

Индустриальные приложения методов классификации временных рядов: обнаружение повреждений дорожного полотна

Е.В.Бурнаев^{*,**}

^{*} Сколковский институт науки и технологий, Москва, Россия

^{**} Институт проблем передачи информации, Российская академия наук
e-mail: e.burnaev@skoltech.ru

Поступила в редколлегию 01.06.2020

Аннотация—Для безопасного вождения важно поддерживать дорожное покрытие в хорошем состоянии. Мониторинг состояния дорожного покрытия является трудоемким и требует специальных знаний. Ситуация ухудшается тем, что процедура мониторинга должна повторяться с относительно высокой частотой. Соответственно, требуется автоматизация данного процесса. Существуют методы детекции и классификации повреждений дорожного полотна, которые основаны на использовании методов компьютерного зрения. Однако, обучение соответствующих предиктивных моделей требует наличия размеченной выборки фотографий значительного размера. Более того, требуется установка на машину специализированного оборудования для проведения съемки. В данной работе мы оцениваем возможность решения поставленной задачи на основе обработки данных с акселерометра автомобиля. В качестве инструмента для построения предиктивной модели используются методы классификации временных рядов на основе машинного обучения.

КЛЮЧЕВЫЕ СЛОВА: система мониторинга, обнаружение аномалий, машинное обучение, предсказательное техническое обслуживание, обработка сигналов.

1. ВВЕДЕНИЕ

На дорогах общего назначения с интенсивным транспортным потоком, расположенных в областях с неустойчивой и резко меняющейся погодой, происходит быстрое изнашивание дорожного полотна. Для отслеживания повреждений полотна обычно используются полуавтоматические или даже “ручные” методы. Стоимость и трудоемкость процедуры сбора данных о состоянии полотна возрастают еще и потому, что требуется выполнять сбор данных относительно часто, чтобы иметь актуальную информацию о состоянии дорожной сети.

В данной работе рассматривается задача выявления и классификации типа повреждения дорожного покрытия по данным акселерометра, установленного на автомобиле. Основная идея заключается в том, что ускорение автомобиля изменяется, когда дорога повреждена (например, амплитуда колебаний автомобиля при движении на поврежденной дороге повышается, или же происходит резкое изменение компонент ускорения, когда водитель пытается объехать поврежденный участок дороги). Соответственно, по такому изменению данных с акселерометра потенциально можно детектировать наличие повреждения и его тип. Данный подход легко реализовать на практике, поскольку на многих современных автомобилях установлены акселерометры. Значит, не требуется установка какого-либо специализированного оборудования, и основная трудность в реализации такого подхода состоит в построении предиктивной модели, способной выделять паттерны в данных акселерометра, надежно свидетельствующие о наличии повреждений.

Для построения предиктивной модели требуется провести тестовые измерения, в ходе которых необходимо собрать данные с акселерометров легковых автомобилей, которые проезжают в обычном режиме по выделенным дорогам общего пользования. Также, для этих измерений требуется выделить координаты траектории, соответствующие положениям повреждений на дорожном полотне, и соответствующие моменты времени, в которые происходил наезд на эти повреждения (разметка данных в виде «есть повреждение/нет повреждения»). В таком случае, по данным акселерометра, представленным в виде временных рядов, можно было бы подсчитать признаки, позволяющие обнаруживать повреждения, и, используя предоставленную разметку, обучить классификационную модель для детектирования повреждений.

В результате проведения тестовых измерений были получены два типа данных: данные лидара и данные акселерометра. Эти наборы данных были собраны независимо, с автомобилями двух видов: один вид автомобилей — специализированные автомобили, оснащенные лидарами; другой вид автомобилей — стандартные легковые автомобили, с акселерометров которых собирался второй тип данных. При этом проезды этих видов автомобилей, в силу различных организационных причин, в некоторых случаях происходили по разным дорогам. Тем не менее, есть определенный процент дорог, на которых были произведены измерения обоих типов данных — собраны данные с лидаров автомобилей первого вида, и собраны данные с акселерометров автомобилей второго вида. Такая особенность сбора данных как раз связана с тем, что сбор данных с акселерометров довольно легко организовать и возможно использование широкого спектра легковых автомобилей для этой задачи, при этом автовладельцы продолжают использовать свои личные транспортные средства в обычном режиме.

