

**Б. Е. РЕЗНИК<sup>1</sup>, М. Е. МАНСУРОВА<sup>2</sup>, Ж. Е. БАЙГАРАЕВА<sup>2</sup>,  
Г. А. АМИРХАНОВА<sup>2</sup>, С. Ш. ИКСАНОВ<sup>2\*</sup>**

<sup>1</sup>Берлинский университет прикладных наук, Берлин, Германия

<sup>2</sup>Казахский национальный университет имени аль-Фараби, Алматы, Казахстан

## **СИСТЕМА КЛАССИФИКАЦИИ ТРАНСПОРТНЫХ СРЕДСТВ НА ДОРОЖНЫХ СООРУЖЕНИЯХ С ИСПОЛЬЗОВАНИЕМ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА**

*В этом исследовании предлагается метод, основанный на искусственной нейронной сети для классификации систем грузовых автомобилей для мониторинга дорожных сооружений. Как правило, для того, чтобы гарантировать структурную и эксплуатационную безопасность и обеспечить раннее предупреждение о повреждении или износе до дорогостоящего ремонта или даже катастрофического обрушения дорожных конструкций, необходимо обеспечить высококачественную систему мониторинга, основанную на инновационных методах. Начиная с выбора подходящих датчиков и заканчивая проектированием системы оценки состояния конструкции, разрабатывается интеллектуальная система мониторинга для большого моста, которая действительно способна предоставлять информацию для оценки целостности конструкции. В этой статье рассматриваются последние инновационные достижения в области регистрации транспортных средств на дорожных сооружениях. Распознавание и классификация каждого отдельного типа грузового транспортного средства очень сложны, поскольку существуют различные их типы, включая разное количество осей и их расположение, что вызывает неоднозначность в процессе распознавания и классификации. Чтобы справиться с этими классификационными неоднозначностями, авторы предлагают метод распознавания и классификации, основанный на искусственной нейронной сети. Грузовые транспортные средства классифицируются с помощью искусственной нейронной сети, основанной на амплитуде вынужденных колебаний конструкции. Как только нейронная сеть обучена полученным сигналам, она используется для определения типа грузовых транспортных средств с использованием полученных сигналов. Эффективность классификации была оценена в ходе экспериментов на мосту в Берлине, Германия. Обучение модели проводилось с использованием метода CNN для классификации транспортных средств, что привело к общей точности классификации около 95%.*

**Ключевые слова:** *Structural Health Monitoring (SHM), классификация транспортных средств, нейронные сети, искусственный интеллект, инженерные сооружения.*

**Введение.** Классификация транспортных средств является одним из основных компонентов систем мониторинга дорожного движения. Он играет решающую роль в транспортном планировании и управлении дорожным движением. Например, организации по безопасности очень заинтересованы в определении пропускной способности и геометрического дизайна автострад и обслуживании дорожного покрытия в соответствии с типами транспортных средств, номерами и т.д. С целью регистрации дорожных транспортных средств используются различные приложения, такие как автоматизированные системы парковки, используемые в исследованиях [1] и [2], мониторинг состояния конструкций, используемых в [3] и [4], или в целях обеспечения безопасности инженерных сооружений, как в [5] и мониторинг транспортных пото-

---

\* E-mail корреспондирующего автора: [iks74@mail.ru](mailto:iks74@mail.ru)

ков, изученных в статьях [6] и [7]. Для обнаружения транспортных средств используются различные методы, такие как зоны мониторинга транзита, пересечения перед стационарными датчиками, которые были взяты за основу в исследованиях [8], также используются глобальные методы покрытия или гибридные методы, как в статье [9]. Данные, собираемые датчиками и детекторами, охватывают широкий спектр информации, включая скорость, ускорение/замедление, номерной знак, тип и модель, вес и расстояние между осями, а также количество и форму транспортных средств, то есть высоту, ширину и длину.

Недавно было внедрено несколько систем обнаружения транспортных средств благодаря огромным достижениям в области программных вычислений, беспроводной связи и сенсорных технологий. Эти методы имеют различные требования и спецификации с точки зрения аппаратных средств и параметров конфигурации, среды развертывания, стоимости, типов датчиков и т.д.

