

Д. А. СЛЕСАРЕВ¹, д-р техн. наук, доц.

Н. А. СЛЕСАРЕВА²

¹ ООО «ИНТРОН ПЛЮС» (Москва, Россия),

² ООО «ИНТРОН-ВТД», Москва

ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ОЦЕНКИ КРИТИЧНОСТИ ДЕФЕКТОВ СТАЛЬНЫХ КАНАТОВ ПРИ ИХ МАГНИТНОЙ ДЕФЕКТОСКОПИИ

Аннотация. Стальные канаты применяются в различных сферах промышленности и в том числе на опасных промышленных объектах. Одним из главных критериев браковки канатов является число оборванных проволок на заданную длину, как правило, 6D и 30D (D — диаметр каната). При этом особенно сложным является определение числа оборванных проволок в локальном скоплении. В настоящем докладе рассматривается возможность применения искусственных нейронных сетей для анализа дефектограмм магнитного дефектоскопа с целью оценки числа обрывов в скоплении. Исследуются различные типы и архитектура нейронной сети, а также особенности выбора первичных признаков и процесса обучения сети.

Ключевые слова: нейронные сети, машинное обучение, стальные канаты.

Введение

Стальные канаты широко используются в различных отраслях промышленности как несущий элемент подъемных и транспортных установок или строительных конструкций. Срок службы и надёжность стального каната зависит от его технического состояния, поэтому регулярное обследование каната является ключевым фактором обеспечения безопасности таких установок и сооружений, и обеспечения экономически эффективной их эксплуатации за счёт планирования операций по замене канатов. В соответствии с российскими и международными техническими нормативами, например, ISO 4309 [1] и РД 03-348-00 [2], основными критериями браковки стальных канатов являются: величина потери металлического сечения каната и количество обрывов проволок на заданную длину каната, как правило, 6D и 30D, где D — диаметр каната. Наиболее распространенным и хорошо зарекомендовавшим себя методом диагностики канатов является магнитная дефектоскопия [3], позволяющая измерять величину потери сечения (ПС) и обнаруживать локальные дефекты (ЛД), такие как одиночные и скопления обрывов проволок. При оценке состояния каната наиболее сложным оказывается оценка числа обрывов проволок в скоплениях (Рис. 1), при том что такие участки каната представляют наибольшую опасность, поскольку являются наиболее вероятным местом потенциального обрыва каната. Правильная оценка числа дефектов требует совместного анализа различных измерительных канатов дефектоскопа (ПС, ЛД, отдельных датчиков), знания конструкции и режима нагрузки каната и выполняется, как правило, опытным экспертом. В настоящем докладе описывается возможное решение этой задачи

с применением искусственных нейронных сетей (далее — нейросетей) и оценивается результат этого решения.



Рис. 1. Участок каната с множественными обрывами проволок

1. Анализ поставленной задачи

При магнитной дефектоскопии стальных канатов основную информацию об обрывах проволок несёт измерительный канал ЛД, с его помощью отдельные обрывы чётко идентифицируются и имеют характерную форму сигнала, однако при наличии нескольких близлежащих дефектов форма сигнала существенно усложняется, не позволяя идентифицировать каждый обрыв в отдельности. Так на рис. 2 приведены дефектограммы каналов ЛД и ПС, где на дистанции 72,6 — 72,85 м имеется сигнал от скопления (более 5) дефектов, на дистанции 73,25 м – сигнал от одиночного обрыва.




Рис. 2. Дефектограммы ЛД и ПС участка каната с множественными обрывами проволок (получены дефектоскопом Интрос МГ 6-24)

При намагничивании каната до насыщения поток магнитной индукции поля рассеяния над дефектом является пропорциональным эквивалентному суммарному сечению оборванных проволок и, соответственно, величина сигнала по каналу ПС также будет зависеть от их суммарного сечения. В связи с этим сигнал по ПС можно дополнительно использовать для оценки числа оборванных проволок.

