данных на более продолжительном промежутке времени. Одна из идей состоит в том, чтобы из данных ИИМ выделить набор величин, которые удобно использовать для классификации интенсивности маневров (динамики).

Для решения этой задачи используется МГК, применяемый к скользящему окну, содержащему последнюю выборку $N_{samples}$ данных ИИМ [7, 16]. С помощью МГК выделяют собственные величины и собственные векторы матрицы ковариации для данных скользящего окна в каждый момент времени. Собственные величины (дисперсии) для каждого собственного вектора отражают динамику по данной оси [16]. Таким образом, собственные значения удобно использовать для классификации маневров. На




Рис. 1. Применение МГК для двумерных данных

рис. 1 показан пример применения МГК для двумерных данных $\mathbf{x} = (x \ y)^T$.

Итак, для $\mathbf{X}_i = \{\mathbf{x}_l \mid (i - N_{samples} + 1 \leq l \leq i)\}$ (последняя выборка $N_{samples}$ данных ИИМ) процедура, реализующая МГК, сводится к выполнению следующих шагов [7, 16]:

- вычисление среднего значения $\mathbf{X}_i$:

$$\mathbf{m}_{\mathbf{x}_i} = \text{mean}(\mathbf{X}_i); \quad (1)$$

- вычисление матрицы ковариации для $\mathbf{X}_i$:

$$\mathbf{S}_{\mathbf{x}_i} = \text{cov}(\mathbf{X}_i) = \left(\frac{1}{N_{samples} - 1} \right) \sum_{l=i-N_{samples}+1}^i ((\mathbf{x}_l - \mathbf{m}_{\mathbf{x}_i})(\mathbf{x}_l - \mathbf{m}_{\mathbf{x}_i})^T); \quad (2)$$

- нахождение собственных векторов и собственных значений матрицы ковариации S_{x_i} .

Следует отметить, что без предварительной подготовки данных ИИМ с помощью МГК классификатор построить затруднительно.

Метод логистической регрессии

Для решения задачи классификации используется метод логистической регрессии, который также иногда называют логистической моделью, или логит-моделью. С помощью логистической регрессии выполняется анализ соотношения множества независимых переменных и зависимой переменной и оценивается апостериорная вероятность события, отражающего соответствие данных логистической кривой [13]. Этот метод можно использовать для разделения как на два (бинарная логистическая регрессия), так и на несколько классов (полиномиальная логистическая регрессия) [13, 14]. Более подробное разъяснение представлено в приложении.

Классификация методом логистической регрессии осуществляется путем предварительного нахождения весовых коэффициентов для каждого класса на основе набора обучающих данных (при помощи уравнения (П-14) или (П-16)). Затем в рабочем режиме эти весовые коэффициенты используются для вычисления апостериорных вероятностей какой-либо новой выборки в соответствии со всеми классами (уравнения (П-8 и П-9) или (П-10 и П-11)). Таким образом, после сравнения всех апостериорных вероятностей можно выбрать подходящий класс для этой новой выборки.

Алгоритм классификации маневров

С помощью предлагаемого онлайн-алгоритма можно систематизировать маневры подвижного объекта с шестью степенями свободы по трем уровням (отсутствие маневра, плавный маневр или резкий маневр) на основе данных бортового микромеханического ИИМ, который содержит три акселерометра $\{Acc_i = (Acc_x^i \ Acc_y^i \ Acc_z^i)^T\}$ и три гироскопических датчика угловой скорости $\{W_i = (W_x^i \ W_y^i \ W_z^i)^T\}$, где i обозначает момент выборки. В рамках этой статьи было исследовано три метода.

1. *Прямой метод.* Классификация по трем уровням (отсутствие маневра, плавный или резкий маневр) выполняется в один шаг, как показано на рис. 2. В этом случае данные записываются в виде:

$$x_all_i = (Acc_x^i \ Acc_y^i \ Acc_z^i \ W_x^i \ W_y^i \ W_z^i)^T. \quad (3)$$




Рис. 2. Схема предлагаемого прямого метода

2. *Двухшаговый метод.* Классификация выполняется в два шага. Сначала производится классификация по наличию или отсутствию маневра (да/нет) по данным гироскопических датчиков угловой скорости, а второй шаг выполняется, только если на первом шаге определено наличие маневра, который классифицируется как плавный или резкий по данным акселерометров, как показано на рис. 3. В этом случае данные записываются в виде:

$$\mathbf{x_Acc}_i = (Acc_x^i \quad Acc_y^i \quad Acc_z^i)^T, \quad \mathbf{x_W}_i = (W_x^i \quad W_y^i \quad W_z^i)^T. \quad (4)$$