Данные лидара сопровождаются 3D-моделью дорожного полотна, построенной на основе полученных измерений. Этот набор данных можно использовать для того, чтобы по некоторым дорогам получить разметку повреждений. В использованной в данной работе выборке для некоторых дорог вручную была произведена разметка повреждений по построенным 3D-моделям дорожного полотна.

Задача состоит в том, чтобы определить дорожные повреждения на основе показаний акселерометра. При этом для данных акселерометра разметка отсутствует, то есть не известно, в какой момент какая из машин проезжала то или иное место с повреждением дорожного полотна. Единственные данные, в которых есть информация о повреждениях — это данные лидара, но они были получены при проведении заездов специализированных машин. Таким образом, требуется решение двух подзадач:

1. Сопоставить координаты областей с повреждениями полотна на ортофотоснимках (3D модель) с траекториями движения транспортных средств, которые производят измерение данных с акселерометров, чтобы сформировать набор данных для решения задачи обучения с учителем — задачи классификации,
2. Применить методы классификации временных рядов для идентификации дорожных повреждений на основе построенного набора размеченных данных.

В литературе задача обнаружения повреждений дорожного полотна уже рассматривалась. Большинство подходов можно отнести к одной из следующих групп:

- Анализ 3D данных: использование стерео изображений [1] или лидарных данных для обнаружения повреждений [2],
- Анализ данных о вибрации: использование акселерометров или гироскопов [3, 4], установленных на автомобиле,
- Анализ изображений: подход к обнаружению повреждений на основе обработки изображений, полученных с камеры смартфона, с помощью глубоких сверточных нейросетей [5–7].

Отметим, что для сбора 3D данных требуется специализированное оборудование, поэтому этот подход можно применять лишь ограниченно, например, для верификации полученных результатов прогнозов, или для получения разметки измерений, собранных сенсором другого типа.

Основной недостаток подхода на основе анализа изображений в том, что требуется большое количество изображений с размеченными повреждениями, при этом модель для детекции повреждений получается достаточно чувствительной к ложным срабатываниям — например, в некоторых случаях тени могут классифицироваться как те или иные типы повреждений. Более того, для дорог в других областях/странах требуется повторный сбор данных, так как модели на основе компьютерного зрения зачастую могут быть весьма чувствительными к изменению фона, на котором производится съемка изображений.

Подход на основе анализа данных о вибрациях — самый экономически выгодный, поскольку фактически не требуется установка специализированных сенсоров. Задачу обнаружения повреждений дорожного полотна можно рассматривать как задачу обнаружения аномалий во временных рядах (показания акселерометра) [8–13]. Однако, использование такого рода методов зачастую приводит к значительной доле ложных тревог в прогнозах, что недопустимо в рассматриваемом приложении. По этой причине, требуется использование методов классификации. Однако, в рассматриваемом подходе затруднена разметка данных — вручную сложно выделить, в какие именно периоды времени происходил наезд автомобиля на поврежденные области дорожного полотна, отсчитывая показания акселерометра. Таким образом, чтобы преодолеть указанную трудность, данная работа комбинирует подход на основе анализа данных о вибрациях, с разметкой, которая получается за счет анализа 3D данных.

Работа имеет следующую структуру. В разделе 2 приводится описание собранных данных. В разделе 3 описывается построение модели классификации. В разделе 4 обсуждаются полученные результаты, в заключении в разделе 5 — делаются выводы из проделанной работы.

2. ОПИСАНИЕ ДАННЫХ

2.1. Данные акселерометра

Данные акселерометра содержат записанные события для различных транспортных средств. Каждое событие содержит несколько секунд показаний (a_x, a_y, a_z) акселерометра, установленного на транспортное средство (3-мерный временной ряд), см. рис. 1.