Самым простым методом обнаружения транспортных средств является ручной подсчет, однако он подвержен ошибкам и отнимает много времени. Методы, основанные на зрении, как наиболее часто используемый и изученный подход к идентификации транспортных средств, обнаруживают и отслеживают транспортные средства путем удаления визуальных признаков, таких как текстурные узоры, цвета и видеополосы [10]. Методы, основанные на видении, включают в себя несколько этапов, включая сегментацию изображения, PR, извлечение признаков и обучение.

Детектор магнитной петли, используемый в статье [11], представляет собой технологию, которая определяет длину транспортного средства и использовалась в последние десятилетия для обнаружения транспортных средств. Двухконтурные детекторы, используемые в статье [12], могут измерять скорость целевого транспортного средства. Аналогично пневматическим трубчатым детекторам, которые, однако, плохо работают на дорогах с большим объемом движения, хотя они довольно дешевы и выполняют автоматическую классификацию.

Радарные датчики, которые использовались в экспериментах [13], являются пространственными инструментами, которые способны классифицировать транспортные средства в соответствии с их размерами, такими как длина, габариты, высота и т.д. Несмотря на их недостаток при плотном движении и по сравнению с другими методами регистрации транспортных средств на инженерных сооружениях, они более устойчивы к изменениям окружающей среды.

Также используются инфракрасные датчики, они используют отраженный свет транспортного средства для поиска эквивалентного соответствия в базе данных. Но изменения окружающей среды оказывают негативное влияние на инфракрасные датчики. Акустические датчики используют акустические сигнатуры, которые не зависят от скорости, для определения классов транспортных средств, которые рассматривались в исследовании статьи [14].

**Метод.** Мониторинг – это систематический или периодический мониторинг (наблюдение) деформационно-напряженного состояния конструкций, выявляющий развитие повреждений и дающий характеристику конструкции о ее пригодности для дальнейшей эксплуатации. Результаты измерений дают представление об изменениях

геометрических свойств материалов и позволяют анализировать состояние конструкции с течением времени.

Чтобы проанализировать вибрационное поведение инженерной конструкции, были проведены измерения для сбора данных на мосту Фрейбрюке в Берлине, Германия. Это сооружение является частью Хеерштрассе протяженностью около 10 км, которая является важным связующим звеном между западными районами и центром Берлина и по которой ежедневно проезжает около 60 000 автомобилей.

Этапы разработки этого метода показаны на рисунке 1. Первый этап – это разработка системы мониторинга, которая включает в себя акселерометр и видеокамеру. Второй этап – это сбор и анализ данных, полученных с акселерометра, ниже также будут приведены иллюстрации изменений параметров во время мониторинга. Последним этапом является разработка системы классификации, которая включает в себя обучение модели с использованием метода CNN и получение результатов в виде распознанного транспортного средства на выходе.

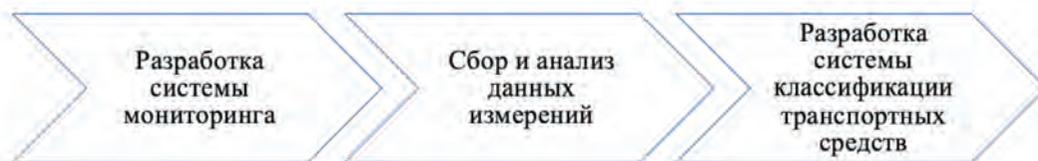


Рисунок 1 – Этапы разработки предлагаемой системы

Во время мониторинга были установлены акселерометры, которые измеряют вибрацию и ускорения (внезапное возбуждение конструкции, создающее резонанс). Эти акселерометры характеризуются измерением углов относительно осей X и Y, при этом ось Z расположена вертикально. Для качественного обследования важно обнаружить даже небольшие изменения амплитуды вибрации. Аналого-цифровое преобразование выполняется внутри устройства, устраняя любые помехи, возникающие в аналоговых кабелях. Измерения вибрации проводились с использованием обычного акселерометра с частотой дискретизации 153 Гц [15]. В дополнение к акселерометру на инженерном сооружении была установлена видеокамера для сравнения измерений на датчике с записью.