Следует также учитывать, что форма и амплитуда сигнала от близлежащих обрывов по каналу ЛД зависит от расстояния между отдельными обрывами, а также от расстояния между концами оборванных проволок. Было проведено аналитическое моделирование сигналов ЛД (LF) от трёх близлежащих одинаковых обрывов с фиксированным зазором между концами проволок (3 мм) на канате диаметром 16 мм для измерительной системы дефектоскопа Интрос при различном расстоянии между обрывами: 50 мм, 20 мм и 15 мм. Результаты моделирования показаны на рис. 3. Как видно из графиков, сигнал от обрывов на расстоянии 50 мм друг от друга четко разделены (см. рис. 3,а) и могут быть точно оценены (по амплитуде). При снижении расстояния между обрывами до 20 мм амплитуда импульса от среднего обрыва примерно на 30 % ниже, чем амплитуда импульсов соседних обрывов (см. рис. 3,б). При уменьшении расстояния между обрывами до 15 мм сигнал от срединного обрыва практически исчезает, а сигналы от первого и последнего становятся однополярными (см. рис. 3,в), что может привести к ошибочной их интерпретации, в частности такой вид может иметь сигнал от обрыва с большим расстоянием между концами проволок (в данном случае – 30 мм).




Рис. 3. Сигнал канала ЛД от двух близлежащих дефектов при расстоянии между ними: 50 мм (а), 20 мм (б), 15 мм (в)

В то же время обрывы проволок обуславливают небольшие сигналы по каналу ПС, амплитуда и вид которых зависит как от характеристик самих обрывов, так и от измерительной системы дефектоскопа. Было проведено численное моделирование сигналов по каналам ЛД (LF) и ПС (LMA) для обрывов проволок одинакового поперечного сечения и различным зазором между концами. На рис. 4 показаны графики, построенные по результату проведенного моделирования для обрыва проволоки эквивалентного поперечного сечения 0,5 %, расположенного по центру каната диаметром 40 мм. Зазоры между концами проволоки: 5 мм, 15 мм и 50 мм. Как следует из

графиков, амплитуда сигналов ЛД в зависимости от зазора изменяется более, чем в 2 раза.

Амплитуда сигнала по каналу ПС также зависит от величины зазора, для 50 мм она почти в 2 раза больше, чем для 5 мм, при этом для 50 мм максимальное значение ПС практически соответствует реальной величине относительного сечения оборванной проволоки. При обрыве двух проволок в одном сечении сигнал по каналам ЛД и ПС пропорционально возрастёт. Следует отметить, что зависимость амплитуды сигнала от зазора для разных магнитных головок (МГ) различная. Тем не менее, для конкретной МГ совместный анализ сигналов по каналам ЛД и ПС позволяет сделать оценку числа оборванных проволок.





Рис. 4. Моделирование сигналов каналов ЛД и ПС от обрыва проволоки с зазорами между концами 5 мм, 15 мм, 50 мм

В реальном скоплении обрывов проволок зазоры между концами проволок, их ориентация и расстояние между отдельными обрывами неизвестны, поэтому точная оценка числа обрывов в скоплении невозможна, возможна только вероятностная оценка на основании магнитной дефектоскопии и с учётом конструкции и условий эксплуатации каната. Для осуществления такой оценки предлагается использовать искусственную нейронную сеть.

2. Применение нейросетей для оценки числа обрывов в скоплении

Искусственные нейронные сети хорошо зарекомендовали себя в задачах обработки гетерогенных данных, в частности при решении задачи регрессии, в связи с этим они представляются хорошим кандидатом для оценки числа обрывов в скоплениях на основе комбинации дефектограмм ЛД и ПС и учёта дополнительных параметров каната. Известные публикации по применению нейронных сетей для анализа результатов магнитной дефектоскопии были посвящены решению задачи классификации и обнаружения дефектов с применением дополнительно вейвлет-анализа [4]. Дефектограммы при этом преобразовывались в двумерные вейвлет-образы и нейронная сеть использовалась для обработки изображений. Такого рода обработка является весьма ресурсоёмкой, что ограничивает возможность ее широкого применения в рамках ПО на обычном локальном ПК клиента. При этом обрабатывались лишь сигналы отдельных дефектов, но не их скоплений.