Рис. 3. Схема предлагаемого двухшагового метода

3. *Двухшаговый метод с нелинейной базисной функцией.* Этот метод аналогичен описанному в п. 2 двухшаговому методу по своей структуре, но на каждом шаге исходные данные дополняются нелинейными базисными функциями, как показано на рис. 4. Была проведена проверка нескольких вариантов, в результате которой выбрана нелинейная базисная функция $\Phi(x)=x^2$. В связи с этим данные записываются в следующем виде:

$$\mathbf{x_Acc}_i^b = (\mathbf{x_Acc}_i \quad \Phi(\mathbf{x_Acc}_i))^T, \quad \mathbf{x_W}_i^b = (\mathbf{x_W}_i \quad \Phi(\mathbf{x_W}_i))^T, \quad (5)$$

где

$$\left. \begin{aligned} \Phi(\mathbf{x_Acc}_i) = \mathbf{x_Acc}_i^2 &= \left((Acc_x^i)^2 \quad (Acc_y^i)^2 \quad (Acc_z^i)^2 \right)^T \\ \Phi(\mathbf{x_W}_i) = \mathbf{x_W}_i^2 &= \left((W_x^i)^2 \quad (W_y^i)^2 \quad (W_z^i)^2 \right)^T \end{aligned} \right\}. \quad (6)$$




Рис. 4. Схема предлагаемого двухшагового метода с нелинейной базисной функцией

Предлагаемый алгоритм можно разбить на два основных этапа:

- 1) этап обучения, на котором определяют параметры классификатора по имеющимся данным ИИМ;
- 2) рабочий режим, на котором классификатор определяет категорию маневра (резкий, плавный, отсутствующий маневр).

На рис. 5 представлены блок-схемы указанных этапов предлагаемого алгоритма, которые подробнее описаны в нижеследующих подразделах.




Рис. 5. Схема предлагаемого алгоритма

Этап обучения

Обязательным условием для реализации этого этапа является наличие априорных данных, т.е. обучающего набора. Этот набор представляет собой данные бортового микромеханического ИИМ подвижного объекта, полученные в ходе реального эксперимента. В набор входят все возможные варианты маневров. Прежде чем подготовить обучающие данные для процедуры классификации, их необходимо промаркировать в ручном режиме (определяя класс, к которому относится каждая выборка). Таким образом, траекторию БЛА можно в ручном режиме достоверно разбить на несколько участков таким образом, чтобы каждый из них был бы сопоставим с одним из следующих классов:

- C_{no} – «маневр отсутствует»;
- C_{yes} – «имеется маневр», который, в свою очередь, разделяется на два подкласса:
 - ✓ C_{low} – «плавный маневр»,
 - ✓ C_{high} – «резкий маневр».

На дальнейших этапах происходит подготовка обучающих данных (на схеме рис. 5 – блоки с $a-1$ по $a-5$), которые используются для определения параметров классификатора методом логистической регрессии (на схеме – блок $a-6$).

Подготовка обучающих данных

Для каждой выборки $(\mathbf{x}_{\text{Acc}_i}, \mathbf{x}_{\text{W}_i})$ из набора обучающих данных выполняются следующие действия:

- 1) считывание новой выборки из обучающего набора и ее перезапись в соответствии с применяемым методом (уравнения (3, 4) или (5));
- 2) обновление скользящего окна, чтобы оно содержало последние выборки N_{samples} , в том числе $\mathbf{x}_i$:

$$\mathbf{Data_x}_i = [\mathbf{x}_{i-N_{\text{samples}}}, \mathbf{x}_{i-N_{\text{samples}}+1}, \dots, \mathbf{x}_i]. \quad (7)$$

Следует иметь в виду, что для прямого метода имеется только одно скользящее окно, а для других методов – два скользящих окна в зависимости от номера выполняемой процедуры классификации (прямой метод предусматривает одну, а два других метода – две процедуры классификации). Нужно отметить, что размер окна N_{samples} выбирается экспериментальным путем таким образом, чтобы все изменения, происходящие с подвижным объектом, были наблюдаемыми с учетом времени выборки и максимальной скорости объекта. Далее выполняются следующие процедуры.