На рисунке 2 показаны результаты измерений по каждой из трех осей в течение приблизительно 15 минут. Изучая полученную информацию, в частности, величину переадресаций при въезде отдельных тяжелых транспортных средств, важно определить контрасты между осями. Значения ускорения в вертикальном направлении (X) имеют размах крыльев менее 10 м/с<sup>2</sup>, тогда как значения отклонения по двум горизонтальным осям (Y и Z) значительно выше и имеют размах крыльев около 20 м/с<sup>2</sup> и 40 м/с<sup>2</sup> соответственно. Особенно интересна взаимосвязь между размахом и размером «нормального» диапазона колебаний, в дополнение к абсолютным размерам отклонений. То, что уже можно вывести визуально из «толщины полосы», может быть подтверждено численно. Напротив, это соотношение намного выше в поперечном направлении (Y), где размах более чем в 20 раз превышает нормальный размах колеба-

ний. Это соотношение является самым низким в вертикальном направлении (X), где размах всего примерно в 8 раз больше, чем окно нормального поведения колебаний.

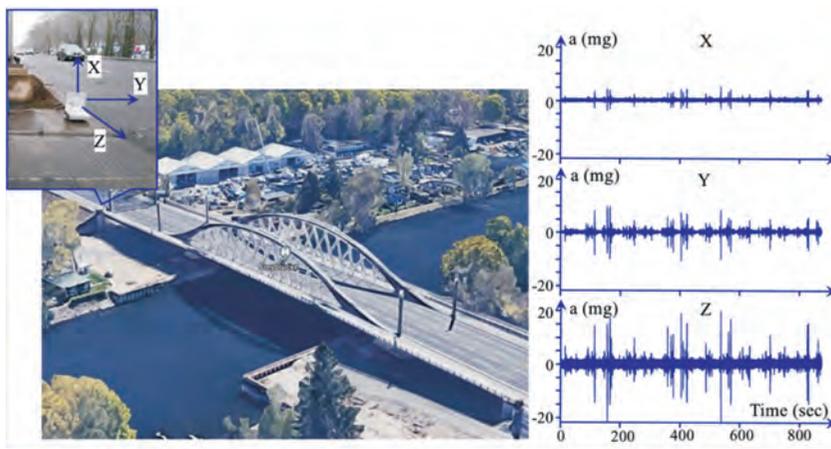


Рисунок 2 – Сбор данных с акселерометра и амплитуд вибраций

В результате этих измерений было показано, что при прохождении грузовика обнаруживаются изменения амплитуды. Как показано на рисунке 3, незначительные изменения амплитуды регистрируются во время проезда легкого транспортного средства. Когда проезжает грузовик, изменение амплитуды на каждой оси грузовика – это точно такие же изменения амплитуд, которые регистрируются на грузовиках по оси X. Следовательно, эти данные были использованы для обучения нейросетевой модели для регистрации транспортных средств на инженерных сооружениях.

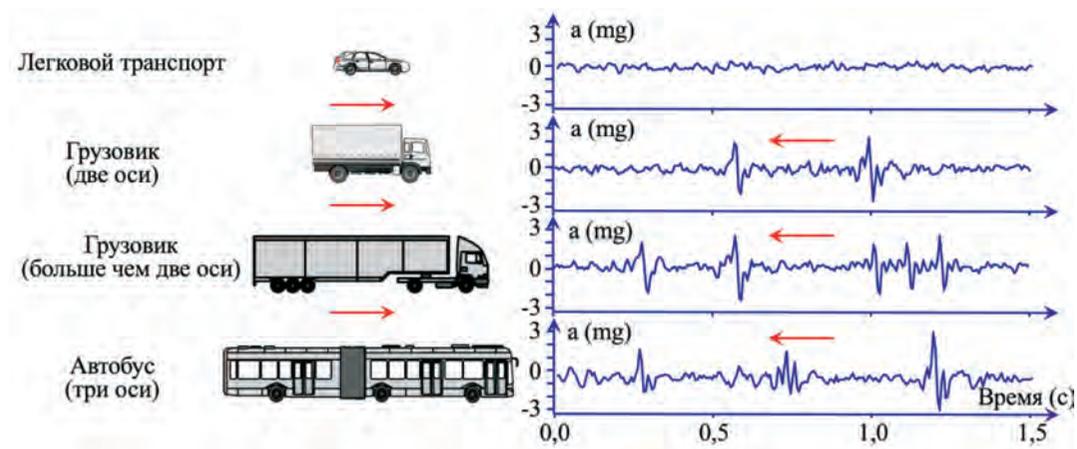
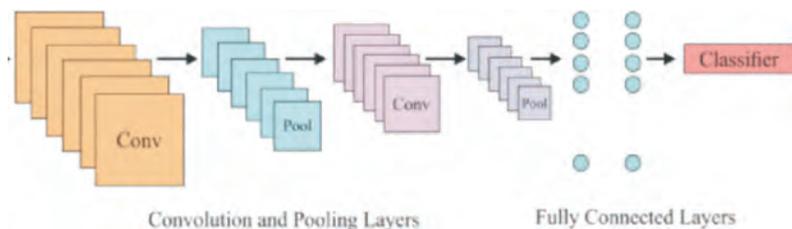