Каждое событие было получено с помощью следующей процедуры:

1. Когда скорость транспортного средства превышает 10 км/ч, система записывает окно длиной 1.28 с с значениями a_z (128 отсчетов);
2. Подсчитывается статистика (1) по данным в окне и сохраняется в памяти до тех пор, пока размер подсчитанных данных не составит 401 элемент:

$$s_i = (a_z[i])^4, \quad r = \sqrt{\frac{1}{128} \sum_{i=1}^{i=128} s_i^2}. \quad (1)$$

3. В качестве порога используется 50%-квантиль массива значений r ;
4. Если для нового окна значение r больше порогового, тогда данные в этом окне сохраняются;
5. Последовательности окон без значительных промежутков собираются в наборы данных, называемых “событиями”.




Рис. 1. Пример данных акселеромента для 3 разных окон (каждый цвет обозначает одно окно)




Рис. 2. Визуализация ортофотоснимков.

2.2. Данные лидара


Данные лидара содержат ортофотоснимки¹ и 3D-модель² дороги, построенную на основе полученных измерений. В целом, с помощью этого набора данных возможно построение разметки. Действительно, некоторые ортофотоснимки содержат метки о наличии тех или иных типах повреждений дорожного покрытия. Однако, значительная сложность связана с тем, что специализированные машины с установленными на них лидарами малочисленны, при этом данные с акселерометра получены с обычных автомобилей рядовых граждан, которые участвовали в эксперименте. Более того, автомобили с лидарами и с акселерометрами ездили по разным дорогам в разные дни, то есть нет гарантии, что для координат GPS, которые соответствуют тем или иным измерениям с акселерометра, известны также и ортофотоснимки с наложенными на них метками о повреждениях.

3. ПОСТРОЕНИЕ МОДЕЛИ КЛАССИФИКАЦИИ

Поскольку заранее неизвестно, какие именно признаки наиболее важны для решения задачи, то для построения предиктивной модели предлагается использовать методы на основе деревьев классификации, поскольку они не зависят от масштабов значений признаков, и, в отличие от ядерных методов классификации, от выбора типа расстояния между объектами в пространстве признаков и плотности заполнения выборкой признакового пространства.

¹ Ортофотоснимки — это искусственно созданные фотографии участков дорожного покрытия, сопровождаемые GPS-координатами и информацией об угле поворота сенсора относительно дороги.

² модель CRG (Curved Regular Grid) — это подробное описание дорожного покрытия, содержащее GPS координаты дороги, кривизну и высоту каждого участка дороги, и т.д. (см. <http://www.opencreg.org/>)



(а) 2D визуализация CRG модели в исходных координатах. Цвет кодирует высоту поверхности дороги.

(б) 3D визуализация поверхности дороги в оригинальных xyz -координатах. Цветом закодирована высота поверхности дороги.

Рис. 3. Визуализация модели CRG.

В целом, методы на основе деревьев решений разбивают признаковое пространство объектов на набор гиперпараллелипипедов, а затем в каждом из них строят простую модель прогноза, например, прогноз константой (см. [14], раздел 9.2). Так как число примеров разных классов не сбалансированно, мы также использовали методы несбалансированной классификации [15, 16].

3.1. Выравнивание интервалов

Интервалы событий, обнаруженные рядом с повреждением дороги, объединяются в наборы интервалов. Затем для интервалов в каждом наборе происходит выравнивание в два этапа.

Во-первых, мы выполняем грубое выравнивание интервалов на основе расстояния до повреждения дороги (см. пример на рис. 4).

Во-вторых, мы точно настраиваем выравнивание на основе локальных максимумов a_z в пределах 10 метров от повреждения дороги (см. пример на рис. 5).

3.2. Извлечение признаков из показаний акселерометра

Состояния системы представлены векторами признаков в каждый момент времени, эти векторы содержат агрегированную статистику показаний акселерометра за локальный интервал времени вокруг момента наезда на предполагаемое место повреждение дорожного покрытия.