1. Проведение МГК [7, 16] для скользящего окна $\mathbf{Data_x}_i$ (см. подраздел «МГК»). В результате анализа должны быть вычислены собственные значения, упорядоченные от наибольшего к наименьшему.

2. Считывание маркировки данных и, соответственно, класса, к которому эти данные относятся (см. вступление к разделу «Этап обучения»). После этого квадратный корень этих упорядоченных собственных значений вводится в матрицу, связанную с этим классом; таким образом, получаем

$$(\{\mathbf{Data_C}_{no}, \mathbf{Data_C}_{yes}, \mathbf{Data_C}_{low}, \mathbf{Data_C}_{high}\}), \quad (8)$$

где $\mathbf{Data_C}_k = [\sqrt{\text{собств. знач. } \mathbf{Data_x}_i} \quad \forall \mathbf{x}_i \in \mathbf{C}_k]$.

Определение параметров классификатора

Из вышесказанного видно, что процесс классификации на основе логистической регрессии определяется нахождением весовых коэффициентов для каждого класса с помощью подходящего последовательного градиентного спуска (уравнения (П-14) или (П-16)) в соответствии с применяемым методом. Значит, последовательность шагов для стадии обучения будет выглядеть следующим образом:

$$\mathbf{C}_k \rightarrow \mathbf{Data_C}_k \rightarrow \mathbf{w}_k = (w_{k0}, w_{k1}, \dots, w_{kd})^T, \quad k \in \{\text{нет}, \text{да}, \text{резкий}, \text{плавный}\}. \quad (9)$$

Рабочий режим

В рабочем режиме классификатор определяет класс (нет маневра, плавный, резкий маневр), к которому относятся показания. Для каждой новой выборки выполняется следующая последовательность действий (см. рис. 5, б).

1. Подготовка данных повторением шагов (1; 2; 3), описанных в подразделе «Подготовка обучающих данных». В результате должны быть получены собственные значения для данной новой выборки в порядке от наибольшего к наименьшему (на схеме рис. 5 – блоки *b-1*, *b-2*, *b-3*).

2. Вычисление апостериорных вероятностей для всех классов в зависимости от результатов стадии обучения в соответствии с принятым методом с использованием величин, полученных на предыдущем этапе с помощью соответствующего уравнения (уравнения (П-8) и (П-9) или (П-10) и (П-11)) (на схеме рис. 5 – блок *b-4*).

3. Выбор соответствующего класса по результатам сравнения всех апостериорных вероятностей, вычисленных по формуле (на схеме рис. 5 – блоки *b-5* и *b-6*):

$$\mathbf{x} \in C_i \Leftrightarrow P(C_i | \mathbf{x}) = \max \{P(C_k | \mathbf{x})\}_{1 \leq k \leq K} \quad (10)$$

Следует отметить, что в рабочем режиме нужны только набор весовых коэффициентов для каждого класса и размер скользящего окна $N_{samples}$.

Реализация алгоритма

Использовались два набора данных, полученных от микромеханического ИИМ на борту БЛА. Один из наборов данных был принят в качестве обучающего, а второй – в качестве проверочного, который служил для подтверждения эффективности предложенных алгоритмов.

Реальные эксперименты с инерциальными датчиками микромеханических ИИМ (Crossbow) осуществлялись при следующих условиях: интервал дискретизации $\Delta t = 16$ мс, $N_{samples} = 200$, обучающий набор содержал около 24000 выборок. В табл. 1 представлены характеристики ИИМ Crossbow [17].