Рисунок 3 – Результаты в зависимости от типа транспортного средства (ось X)

За основу для обучения модели были взяты изменения амплитуд, которые были показаны выше, поэтому для достижения наилучшего результата мы использовали метод CNN. Для распознавания символов на сегментированных табличках CNN явля-

ется хорошо известной моделью глубокого обучения. На рисунке 4 изображены слои conv, join и fully connected (FC), которые составляют CNN. Эти слои используются для добавления или удаления блоков во время построения модели CNN с различным количеством блоков.



**Рисунок 4** – Архитектура CNN для распознавания символов

Модель, предложенная в этой работе, была обучена на следующих этапах, показанных на рисунке 5. Сначала будет создан конвективный слой, который варьируется от нейронной сети к нейронной сети, так что не каждое измерение взвешивается и смещается к следующему слою. Однако веса и смещения используются для разбивки всех измерений на более мелкие части. Известные как фильтры или ядра, это карты выходных объектов, которые сворачиваются с каждой меньшей областью входных данных. Каналы рассматриваются как более простые «объекты», которые просматриваются в информационных аспектах и на уровне conv. Поскольку аналогичный фильтр игнорирует каждое измерение в отдельном объекте, функция свертки требует меньшего количества параметров. Гиперпараметры слоя свертки включают количество фильтров, размер локальной области, шаг и заливку. Для достижения эффективной производительности эти гиперпараметры настраиваются в соответствии с размерами и жанрами входных данных.

Далее следует построение объединяющего слоя, который уменьшает количество параметров и снижает затраты на обработку. Параметры не создаются, поскольку входные данные передаются через предопределенную функцию. Существует три различных уровня объединения: максимальное объединение, среднее объединение и стохастическое объединение. Когда окно  $n \times n$  перемещается вдоль входного сигнала со значением шага  $s$ , используется максимальное объединение. Поскольку максимальное значение в области  $n \times n$  учитывается в каждом местоположении, входные данные становятся меньше. Это обеспечивает трансляционную инвариантность, позволяя распознавать даже незначительные различия в местоположении.

Сглаженный выход конечного объединяющего слоя подается в слой FC, который является третьим слоем. Он работает аналогично обычной нейронной сети, где каждый нейрон предыдущего уровня связан с текущим слоем. В результате слой содержит больше параметров, чем сверточный слой. С ним связан выходной слой, также известный как классификатор.

Функция активации создается последней. Архитектурные модели CNN используют множество функций активации. Функция ReLUs была использована в этой работе, потому что она более эффективна, чем другие функции.