В таблице 1 приведены шаблоны, определяющие признаки. Признаки порождаются для $w \in \{2, 10\}$ и $T \in \{a_x, a_z\}$.

3.3. Классификация на основе неточно размеченных данных

В данном разделе мы рассматриваем проблему неполных и неточных меток при решении задачи классификации (weakly supervised classification), когда метки есть в наличии только для небольшого подмножества данных и, кроме того, эти метки не всегда являются истинными. Следующие предположения будут мотивировать метод, используемый в данной работе:

- мы знаем подмножество данных, которые, возможно, связаны с повреждением дороги;




Рис. 4. Выравнивание данных акселерометра на основе расстояния до предполагаемого повреждения дороги. Цветами отмечены различные события.




Рис. 5. Выравнивание данных акселерометра на основе локальных максимумов a_z . Цветами представлены различные события.

Таблица 1. Признаки, извлекаемые из данных временных рядов.

Признаки	Описание
<code>lowpass_mean_abs_deviation_T_w</code>	Среднее абсолютное отклонение необработанного временного ряда T от его низкочастотного фильтрованного сигнала, рассчитанного в радиусе w метров от предполагаемого повреждения дороги.
<code>lowpass_max_abs_deviation_T_w</code>	Максимум абсолютных отклонений необработанного временного ряда T от его низкочастотного фильтрованного сигнала, рассчитанного в радиусе w метров от предполагаемого повреждения дороги.
<code>low_pass_amplitude_T_w</code>	Разница между максимальным и минимальным значением низкочастотного фильтрованного сигнала T на интервале в радиусе w метров от предполагаемого повреждения дороги.

– дорожные повреждения редко встречаются в остальных данных, поэтому случайный подбор из них, скорее всего, не будет связан с каким-либо дорожным повреждением.

Для решения задачи классификации повреждений по данным акселерометра мы применяем метод, который носит название Extremely Randomized Forest (ЕТ) классификатор [17]. Преимущество этого конкретного типа методов, основанного на деревьях решений, заключается в том, что ЕТ при выборе точек разделения для построения гиперпараллелепипеда способен




Рис. 6. Пример сопоставленных лидарных данных и данных с акселерометра

выбирать такие значения, которые могут и не присутствовать в обучающих данных. Тем самым повышается обобщаемая способность при обучении на зашумленных и малых наборах данных [18].

4. РЕЗУЛЬТАТЫ

В данном разделе мы рассмотрим результаты решения задач, описанных в разделе 1.

4.1. Построение выборки данных

Основным препятствием для сведения задачи обнаружения и классификации повреждений дорожного полотна к задаче машинного обучения является отсутствие размеченных событий наезда на место повреждения, которые были бы однозначно связаны с показаниями акселерометра. Поэтому в данном разделе мы сопоставили разметку дорожных повреждений с траекториями движения транспортных средств (и с ортофотоснимками для экспертной проверки).

Поскольку некоторые дорожные повреждения расположены очень близко друг к другу, мы агрегируем группы дорожных повреждений, которые находятся в пределах 1 м, и в итоге получаем 1107 различных групп.

Расстояние между геотегированными показаниями акселерометра составляет до 40 метров. Мы линейно интерполируем значения ширины и долготы во времени для других записей. Затем мы объединяем все события, проходящие вблизи дорожных повреждений в пределах 5 м, в группы и применяем процедуру выравнивания интервалов, описанную в разделе 3.1.

В итоге, мы получили 253 дорожных повреждения (из 1107) с по крайней мере 2 событиями, произошедшими рядом с ними. В среднем же по каждому из них происходит 6.67 события. На рис. 4.1 приведен пример сопоставленных данных. Основываясь на экспертном анализе примеров, мы также агрегируем типы повреждений (метки в исходной терминологии) в классы повреждений для того, чтобы в каждом классе было значимое количество примеров событий:

Таблица 2. Свойства построенного набора данных.

