

УДК 629.053

ПРОБЛЕМЫ РАСПОЗНАВАНИЯ ОБРАЗОВ СЛОЖНЫХ ФИЗИЧЕСКИХ ЯВЛЕНИЙ В МНОГОМЕРНЫХ ВРЕМЕННЫХ РЯДАХ С ИСПОЛЬЗОВАНИЕМ ТЕХНОЛОГИЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

М.В. Желонкин

Центральный аэрогидродинамический институт имени профессора Н.Е. Жуковского (ФАУ «ЦАГИ»)
Россия, 140180, Московская область, Жуковский, ул. Жуковского 1
E-mail: mikhail.zhelonkin@tsagi.ru

С.А. Ковтун

Центральный аэрогидродинамический институт имени профессора Н.Е. Жуковского (ФАУ «ЦАГИ»)
Россия, 140180, Московская область, Жуковский, ул. Жуковского 1
E-mail: mikhail.zhelonkin@tsagi.ru

Ключевые слова: самолет, интеллектуальная система, машинное обучение, многомерные временные ряды, искусственный интеллект.

Аннотация: Выполнено описание проблемы распознавания образов сложных физических явлений на основе анализа временных рядов движения самолета. На сложных режимах полета или при отказах оборудования возникает необходимость быстрого анализа большого числа параметров для построения вывода и корректной оценки ситуации. Мониторинг и диагностика состояния систем и процессов: разработка методов и алгоритмов анализа данных, характеризующих состояние наблюдаемого объекта в реальном масштабе времени, автоматическое соотнесение текущего состояния объекта с набором его эталонных состояний. Обнаружение аномального поведения в функционировании систем ЛА.

1. Введение

Задача обнаружения паттерна нежелательного процесса может быть формализована, как задача бинарной классификации, когда временные отсчеты, соответствующие искомому паттерну, размечаются как «1», а все остальные «0», разметка определяется с помощью экспертных знаний о поведении ЛА на больших углах атаки. Данные могут быть получены экспериментально с помощью полунатурного или математического моделирования [5, 6]. Ставится задача нахождения параметрической функции (или композиции функций), такой, что выход данной функции пропорционален вероятности p принадлежности входного вектора или тензора к классу, размеченному, как «1», соответственно $1-p$, является вероятностью принадлежности входного объекта к классу «0». В рассматриваемой задаче присутствуют 2 возможных класса, размечаемых, например, как {сваливание, не сваливание} = {1, 0}. При этом подразумевается наличие достаточно большой выборки размеченных примеров. Иными словами, ставится задача параметризации распределения Бернулли на имеющейся выборке данных. Такая задача в указанной

постановке является классической задачей машинного обучения – бинарной классификацией.

2. Задача бинарной классификации применительно к временным рядам для распознавания процесса сваливания

Для такой задачи может быть использован градиентный бустинг над решающими деревьями или различные виды искусственных нейронных сетей (НС). Градиентный бустинг требует ручного создания признаков и в случае с многомерными рядами легко переобучается, поэтому за базовый алгоритм лучше принять хорошо зарекомендовавшую себя на практике для классификации временных рядов НС. TCN (Temporal Convolutional Network), хорошо зарекомендовавшая себя в задачах моделирования последовательностей. Базовая архитектура TCN [1] при практической реализации модифицирована в соответствии со спецификой задачи.

В архитектуре TCN используется одномерная расширенная свертка с экспоненциально растущим рецептивным полем (Dilated Causal Convolution). Основной особенностью расширенной свертки является заполнение нулями ядра свертки между ненулевыми элементами, при этом расстояние между соседними ненулевыми элементами ядра называется расширением (dilation), при расширении равном 1, расширенная свертка вырождается в обычную. Такой алгоритм свертки позволяет увеличить рецептивное поле без потери информации, при тех же затратах на вычисления, при этом существенно сократив число оптимизируемых параметров. Расширенная свертка с одномерным ядром может быть представлена выражением:

$$(\mathbf{x} *_{d} \mathbf{K})(s) = \sum_{i=0}^{k-1} \mathbf{K}(i) \mathbf{x}_{s-di},$$

где \mathbf{x} – срез входного тензора, \mathbf{K} – ядро свертки, k – размер ядра свертки, d – степень расширения. Слои с расширенной сверткой реализуются каскадом, при этом степень расширения выбирается $d = 2^n$, где n – номер слоя. Модель состоит из 3 последовательно соединенных блоков, при этом каждый блок включает в себя 2 слоя расширенной свертки с нормализацией весов (Weight Norm) [2] и регуляризацией прореживанием (Dropout) [3].

Прореживание является распространенной техникой для регуляризации (борьбы с переобучением на тестовом наборе) нейронных сетей, при применении прореживания к слою нейронной сети во время обучения генерируется бинарная маска, случайным образом обнуляющая веса слоя с некоторой вероятностью p . Основная идея заключается в обучении ансамбля сетей вместо одной с последующим усреднением полученных результатов. Применения прореживания можно интерпретировать, как измененную функцию активации слоя:

$$f(\mathbf{x}) = \mathbf{D} \odot g(\mathbf{x}),$$

где \mathbf{D} – матрица случайных величин, распределенных по закону Бернулли, $g(\mathbf{x})$ – исходная функция активации слоя. В процессе прохождения входного тензора через сверточные слои, его размер вдоль измерения, по которому осуществляется свертка будет уменьшаться, для сохранения размера, осуществляется нормализация карты признаков за счет присоединения тензоров, содержащих нули. В случае если размер входа и выхода отличается после нормализации, то размер выходной карты признаков корректируется с помощью дополнительного сверточного слоя с единичным ядром. Эквивалентная размерность входа и выхода необходима для реализации остаточного соединения (Residual Connection) [4]. Остаточное соединение может быть описано формулой:

$$\mathbf{x}_{n+1} = \mathbf{x}_n + F(\mathbf{x}, \boldsymbol{\theta}),$$

где \mathbf{x}_n – вход блока, $F(\mathbf{x}, \boldsymbol{\theta})$ – реализуемое блоком преобразование. Остаточные соединения являются эффективным способом борьбы с затуханием градиентов в глубоких нейронных сетях и показали свою эффективность в архитектурах ResNet.

Структурная схема блока представлена на рис. 1.

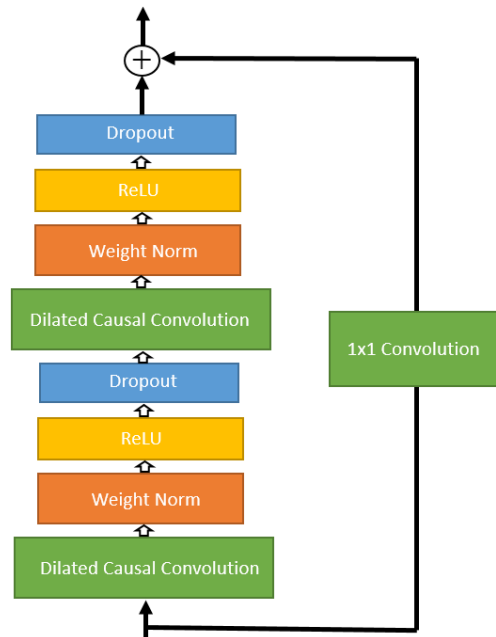


Рис. 1. Схематическое изображение структурного блока TCN.

В качестве функции активации скрытых слоев структурного блока используется функция линейной ректификации (Rectified Linear Unit) ReLU, определяемый выражением:

$$\text{ReLU}(x) = \max\{0, x\}.$$

В выходном слое для перевода карты признаков, полученной в результате применения сверточных слоев в вероятность используется сигмоидальная функция, определяемая выражением:

$$\sigma(x) = \frac{1}{1+e^{-x}}$$

Данная функция характерна тем, что выход $\sigma(x) \in (0,1)$.

3. Обнаружение сваливания для известной модели динамики ЛА

Пример моделирования движения ЛА с выходом на большие углы атаки с переходом в сваливание представлен на рис. 2. С целью получения разнообразной выборки, содержащей большее количество различных признаков и повышения статистической достоверности эксперимента, при моделировании варьировались следующие начальные условия:

- высота;
- индикаторная скорость;
- центровка ЛА.




Рис. 2. Пример моделирования движения ЛА с выходом на большие углы атаки.

Всего было выполнено более 300 моделирований, каждое длительностью 2-3 минуты.

В процессе моделирования регистрировались следующие параметры:

- угол тангажа ϑ , угол рысканья ψ , угол крена γ ;
- угол атаки α , угол скольжения β ;
- угловые скорости крена, рысканья и тангажа: $\omega_x, \omega_y, \omega_z$;
- производные угловых скоростей крена, рысканья и тангажа: $\dot{\omega}_x, \dot{\omega}_y, \dot{\omega}_z$;
- вертикальная скорость V_y ;
- производная угла атаки $\dot{\alpha}$;
- нормальная перегрузка n_y .

Обучение модели выполнялось с помощью алгоритма оптимизации ADAM

Согласно оценкам, полученным на модельной задаче, удается распознать сваливание в среднем за 3 секунды до начала потери управляемости. Можно утверждать, что технология демонстрирует работоспособность и может быть рассмотрена в дальнейшем для модели динамики сверхзвукового пассажирского самолета.

Список литературы

1. Гудфеллоу Я., Бенджио И., Курвилль А. Глубокое обучение. М.: ДМК Пресс, 2018. 652 с.
2. Bai S., Kolter J.Z., Koltun V. An Empirical Evaluation of Generic Convolutional and Recurrent Networks for Sequence Modelling. arXiv:1803.01271v2 [cs.LG], 2019.
3. Salimans T., Kingma D.P. Weight normalization: A simple reparametrization to accelerate training of deep neural networks. NIPS, 2016.
4. Srivastava N., Hinton G.E., Krizhevsky A., Sutskever I., Salakhutdinov R. Dropout: a simple way to prevent neural networks from overfitting // JMLR. 2014. Vol. 15, No. 1.
5. Ковтун С.А., Желонкин М.В. Интеллектуальная система поддержки экипажа. Обработка входных сигналов // XVI Всероссийская мультikonференция по проблемам управления (МКПУ-2023). Материалы мультikonференции. В 4-х томах / Редколлегия: И.А. Каляев, В.Г. Пешехонов, С.Ю. Желтов и др. Волгоград, 2023. С. 194-195
6. Желонкин М.В., Кадильникова Е.Н., Ковтун С.А. Интеллектуальная система поддержки экипажа в сложных условиях. Проблемы и пути решения // Фундаментальные проблемы создания СПС нового поколения. Сборник тезисов международной конференции. М.: 2022. С. 208-210.