Таблица 1

Характеристики микромеханических ИИМ Crossbow (AHRS 400CC-200) [17]

	Характеристики гироскопов	Характеристики акселерометров
Диапазон	± 200 град/ч	± 10 g
Смещение нуля	$\leq \pm 1,0$ град/с	$\leq \pm 12$ mg
Погрешность масштабного коэффициента	≤ 1 %	≤ 1
Чувствительность	$< 0,05$ град/с	$< 1,25$ мГал
Случайный уход	$< 4,5$ град/ $\sqrt{ч}$	< 0.5 м/с/ $\sqrt{ч}$



Габариты: 7,5 × 7,5 × 10,5 см

После подготовки данных в соответствии с подразделом «Подготовка обучающих данных» определяются весовые коэффициенты (9) для всех классов во всех трех предложенных методах – прямом методе, двухшаговом методе и двухшаговом методе с нелинейной базисной функцией. Как пример далее в (11) представлены весовые коэффициенты для двухшагового метода с нелинейной базисной функцией. Следует отметить, что $\mathbf{w}_{\text{да_или_нет}}$ соответствует классификации по наличию/отсутствию маневра по данным гироскопических датчиков угловой скорости, а $\mathbf{w}_{\text{плавный_или_резкий}}$ соответствует классификации по плавности/резкости маневра по данным акселерометров, и при интервале дискретизации $\Delta t = 16 \text{ мс}$ их можно записать как $\mathbf{w} = (w_0, w_1, \dots, w_d)^T$ при $d = 6$ для случая (5).

$$\mathbf{w}_{\text{да_или_нет}} = \begin{pmatrix} 2,449 \\ 80,575 \\ -124,140 \\ -875,320 \\ -1106,765 \\ 1776,662 \\ 30894,843 \end{pmatrix}, \quad \mathbf{w}_{\text{плавный_или_резкий}} = \begin{pmatrix} -6,3957 \\ 24,561 \\ 39,627 \\ -22,883 \\ -18,268 \\ -75,396 \\ -31,459 \end{pmatrix}. \quad (11)$$

В следующем разделе представлены результаты работы с использованием всех методов. Для выбора наилучшего метода проведено сопоставление результатов с использованием двух характеристик – процента удач и процента потерь, которые рассчитываются для каждого метода, а затем сравниваются друг с другом.

Моделирование и результаты

Для подтверждения эффективности предложенных алгоритмов было проведено компьютерное моделирование в среде Matlab с использованием проверочного набора реальных данных, полученных на БЛА. Результаты моделирования показаны на рис. 6 для прямого метода, на рис. 7 – для двухшагового метода и на рис. 8 – для двухшагового метода с нелинейной базисной функцией.

Нужно отметить, что маневры могут носить смешанный характер, то есть одновременно выполняться по более чем одной оси, что затрудняет выделение переменных, влияющих на маневр в целом.

На рис. 6 представлены результаты применения прямого метода. Следует учесть, что в течение периодов времени $(t < 220)$, $(680 < t < 780)$ и $(t > 830)$ маневры отсутствовали, и можно заметить, что прямой метод это учитывает (нет маневра). Кроме того, в период времени $(780 < t < 830)$ имел место плавный маневр (см. кривую рыскания), и можно также заметить, что прямой метод это учитывает (плавный маневр). Тем не менее следует иметь в виду, что прямой метод не всегда обеспечивает корректные результаты. Например, в момент времени $(t \approx 900)$ можно заметить, что маневр отсутствует, но прямой метод указывает на наличие плавного маневра.




Рис. 6. Результаты, полученные прямым методом




Рис. 7. Результаты, полученные двухшаговым методом




Рис. 8. Результаты, полученные двухшаговым методом с нелинейной базисной функцией

Из рис. 7 и 8, на которых соответственно представлены результаты применения двухшагового метода и двухшагового метода с нелинейной базисной функцией, видно, что, как и в прямом методе, для периодов времени ($t < 220$), ($680 < t < 780$), ($t > 830$) и ($780 < t < 830$) классы показаны корректно. Вместе с тем, в отличие от алгоритма прямого метода в момент времени ($t \approx 900$), эти два метода правильно указывают на отсутствие маневра. Тем не менее эти два метода тоже не всегда обеспечивают корректные результаты. Например, в момент времени ($t \approx 790$) имеет место плавный маневр, но по результатам двухшагового метода маневр отсутствует. В целом можно отметить, что двухшаговый метод с применением нелинейной базисной функции более чувствителен к изменениям при маневрировании, чем остальные методы (например, ($650 < t < 680$) и ($810 < t < 830$)). Несмотря на это, сравнение трех методов указанным способом не дает эффективных результатов. По этой причине, чтобы обеспечить эффективность предложенных алгоритмов, было сделано 3500 произвольных выборок и результаты предложенных методов были проверены в ручном режиме для каждой выборки. На этом этапе необходимо определить значение потерь (0 или 1), которое равно 1 только при очень резком маневре, но предложенный алгоритм на это не указывает. Для оценки каждого из описанных методов вводится определение процента потерь, то есть доли выборок, для которых значение потерь равно 1, и определение процента удач, то есть доли выборок, для которых алгоритм дает правильный результат. Процент удач и процент потерь для предлагаемых методов представлены в табл. 2.