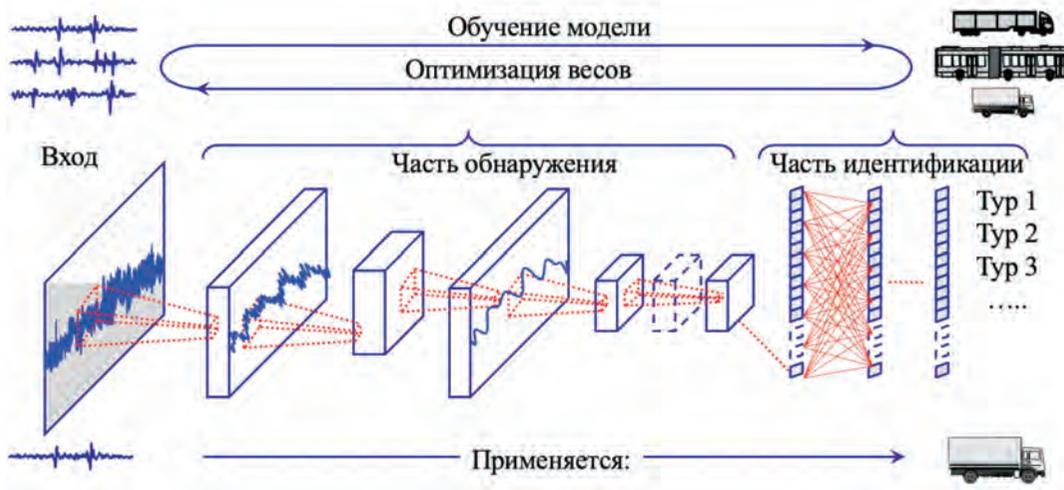


Рисунок 5 – The stages of training the model by CNN

**Результаты.** В результате экспериментов, проведенных для регистрации транспортных средств на инженерных сооружениях, процесс обнаружения и распознавания состоял из следующих этапов:

Шаг 1: Акселерометр записывает измерения на компьютер, и система также записала видеозапись (только для обучения и тестирования). Затем разработанная система мониторинга извлекает все измерения по секундам и амплитудам вибрации, а также видекамера используется для записи и сравнения транспортного средства.

	0	1	2	3
0	68.2339	2	0.99999	0.003906
1	79.4849	2	0.999858	0.003113
2	135.761	2	0.999997	0.004578
3	137.6	2	0.999996	0.003479
4	139.021	2	0.999996	0.004334
5	157.274	2	0.999974	0.003723
6	158.294	2	0.999998	0.003723
7	209.562	2	0.999787	0.003723
8	349.646	3	0.975534	0.002564
9	352.43	3	0.919092	0.002747
10	354.98	2	0.973106	0.002136
11	394.294	3	0.852111	0.002564
12	421.555	2	0.999999	0.004639
13	556.804	2	0.998639	0.00354
14	568.246	2	0.993276	0.002991
15	617.523	2	0.9854	0.00293

Рисунок 6 – Результаты работы системы распознавания

Шаг 2: Для сегментации система использовала метод CNN для сегментации каждого измерения.

Шаг 3: Система использовала CNN для извлечения характеристик, а именно данных измерений за время регистрации грузовых транспортных средств. Затем система протестировала измерения в обучающем наборе данных. Для оценки результатов эксперимента было получено 230 измерений транспортных средств. Частота ошибок для этой системы составляла 1-5%. После обучения CNN приобрела точность 95-99% на основе набора тестов и достигла точности 98,1% на основе набора тестов. Результаты работы системы распознавания транспортного средства показаны на рисунке 6. Слева в таблице показано время (в секундах), затем количество осей транспортного средства и, наконец, процент обнаружения проезжающего транспортного средства в программе.

**Заключение.** В данной статье представлен основанный на классификации подход, позволяющий регистрировать изменения амплитуды вибраций при прохождении грузовых транспортных средств по мосту, а затем обнаруживать их с помощью системы распознавания. Чтобы продемонстрировать обоснованность предлагаемого подхода, были проведены исследования с использованием данных акселерометра, полученных с моста Фрейбрюке в Берлине. На основе этих измерений на CNN и полученных в результате совместных событий с видеокамерой, была проведена классификация. Результаты кластеризации показали сходство между соединениями, расположенными в разных местах расположения мостов и областях, и помогли сгруппировать те, которые имеют схожее поведение.

Предлагаемый подход также может быть легко применен для получения оценки рабочей нагрузки структуры. Таким образом, можно обнаружить любое потенциальное повреждение конструкции.

## ЛИТЕРАТУРА

1 S. Y. Jo, N. Ahn, Y. Lee, and S.-J. Kang, "Transfer learning-based vehicle classification," in Proc. Int. SoC Design Conf. (ISOCC), Nov. 2018, pp. 127–128.