Класс	Описание	Число уникальных меток	Число правильных событий в пределах 5м от повреждения
1	Тонкие поперечные полосы на дороге	57	788
2	Трещины	59	495
3	Дорожная разметка	97	170
0	Случайный интервал, отобранный из всех событий	-	7714




Рис. 7. Кривые Precision-recall для разных классов.

- класс 1: метка (1, 4),
- класс 2: метки (3, 1) и (3, 2),
- класс 3: метки (6, 1) и (9, 2).

Наконец, мы добавляем случайно выбранные интервалы из всего набора данных, предполагая, что вероятность того, что они будут близки к повреждениям дороги, невелика. Поэтому мы помечаем их как класс 0. Свойства собранного набора данных показаны в таблице 2.

4.2. Обучение и валидация модели

В этом разделе мы применили метод классификации, описанный в разделе 3.3, для объектов, извлеченных из интервалов, собранных на предыдущем шаге используя метод из раздела 3.2.

Мы валидировали модель с помощью 10-кратной перекрестной валидации. Поскольку классы несбалансированы, мы оцениваем качество с помощью Precision-Recall кривых [19]. Результаты показаны на рис. 7. Мы также привели информацию о важности различных признаков на рис. 8.

5. ЗАКЛЮЧЕНИЕ

Достигнутая точность классификатора свидетельствует о наличии в данных акселерометра информации о классах дорожных повреждений. Отметим, что небольшое разнообразие классов может означать высокий риск переобучения — модель “запомнит” примеры повреждений, которые есть в обучающей выборке вместо того, чтобы выявить паттерны (в показаниях акселерометра, возникающие из-за дорожных повреждений), которые воспроизводятся и на других дорогах.




Рис. 8. Важность признаков для обученного классификатора.

Тем не менее, нынешняя точность не позволяет применять модель в промышленной практике:

- Отсутствие случаев покрытия типичных дорожных повреждений приводит к низкой обобщающей способности классификатора,
- Высокий уровень шума в данных из-за неточности акселерометра и процедуры совмещения меток и данных акселерометра:
 - GPS-измерения, синхронизированные с показаниями акселерометра, разрежены (расстояние до 40 м между измерениями),
 - Даже если бы измерения GPS были более частыми, колеса автомобиля могут не попасть непосредственно на область дороги, в которой у дорожного полотна есть повреждение, несмотря на то, что траектория движения автомобиля пересекает такие области.

Для повышения точность классификации требуется собирать более точные данные акселерометра непосредственно в моменты времени, когда автомобиль наезжает на области дороги с повреждениями дорожного полотна.

Е. Бурнаев выражает благодарность Е. Капушеву и Н. Ключникову за помощь в обработке данных, В. Волкову — за постановку задачи.

СПИСОК ЛИТЕРАТУРЫ

1. R. Fan and M. Liu. Road damage detection based on unsupervised disparity map segmentation. *IEEE Transactions on Intelligent Transportation Systems*, pages 1–6, 2019.
2. Shen-En Chen, Wanqiu Liu, Haitao Bian, and Ben Smith. *3D LiDAR Scans for Bridge Damage Evaluations*, pages 487–495.
3. Fergyanto Gunawan. Detecting road damages by using gyroscope sensor. *ICIC Express Letters*, 12:1089–1098, 11 2018.
4. Sattar S, Li S, and Chapman M. Road surface monitoring using smartphone sensors: A review. *Sensors (Basel)*, 18(11), 2018.
5. A. Alfarrarjeh, D. Trivedi, S. H. Kim, and C. Shahabi. A deep learning approach for road damage detection from smartphone images. *2018 IEEE International Conference on Big Data (Big Data)*, pages 5201–5204, 2018.
6. Andres Angulo, Juan Antonio Vega-Fernández, Lina Maria Aguilar-Lobo, Shailendra Natraj, and Gilberto Ochoa-Ruiz. Road damage detection acquisition system based on deep neural networks for physical asset management. In Lourdes Martínez-Villaseñor, Ildar Batyrshin, and Antonio Marín-Hernández, editors, *Advances in Soft Computing*, pages 3–14. Springer International Publishing, 2019.