Т а б л и ц а 2

Результаты для предложенных методов

Предлагаемый алгоритм	Процент удач	Процент потерь
Прямой метод	89,41%	1,05%
Двухшаговый метод	87,56%	0,7%
Двухшаговый метод с нелинейной базисной функцией	92,46%	0,39%

Результаты, представленные в табл. 2, подтверждают эффективность предложенных методов. При этом очевидно, что третий метод (двухшаговый метод с нелинейной базисной функцией) обеспечивает наилучшие результаты: процент удач в нем составляет 92,46%, а процент потерь – 0,39%. Кроме того, было установлено, что время, необходимое для принятия решения и выбора соответствующего класса для каждой новой выборки в среде Matlab 2015-а на ПК (i7, RAM 8ГБ), составляет не более 1,5 мс, то есть значительно меньше, чем время выборки (16 мс). Следовательно, можно говорить о том, что предлагаемый алгоритм может использоваться в онлайн-режиме.

Вывод и рекомендации

В настоящей работе представлен новый онлайн-алгоритм для классификации интенсивности маневров подвижного объекта с шестью степенями свободы ме-

тодом логистической регрессии с помощью методов главных компонент и машинного обучения. Предлагаемый алгоритм строится с использованием нелинейной базисной функции (квадратичной функции) в два этапа. На первом этапе выполняется классификация по наличию/отсутствию маневра (да/нет) по данным гироскопических датчиков угловой скорости. Второй этап выполняется в том случае, если на первом было определено наличие маневра, который классифицируется по интенсивности (плавный/резкий) на основании данных акселерометров. Моделирование с использованием результатов реальных экспериментов с БЛА подтвердило эффективность предложенного алгоритма и его пригодность для построения соответствующей экспериментальной модели поведения за счет обучения классификатора на имеющихся априорных данных и применения полученных результатов к новым данным, которые до этого не обрабатывались в режиме онлайн. При этом получены приемлемые значения для соотношения удач и потерь. По мнению авторов, предложенный алгоритм подходит для широкого спектра применений.

По результатам исследования сформулированы рекомендации по двум основным направлениям. Первое из них касается повышения процента удач и уменьшения процента потерь, для которых рекомендуется использовать другие нелинейные базисные функции (или их сочетания) или другие методы машинного обучения. Второе – расширение набора классов, например добавление класса для очень резких маневров, которые могут привести к выходу из строя подвижного объекта. Для этого случая описываемый алгоритм можно назвать алгоритмом выявления неисправностей. Еще один способ расширить набор классов – добавить класс для констатации неподвижности объекта. В этом случае мы будем говорить об алгоритме обнаружения нулевого движения, который может применяться при выставке инерциальной навигационной системы.

В заключение следует отметить, что предлагаемый алгоритм был успешно реализован на нескольких наборах реальных данных и подтвердил свою эффективность.

Приложение.

Классификация методом логистической регрессии

В основе метода логистической регрессии лежит принцип вычисления апостериорной вероятности при допущении, что $\logit$ – натуральный логарифм отношения правдоподобия – является линейной функцией [7, 16].

Можно использовать подход, в котором моделируются условные вероятности классов, заданные $P(\mathbf{x}|C_i)$, а также априорные вероятности $P(C_i)$ для классов C_i , после чего искомые апостериорные вероятности $P(C_i|\mathbf{x})$ могут быть вычислены по теореме Байеса в следующем виде [11, 12]:

$$P(C_i|\mathbf{x}) = \frac{P(\mathbf{x}|C_i)P(C_i)}{P(\mathbf{x})}, \quad P(\mathbf{x}) = \sum_{k=1}^K P(\mathbf{x}|C_k)P(C_k). \quad (\text{П-1})$$