2 Z. Pu, R. Ke, Y. Zhuang, and Y. H. Wang, "A smart efficient and reliable parking surveillance system with edge artificial intelligence on IoT devices," IEEE Trans. Intell. Transp. Syst., early access, Apr. 8, 2020, doi: 10.1109/TITS.2020.2984197.

3 H. Shokravi and N. Bakhary, "Comparative analysis of different weight matrices in subspace system identification for structural health monitoring," IOP Conf. Series Mater. Sci. Eng., vol. 271, Aug. 2017, Art. no. 12092.

4 H. Shokravi, H. Shokravi, N. Bakhary, S. S. R. Koloor, and M. Petru, "Health monitoring of civil infrastructures by subspace system identification method: An overview," Appl. Sci., vol. 10, no. 8, p. 2786, 2020.

5 H. Shokravi, H. Shokravi, N. Bakhary, S. S. R. Koloor, and M. Petru, "A comparative study of the data-driven stochastic subspace methods for health monitoring of structures: A bridge case study," Appl. Sci., vol. 10, no. 9, p. 3132, 2020.

6 H. Shokravi, H. Shokravi, N. Bakhary, M. Heidarrezaei, S. S. R. Koloor, and M. Petru, "Vehicle-assisted techniques for health monitoring of bridges," Sensors, vol. 20, no. 12, p. 3460, 2020.

7 H. Shokravi, H. Shokravi, N. Bakhary, M. Heidarrezaei, S. S. R. Koloor, and M. Petru, "Application of the subspace-based methods in health monitoring of the civil structures: A systematic review and meta-analysis," Appl. Sci., vol. 10, no. 10, p. 3607, 2020.

8 M. T. Tamam, W. Dwiono, and R. J. P. Safian, "Design a prototype of the application system of classification and calculating motor vehicles on highway," IOP Conf. Series Mater. Sci. Eng., vol. 771, Mar. 2020, Art. no. 12002.

9 B. Sliwa, N. Piatkowski, and C. Wietfeld, "The channel as a traffic sensor: Vehicle detection and classification based on radio finger- printing," IEEE Internet Things J., vol. 7, no. 8, pp. 7392–7406, Aug. 2020.

10 M. Won, "Intelligent traffic monitoring systems for vehicle classification: A survey," IEEE Access, vol. 8, pp. 73340–73358, 2020.

11 C.-W. Kim, K. C. Chang, P. J. McGetrick, S. Inoue, and S. Hasegawa, "Utilizing moving vehicles as sensors for bridge condition screening—A laboratory verification," Sens. Mater., vol. 29, no. 2, pp. 153–163, Jan. 2018.

12 R. Velazquez-Pupo et al., "Vehicle detection with occlusion handling, tracking, and OC-SVM classification: A high performance vision-based system," Sensors, vol. 18, no. 2, p. 374, 2018.

13 N. Siddiqui and M. S. Husain, "CTS: A credit-based threshold system to minimize the dissemination of faulty data in vehicular adhoc networks," Control Theory Appl., vol. 9, no. 17, pp. 8499–8508, 2018.

14 Q. Ji, B. Jin, Y. Cui, and F. Zhang, "Using mobile signaling data to classify vehicles on highways in real time," in Proc. 18th IEEE Int. Conf. Mobile Data Manag. (MDM), 2018, pp. 174–179.

15 Resnik, B., Sargsyan, A. (2019): Application of MEMS accelerometers in the context of structural monitoring using a typical example. AVN General Survey News. Wichmann Verlag, Berlin / Offenbach, Issue 6-7, pp. 163-172.

## REFERENCES

1 S. Y. Jo, N. Ahn, Y. Lee, and S.-J. Kang, "Transfer learning-based vehicle classification," in Proc. Int. SoC Design Conf. (ISOCC), Nov. 2018, pp. 127–128.

2 Z. Pu, R. Ke, Y. Zhuang, and Y. H. Wang, "A smart efficient and reliable parking surveillance system with edge artificial intelligence on IoT devices," IEEE Trans. Intell. Transp. Syst., early access, Apr. 8, 2020, doi: 10.1109/TITS.2020.2984197.