7. Hiroya Maeda, Yoshihide Sekimoto, Toshikazu Seto, Takehiro Kashiya, and Hiroshi Omata. Road damage detection and classification using deep neural networks with smartphone images: Road damage detection and classification. *Computer-Aided Civil and Infrastructure Engineering*, 33, 06 2018.
8. A. Artemov, E. Burnaev, and A. Lokot. Nonparametric decomposition of quasi-periodic time series for change-point detection. In *Proc. SPIE*, volume 9875, pages 9875–9875–5, 2015.
9. A. Artemov and E. Burnaev. Detecting performance degradation of software-intensive systems in the presence of trends and long-range dependence. In *2016 IEEE 16th International Conference on Data Mining Workshops (ICDMW)*, pages 29–36, 2016.
10. D. Volkhonskiy, E. Burnaev, I. Nouretdinov, A. Gammerman, and V. Vovk. Inductive conformal martingales for change-point detection. In *Proceedings of the Sixth Workshop on Conformal and Probabilistic Prediction and Applications*, volume 60, pages 132–153. PMLR, 2017.
11. A. Safin and E. Burnaev. Conformal kernel expected similarity for anomaly detection in time-series data. *Advances in Systems Science and Applications*, 17(3):22–33, 2017.
12. A. Artemov and E. Burnaev. Ensembles of detectors for online detection of transient changes. In *Proc. SPIE*, volume 9875, pages 9875 – 9875 – 5, 2015.
13. D. Smolyakov, N. Sviridenko, E. Burikov, and E. Burnaev. Anomaly pattern recognition with privileged information for sensor fault detection. In *Artificial Neural Networks in Pattern Recognition*, pages 320–332. Springer, 2018.
14. Trevor Hastie, Robert Tibshirani, and Jerome Friedman. *The elements of statistical learning: data mining, inference and prediction*. Springer, 2 edition, 2009.
15. E. Burnaev, P. Erofeev, and A. Papanov. Influence of resampling on accuracy of imbalanced classification. In *Proc. SPIE*, volume 9875, pages 9875–9875–5, 2015.
16. D. Smolyakov, A. Korotin, P. Erofeev, A. Papanov, and E. Burnaev. Meta-learning for resampling recommendation systems. In *Proc. SPIE 11041, Eleventh International Conference on Machine Vision (ICMV 2018), 110411S (15 March 2019)*, 2019.
17. Pierre Geurts, Damien Ernst, and Louis Wehenkel. Extremely randomized trees. *Machine learning*, 63(1):3–42, 2006.
18. Ed Lawson, Denson Smith, Donald Sofge, Paul Elmore, and Frederick Petry. Decision forests for machine learning classification of large, noisy seafloor feature sets. *Computers and geosciences*, 99:116–124, 2017.
19. Jesse Davis and Mark Goadrich. The relationship between precision-recall and roc curves. *Proceedings of the 23rd International Conference on Machine Learning*, pages 233–240, 2006.

Time-series Classification for Industrial Applications: Road Surface Damage Detection Use Case

Burnaev E.V.

For safe driving, it is important to keep the road surface in good condition. Monitoring the condition of the road surface is time-consuming and requires special knowledge in this area. The situation is worsened by the fact that the monitoring procedure must be repeated with a relatively high frequency. Accordingly, automation of this process is required. There are methods for detecting and classifying roadway damage that are based on the use of computer vision technologies. However, training appropriate predictive models requires labeled images. Moreover, it is necessary to install specialized equipment on the car for image acquisition. In this paper, we evaluate the possibility of solving this problem based on processing data from the car’s accelerometer. Time series classification methods based on machine learning are used as a tool for building the predictive model.

KEYWORDS: monitoring system, anomaly detection, machine learning, predictive maintenance, signal processing.