Рассмотрим сначала случай двух классов, то есть $k=2$. Апостериорную вероятность для класса C_1 можно записать как [11, 12]

$$P(C_1|\mathbf{x}) = \frac{P(\mathbf{x}|C_1)p(C_1)}{P(\mathbf{x}|C_1)P(C_1) + P(\mathbf{x}|C_2)P(C_2)}, \quad (\text{П-2})$$

$$P(C_1 | \mathbf{x}) = \frac{1}{1 + \frac{P(\mathbf{x} | C_2)P(C_2)}{P(\mathbf{x} | C_1)P(C_1)}} = \frac{1}{1 + \exp(-a(\mathbf{x}))} = \sigma(a(\mathbf{x})), \quad (\text{П-3})$$

где

$$a(\mathbf{x}) = \ln \frac{P(\mathbf{x} | C_1)p(C_1)}{P(\mathbf{x} | C_2)p(C_2)} = \ln \frac{P(\mathbf{x} | C_1)}{P(\mathbf{x} | C_2)} + \ln \frac{P(C_1)}{P(C_2)}. \quad (\text{П-4})$$

При этом $\sigma(x) = \frac{1}{1 + \exp(-x)}$ является логистической сигмоидной функцией [11, 12]. В свою очередь, logit по определению представляет собой натуральный логарифм отношения правдоподобия, выраженного как $\left(\frac{P(C_1 | \mathbf{x})}{1 - P(C_1 | \mathbf{x})} \right)$, поэтому его можно записать следующим образом [11, 12]:

$$\begin{aligned} \text{logit}(P(C_1 | \mathbf{x})) &= \ln \frac{P(C_1 | \mathbf{x})}{1 - P(C_1 | \mathbf{x})} = \\ &= \ln \frac{P(C_1 | \mathbf{x})}{P(C_2 | \mathbf{x})} = \\ &= \ln \frac{P(\mathbf{x} | C_1)p(C_1)}{P(\mathbf{x} | C_2)p(C_2)} = a(\mathbf{x}). \end{aligned} \quad (\text{П-5})$$

Вместе с тем, как говорилось выше, логистическая регрессия строится на допущении о том, что logit является линейной функцией, то есть $\text{logit}(P(C_1 | \mathbf{x})) = \mathbf{w}^T \mathbf{x} + w_0$.

Таким образом [11, 12],

$$a(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + w_0, \quad \text{где } w_0 = \ln \frac{P(C_1)}{P(C_2)}. \quad (\text{П-6})$$

Следовательно, используя уравнения (П-3) и (П-6), апостериорную вероятность можно записать в виде сигмоидной функции [11, 12]:

$$P(C_1 | \mathbf{x}) = \frac{1}{1 + \exp(-a(\mathbf{x}))} = \frac{1}{1 + \exp(-(\mathbf{w}^T \mathbf{x} + w_0))} = \sigma(\mathbf{w}^T \mathbf{x} + w_0). \quad (\text{П-7})$$

Логистическая регрессия определяет линейную границу между классами, что способствует процессу разделения на классы, которое может быть выполнено путем нахождения весовых коэффициентов $\mathbf{w} = (w_0, w_1, \dots, w_d)^T$ [11, 12].

Аналогичным образом логистическую регрессию легко обобщить для множества классов, количество которых составляет более двух ($K > 2$). У каждого класса имеется собственный вектор весов $\mathbf{w}_i$, и вероятность определяется через функцию Softmax (см. [11], стр. 254).

$$f_i(\mathbf{x}, \mathbf{w}_i) = P(C_i | \mathbf{x}, \mathbf{w}_i) = a(\mathbf{w}_i^T \mathbf{x}), \quad 1 \leq i \leq K, \quad (\text{П-8})$$

$$a(\mathbf{w}_i^T \mathbf{x}) = \frac{\exp(\mathbf{w}_i^T \mathbf{x})}{\sum_{k=1}^K \exp(\mathbf{w}_k^T \mathbf{x})} = \text{Softmax}(\mathbf{w}_i^T \mathbf{x}). \quad (\text{П-9})$$