3 H. Shokravi and N. Bakhary, "Comparative analysis of different weight matrices in subspace system identification for structural health monitoring," IOP Conf. Series Mater. Sci. Eng., vol. 271, Aug. 2017, Art. no. 12092.

4 H. Shokravi, H. Shokravi, N. Bakhary, S. S. R. Koloor, and M. Petru, "Health monitoring of civil infrastructures by subspace system identification method: An overview," Appl. Sci., vol. 10, no. 8, p. 2786, 2020.

5 H. Shokravi, H. Shokravi, N. Bakhary, S. S. R. Koloor, and M. Petru, "A comparative study of the data-driven stochastic subspace methods for health monitoring of structures: A bridge case study," Appl. Sci., vol. 10, no. 9, p. 3132, 2020.

6 H. Shokravi, H. Shokravi, N. Bakhary, M. Heidarrezaei, S. S. R. Koloor, and M. Petru, "Vehicle-assisted techniques for health monitoring of bridges," Sensors, vol. 20, no. 12, p. 3460, 2020.

7 H. Shokravi, H. Shokravi, N. Bakhary, M. Heidarrezaei, S. S. R. Koloor, and M. Petru, "Application of the subspace-based methods in health monitoring of the civil structures: A systematic review and meta-analysis," Appl. Sci., vol. 10, no. 10, p. 3607, 2020.

8 M. T. Tamam, W. Dwiono, and R. J. P. Safian, "Design a prototype of the application system of classification and calculating motor vehicles on highway," IOP Conf. Series Mater. Sci. Eng., vol. 771, Mar. 2020, Art. no. 12002.

9 B. Sliwa, N. Piatkowski, and C. Wietfeld, "The channel as a traffic sensor: Vehicle detection and classification based on radio finger- printing," IEEE Internet Things J., vol. 7, no. 8, pp. 7392–7406, Aug. 2020.

10 M. Won, “Intelligent traffic monitoring systems for vehicle classification: A survey,” *IEEE Access*, vol. 8, pp. 73340–73358, 2020.

11 C.-W. Kim, K. C. Chang, P. J. McGetrick, S. Inoue, and S. Hasegawa, “Utilizing moving vehicles as sensors for bridge condition screening—A laboratory verification,” *Sens. Mater.*, vol. 29, no. 2, pp. 153–163, Jan. 2018.

12 R. Velazquez-Pupo et al., “Vehicle detection with occlusion handling, tracking, and OC-SVM classification: A high performance vision-based system,” *Sensors*, vol. 18, no. 2, p. 374, 2018.

13 N. Siddiqui and M. S. Husain, “CTS: A credit-based threshold system to minimize the dissemination of faulty data in vehicular adhoc networks,” *Control Theory Appl.*, vol. 9, no. 17, pp. 8499–8508, 2018.

14 Q. Ji, B. Jin, Y. Cui, and F. Zhang, “Using mobile signaling data to classify vehicles on highways in real time,” in *Proc. 18th IEEE Int. Conf. Mobile Data Manag. (MDM)*, 2018, pp. 174–179.

15 RESNIK, B., SARGSYAN, A. (2019): Application of MEMS accelerometers in the context of structural monitoring using a typical example. *AVN General Survey News*. Wichmann Verlag, Berlin / Offenbach, Issue 6-7, pp. 163-172.

**Б. Е. РЕЗНИК<sup>1</sup>, М. Е. МАНСУРОВА<sup>2</sup>, Ж. Е. БАЙҒАРАЕВА<sup>2</sup>,  
Г. А. АМИРХАНОВА<sup>2</sup>, С. Ш. ИКСАНОВ<sup>2</sup>**