При выборе подхода к решению поставленной задачи необходимо учитывать, что использование непосредственно исходных сигналов в качестве входных данных приводит к низкой робастности нейросети [5], небольшие возмущения входных данных могут приводить к значительным отклонениям результата. Поэтому было принято решение проводить предварительную обработку сигналов по каналам ЛД и ПС с целью выделения первичных признаков, а затем уже вектор первичных признаков использовать в качестве входного для нейросети. Всего было выделено 12 первичных признаков, в числе которых: абсолютный максимум ЛД, абсолютный минимум ЛД, абсолютный максимум ПС, число локальных максимумов по ЛД, число локальных максимумов по ПС, протяженность области сигнала и другие. На основании дисперсионного анализа на обучающей выборке было отобрано 8 наиболее независимых признаков. Для решения поставленной задачи оценки числа обрывов в скоплении были рассмотрены два типа нейросети: многослойный персептрон (MLP) и радиально-базисная сеть (RBF) [5]. Оба типа нейросети широко применяются для решения задачи регрессии.

Исследуемая выборка была сформирована по результатам обследования 16 различных объектов (канатов канатных дорог, подъемных кранов, талевых канатов буровых установок), контроль выполнялся 7 различными дефектоскопами (в зависимости от диаметра каната), всего было выявлено и

классифицировано 130 дефектов в виде скоплений обрывов проволок. Вся выборка была разделена на три части: обучающую, тестирующую и валидационную. Авторами были исследованы различные архитектуры выбранных нейросетей. Число входных нейронов варьировалось от 6 до 8, число нейронов в скрытом слое – от 5 до 12.

Также использовались различные функции активации. Приведенные результаты для MLP сети соответствуют функции активации в виде гиперболического синуса для скрытого слоя и ReLU – для выходного слоя. Для обучения сети использовался квази-ньютоновский алгоритм (BFGS). Качество получившейся сети оценивалось по средней ошибке предсказания и максимальной относительной ошибке предсказания. Кроме этого для оценки робастности сети использовалась вариация ошибки, определяемая путем случайного возмущения начальных условий обучения. Результаты обучения представлены в Таблице 1. Число входных нейронов изменялось путем удаления признаков, дающих наименьший вклад в финальный результат на обученной нейросети. Обучение проводилось как на полной исходной выборке, так и на усечённой выборке, из которой были удалены экстремальные значения, встречающиеся на практике крайне редко (например, 40 обрывов в скоплении). Как видно из таблицы, наилучший результат был получен для сети с 6 входными нейронами, дальнейшее сокращение числа входных признаков приводит к росту средней ошибки. Число скрытых нейронов 5 и 8 дают примерно одинаковый результат, при этом сеть с 8 скрытыми нейронами оказывается менее робастной, вероятно, из-за ограниченности обучающей выборки. По мере дообучения сети с ростом объема выборки можно ожидать повышения робастности.

Таблица 1 Сравнения результат обучения многослойного персептрона

Архитектура сети	Средняя ошибка оценки	Максимальная относительная ошибка оценки	Вариация ошибки
MLP 8-8-1	1,0	20%	20%
MLP 8-5-1	1,1	25%	15%
MLP 8-8-1 (усечённая выборка)	0,5	40%	15%
MLP 7-8-1 (усечённая выборка)	0,38	40%	25%
MLP 6-5-1 (усечённая выборка)	0,3	55%	40%
MLP 6-8-1 (усечённая выборка)	0,32	60%	60%
MLP 6-12-1 (усечённая выборка)	0,35	70%	50%
MLP 5-8-1 (усечённая выборка)	1,3	50%	40%

В Таблице 2 приведены результаты обучения радиально-базисной сети с разной архитектурой. Было проведено обучение нейросети с 8 и 12 скрытыми нейронами. Увеличение числа скрытых нейронов приводит к снижению

ошибки сети, но робастность остается очень низкой. Таким образом, радиально-базисная сеть значительно уступает многослойному персептрону при оценке числа обрывов на основе выделенных информационных признаков сигналов.