При недостаточной гибкости линейной модели можно добавить нелинейные базисные функции $\Phi(\mathbf{x})$, например ($\sin$, $\log$, $\exp$, $\sqrt{x}$, x^2 , ...), при этом апостериорная вероятность будет также определяться через функцию Softmax [11, 12]:

$$f_i(\mathbf{x}, \mathbf{w}_i) = P(y = C_i | \mathbf{x}, \mathbf{w}_i) = a(\mathbf{w}_i^T \Phi(\mathbf{x})), \quad 1 \leq i \leq K, \quad (\text{П-10})$$

$$a(\mathbf{w}_i^T \Phi(\mathbf{x})) = \frac{\exp(\mathbf{w}_i^T \Phi(\mathbf{x}))}{\sum_{k=1}^K \exp(\mathbf{w}_k^T \Phi(\mathbf{x}))} = \text{Softmax}(\mathbf{w}_i^T \Phi(\mathbf{x})). \quad (\text{П-11})$$

Логистическая регрессия используется для обучения с учителем. В случае двух классов $\{C_0, C_1\}$ это означает, что для заданного обучающего набора $\mathbf{x} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$ классы ассоциируются с заданными значениями

$$\mathbf{t} = \{t_1, t_2, \dots, t_N\}, \text{ где } t_n = \begin{cases} 1 & \text{if } \mathbf{x}_j \in C_1 \\ 0 & \text{if } \mathbf{x}_j \in C_0 \end{cases}, \quad 1 \leq n \leq N.$$

Эти заданные значения определяются специалистами в ручном режиме только для обучающего набора данных. Оптимизация весовых коэффициентов осуществляется путем минимизации *кросс-энтропийной* функции ошибок $E(\mathbf{w} \setminus \mathbf{x})$ [12] для обучающего набора. Для случая двух классов данную функцию можно записать в виде

$$E(\mathbf{w} \setminus \mathbf{x}) = - \sum_{n=1}^N \{t_n \ln y_n + (1 - t_n) \ln (1 - y_n)\}, \quad (\text{П-12})$$

где $y_n = \sigma(\mathbf{w}^T \mathbf{x}_n + w_0)$. Для решения уравнения (П-12) необходимо воспользоваться итерационными методами оптимизации. Наиболее распространенным из таких методов является стохастический градиентный спуск, или последовательный градиентный спуск (см. [11], стр. 206). Градиент кросс-энтропийной функции ошибок $\nabla_{\mathbf{w}} E(\mathbf{w} \setminus \mathbf{x})$ (13) принимает вид:

$$\nabla_{\mathbf{w}} E(\mathbf{w} \setminus \mathbf{x}) = \sum_{n=1}^N \nabla_{\mathbf{w}} E(\mathbf{w} \setminus \mathbf{x}_n) = \sum_{n=1}^N (y_n - t_n) \mathbf{x}_n. \quad (\text{П-13})$$

Таким образом, с помощью последовательного градиентного спуска можно получить оптимизированные весовые коэффициенты

$$\mathbf{w}^{(\tau+1)} = \mathbf{w}^{(\tau)} - \eta \nabla_{\mathbf{w}} E_{\mathbf{w}}(\mathbf{w} \setminus \mathbf{x}), \quad (\text{П-14})$$

где τ – номер итерации, а η – параметр скорости обучения. Уравнение (П-14) можно обобщить для случая множества классов, используя при этом следующие кросс-энтропийные функции ошибок:

$$E(\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_K \setminus \mathbf{x}) = - \sum_{n=1}^N \sum_{k=1}^K t_{nk} \ln y_{nk}, \quad (\text{П-15})$$

где $y_{nk} = \text{Softmax}(\mathbf{w}_k^T \Phi(\mathbf{x}_n) + w_0)$, а $t_{nk} = \begin{cases} 1 & \text{if } \mathbf{x}_n \in C_k \\ 0 & \text{if } \mathbf{x}_n \notin C_k \end{cases}$. Таким образом, с по-

мощью последовательного градиентного спуска могут быть получены оптимизированные весовые коэффициенты:

$$\mathbf{w}_k^{(\tau+1)} = \mathbf{w}_k^{(\tau)} - \eta \nabla_{\mathbf{w}_k} E(\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_K \setminus \mathbf{x}) \quad 1 \leq k \leq K. \quad (\text{П-16})$$