<sup>1</sup>Берлин қолданбалы ғылымдар университеті, Берлин, Германия

<sup>2</sup>Әл – Фараби атындағы Қазақ ұлттық университеті, Алматы, Қазақстан

## **ЖАСАНДЫ ИНТЕЛЛЕКТТИ ПАЙДАЛАНА ОТЫРЫП, ЖОЛ ҚҰРЫЛЫСТАРЫНДАҒЫ КӨЛІК ҚҰРАЛДАРЫН КЛАССИФИКАЦИЯЛАУ ЖҮЙЕСІ**

Бұл зерттеу жол құрылыстарын бақылау үшін жүк көлігі жүйелерін жіктеу үшін жасанды нейрондық желіге негізделген әдісті ұсынады. Әдетте, құрылымдық және пайдалану қауіпсіздігіне кепілдік беру және қымбат жөндеуге немесе тіпті жол құрылымдарының апатты құлауына дейін зақымдану немесе тозу туралы ерте ескертуді қамтамасыз ету үшін инновациялық әдістерге негізделген жоғары сапалы бақылау жүйесін қамтамасыз ету қажет. Сәйкес сенсорларды таңдаудан бастап, құрылымның күйін бағалау жүйесін жобалауға дейін, құрылымның тұтастығын бағалау үшін ақпарат бере алатын үлкен көпір үшін Интеллектуалды бақылау жүйесін әзірлеуге дейін. Бұл мақалада жол құрылыстарында Көлік құралдарын тіркеу саласындағы соңғы инновациялық жетістіктер қарастырылады. Жүк көлігінің әрбір жеке түрін тану және жіктеу өте күрделі, өйткені олардың әртүрлі түрлері, әртүрлі осьтер саны және олардың орналасуы бар, бұл тану және жіктеу процесінде түсініксіздікті тудырады. Осы жіктеу түсініксіздіктерімен күресу үшін авторлар жасанды нейрондық желіге негізделген тану және жіктеу әдісін ұсынады. Жүк көліктері жиілік аймағында алынған жүк көлігі жүйелерінің сигналдарына жасанды нейрондық желіні қолдану арқылы жіктеледі. Нейрондық желі алынған сигналдарға үйретілгеннен кейін, ол алынған сигналдарды қолдана отырып, жүк көліктерінің түрін анықтау үшін қолданылады. Жіктеудің тиімділігі Германияның Берлин қаласындағы Фрейбрюк көпіріндегі эксперименттер арқылы бағаланды. Модельді оқыту Көлік құралдарын жіктеу үшін CNN әдісін қолдана отырып жүргізілді, нәтижесінде шамамен 95% классификацияның жалпы дәлдігі пайда болды.

**Түйін сөздер:** *Structural Health Monitoring (SHM)*, көлік құралдарының классификациясы, нейрондық желілер, жасанды интеллект, инженерлік қондырғылар.

**B. E. RESNIK<sup>1</sup>, M. E. MANSUROVA<sup>2</sup>, ZH. E. BAIGARAYEVA<sup>2</sup>,  
G. A. AMIRKHANOVA<sup>2</sup>, S. SH.IXANOV<sup>2</sup>**

*<sup>1</sup>Berlin University of Applied Science, Berlin, Germany*

*<sup>2</sup>Al-Farabi Kazakh National University, Almaty, Kazakhstan*

## **THE CLASSIFICATION SYSTEM OF VEHICLES ON ROAD STRUCTURES USING ARTIFICIAL INTELLIGENCE**

*This study proposes a method based on an artificial neural network for classifying truck systems for monitoring road structures. As a rule, in order to guarantee structural and operational safety and provide early warning of damage or wear before expensive repairs or even catastrophic collapse of road structures, it is necessary to provide a high-quality monitoring system based on innovative methods. Starting from the selection of suitable sensors and ending with the design of a structural condition assessment system, the development of an intelligent monitoring system for a large bridge that is really capable of providing information for assessing the integrity of the structure. This article explores the latest innovative achievements in the field of vehicle registration on road structures. Recognition and classification of each individual type of cargo vehicle is very difficult, because there are different types of them, there are different numbers of axles and their location, which cause ambiguity in the recognition and classification process. To cope with these classification ambiguities, the authors propose a method of recognition and classification based on an artificial neural network. Cargo vehicles are classified by applying an artificial neural network to the signals of truck systems received in the frequency domain. Once the neural network is trained on the received signals, it is used to determine the type of cargo vehicles using the received signals. The effectiveness of the classification was evaluated by experiments on the Freybrücke Bridge in Berlin, Germany. Model training was applied using the CNN method for vehicle classification, which resulted in an overall classification accuracy of about 95%.*

**Key words:** *Structural Health Monitoring (SHM), classification of vehicles, neural networks, artificial intelligence, engineering structures, vehicles, frequency.*