Таблица 2 Сравнения результат обучения радиально-базисной сети

Архитектура сети	Средняя ошибка оценки	Максимальная относительная ошибка оценки	Вариация ошибки
RBF 8-8-1	3,5	50%	> 100%
RBF 8-12-1	2,1	50%	> 100%
RBF 8-12-1 (усечённая выборка)	0,6	40%	> 100%

Обученная нейронная сеть – многослойный персептрон, была реализована в рамках стандартного программного обеспечения Wintros для обработки данных дефектоскопов Интрос. На рис. 5 показан пример результата обработки дефектограммы каната с множественными обрывами проволок.




Рис. 5. Результат обработки дефектограммы каната с множественными обрывами проволок

Перевернутыми треугольниками по верхнему краю дефектограммы ЛД (LF trace) показаны обнаруженные дефекты, красные большие треугольники соответствуют скоплениям обрывов. Число обрывов указано чуть ниже номера дефекта справа. В частности, для дефекта с координатой 72,6 м нейросеть дала оценку – 21 оборванная проволока (экспертная оценка была – 24 проволоки). Следует отметить, что созданный алгоритм автоматической обработки

дефектограмм не требует больших вычислительных ресурсов. Так на стандартном ноутбуке с архитектурой Core i3 анализ дефектограммы каната длиной 1 км с примерно 100 дефектами занимает 2 - 4 секунды.

Использованная обучающая выборка была весьма ограниченной, что связано с тем, что дефектограммы предварительно должны быть обработаны опытным экспертом. По мере дополнения выборки будет проводиться дообучение сети, что приведет к необходимости актуализации параметров расчётного алгоритма. Поэтому параметры нейросети сохраняются в отдельном файле, который может обновляться при подключении приложения Wintros к серверу разработчика.

3. Заключение

Представленные в докладе результаты показывают возможности эффективного применения искусственной нейронной сети для решения задачи оценки числа обрывов в скоплениях при магнитной дефектоскопии стальных канатов. Сигналы измерительных каналов ЛД и ПС предварительно должны быть обработаны с целью вычисления первичных вектора признаков. Наилучший результат был получен с помощью многослойного персептрона при предварительной обработке обучающей выборки с целью устранения экстремальных значений. В итоге средняя ошибка оценки составила 1 проволоку. По мере накопления данных для улучшения качества оценки необходимо увеличивать число нейронов в скрытых слоях.

Список литературы

1. ISO 4309:2017 International standard. Cranes – Wire ropes – Care and maintenance, inspection and discard.
2. РД 03-348-00. Методические указания по магнитной дефектоскопии стальных канатов. Основные положения. - М.: Госгортехнадзор России, 2000.
3. Sukhorukov V., Slesarev D., Vorontsov A. Electromagnetic Inspection and Diagnostics of Steel Ropes: Technology, Cost-Effectiveness, Problems. – Materials Evaluation, 2014, No8, pp. 1019-1027.
4. S.Pernot, O.Reinelt, M.Hanimann. Wirelet 3: Deep leaning models for the automatic analysis of rope surface defects. - Proceedings of the OIPEEC Conference 2022, Stuttgart, Germany 2022, pp. 395-414
5. Haykin S. Neural networks: a comprehensive foundation. – N. Y., 1994.

Контакты:

slesarevda@mpei.ru (Слесарев Дмитрий Александрович);
nadja.slesareva@yandex.ru (Слесарева Надежда Александровна).