ЛИТЕРАТУРА

1. **Stengel, R.**, Aircraft Flight Dynamics, Princeton University, 2014.
2. **Triantafyllou, M.S., Hover, F.S.**, Maneuvering and control of marine vehicles, Cambridge, Massachusetts, USA: edited by authors, 2003.
3. **Oza, N.C., Tumer, K., Tumer, I.Y., Hu, E.M.**, Classification of aircraft maneuvers for fault detection, in: International Workshop on Multiple Classifier Systems, Springer, 2003, pp. 375–384.
4. **Tumer, I.Y., Hu, E.M.**, Principal components analysis of triaxial vibration data from helicopter transmissions, Society for Machinery Failure Prevention Technology, 2001.
5. **Stojakovic, P., Rasuo, B.**, Single propeller airplane minimal flight speed based upon the lateral maneuver condition, Aerospace Science and Technology, Elsevier, vol. 49, 2016.
6. **Larry, E.S.I., Croyle S.R.**, Zero motion detection system for improved vehicle navigation system, uS Patent 5,991,692 (Nov. 23 1999).
7. **Bishop, C.**, Pattern Recognition and Machine Learning, Springer, New York, 2006.
8. **Jurafsky, D., Martin, J.H.**, Speech and Language Processing, Classification: Naive Bayes, Logistic Regression, Sentiment, Pearson, 2014, Ch. 7.
9. **Kay, S.M., Nuttall, A.H., Baggenstoss, P.M.**, Multidimensional probability density function approximations for detection, classification, and model order selection, Signal Processing, IEEE Transactions on, IEEE, vol. 49, 2001.
10. **Mitchell, M.H.T.M.**, Machine Learning, 2nd Edition, Spring, 2015, Ch. 3.
11. **Alpaydin, E.**, Introduction to Machine Learning, third edition Edition, MIT Press, 2014.
12. **Paalanen, P.**, Bayesian classification using Gaussian mixture model and EM estimation: Implementations and comparisons, Information Technology Project, 2004.
13. **Jordan, A.**, On discriminative vs. generative classifiers: A comparison of logistic regression and naive bayes, Advances in neural information processing systems, vol. 14, 2002.
14. **Park, H.-A.**, An Introduction to Logistic Regression: From Basic Concepts to Interpretation with Particular Attention to Nursing Domain, J Korean Acad Nurs, Korean Society of Nursing Science, 2013.
15. **Jiang, Chengyu, Xue, Liang, Chang, Honglong, Yuan, Guangmin, and Yuan, Weizheng**, Signal Processing of MEMS Gyroscope Arrays to Improve Accuracy Using a 1st Order Markov for Rate Signal Modeling, Sensors, 2012.
16. **Shitikov, V.K., Mastitskii, S.E.**, Classification, Regression, and Other Data Mining Algorithms Using R, Togliatti, London, 2017. (**Шитиков В.К., Мастицкий С.Э.** Классификация, регрессия и другие алгоритмы Data Mining с использованием R. Тольятти, Лондон, 2017. 351 с. Электронная книга, URL: <https://github.com/ranalytics/data-mining>.)
17. **Crossbow technology, inc**, AHRS 400CC User's Manual, Document Part Number: 6020-0025-01, web : www.xbow.com.

Al Mansour M., Chouaib I., Jafar A. (Higher Institute for Applied Sciences and Technology (HIAS), Damascus, Syria).

Maneuver Classification of a Moving Vehicle with Six Degrees of Freedom Using Logistic Regression Technique. *Giroskopiya i Navigatsiya*. 2018. Vol. 26. No. 2 (101). P. 43–58.

Abstract. This paper presents a novel on line algorithm for maneuver classification of a moving vehicle with six degrees of freedom, using on-board MEMS IMU's data (three accelerometers and three rate gyros). The classification is either discrete (i.e. high, low or no maneuver), or continuous (a value that reflects the intensity of the maneuver). It should be mentioned that there is no explicit solution for this problem in any research paper previously published, due to the inability to find a direct mathematical model capable of characterizing this problem, despite its importance and its impact in improving the functioning of navigation systems.

The proposed algorithm is based on a machine learning technique called logistic regression, which is a discriminative probabilistic classification model. Computer simulations, using MEMS IMU's data taken from real experiments of an UAV, showed the effectiveness of the proposed algorithm, taking into account the sampling time, and the suitability for a wide spectrum of applications.

Key words: maneuvers, machine learning, statistical classifiers, logistic regression, principal component analyses, UAV.

Материал поступил 28.09.2017.