

УДК 004.624

СРАВНЕНИЕ УСТОЙЧИВОСТИ ФОРМАТОВ ДАННЫХ К ПОВРЕЖДЕНИЯМ ПРИ МЕЖСИСТЕМНОМ ВЗАИМОДЕЙСТВИИ

С. В. ЛУКАШЕВИЧ, В. Л. ШАБАЛОВ, В. В. ЛУКАШЕВИЧ

(Представлено: А. А. СКУКОВСКАЯ)

В статье рассматриваются вопросы надёжности различных форматов данных – CSV, JSON, XML и Excel – при частичной потере или повреждении информации в процессе передачи между системами. Оцениваются такие параметры, как восстанавливаемость данных, чувствительность к синтаксическим ошибкам и возможность частичного чтения.

Ключевые слова: форматы данных, надёжность, повреждение данных, CSV, JSON, XML, Excel, межсистемный обмен.

Введение. При интеграции различных программных систем данные часто передаются через промежуточные форматы, такие как CSV, JSON, XML или файлы Excel. Однако на практике каналы передачи могут быть ненадёжными: возможны обрывы соединения, ошибки записи на диск, несовместимость кодировок или человеческий фактор. В таких условиях важно понимать, насколько устойчив выбранный формат к частичным повреждениям и способен ли он сохранить хотя бы часть полезной информации.

Основная часть. CSV (*Comma-Separated Values*). CSV – это простой текстовый формат, в котором каждая строка представляет собой запись, а поля внутри строки разделяются запятыми (или другими символами, например, точкой с запятой). Формат не имеет строгой стандартизации, хотя существует рекомендация RFC 4180.

Особенности структуры:

- Нет встроенной информации о типах данных (всё – строки).
- Заголовок (если есть) не обязателен.
- Специальные символы (запятые, кавычки, переносы строк) должны экранироваться с помощью двойных кавычек.

Устойчивость к повреждениям:

- Низкая. Даже незначительное повреждение (например, пропущенная кавычка или лишняя запятая) может нарушить выравнивание колонок во всех последующих строках.
- Отсутствие метаданных не позволяет парсеру понять, где заканчивается одна запись и начинается другая.
- При обрыве передачи невозможно определить, завершена ли последняя строка.

Пример уязвимости. Если в поле «Комментарий» содержится текст "Важно, срочно!", но кавычки не экранированы, парсер интерпретирует запятую как разделитель полей, что приведёт к смещению данных.

JSON (*JavaScript Object Notation*). JSON – это лёгкий текстовый формат обмена данными, основанный на синтаксисе объектов JavaScript. Он поддерживает вложенные структуры, массивы, строки, числа, логические значения и null.

Особенности структуры:

- Строгий синтаксис: обязательные двойные кавычки для ключей и строк, запятые между элементами, правильное вложение фигурных и квадратных скобок.
- Не поддерживает комментарии.
- Часто используется в веб-API и конфигурационных файлах.

Устойчивость к повреждениям:

- Очень низкая для классического JSON. Любая синтаксическая ошибка (например, отсутствие запятой или скобки) делает весь документ недействительным – парсер не сможет прочитать ни одного элемента.
- Однако существует альтернатива – JSONL (*JSON Lines*), где каждый объект записан в отдельной строке. В этом случае повреждение одной строки не влияет на остальные, что значительно повышает надёжность.

Пример уязвимости. Если при передаче обрывается последняя скобка (}), стандартный JSON-парсер выдаст ошибку и не вернёт никаких данных, даже если 99% документа корректны.

XML (*eXtensible Markup Language*). XML – это разметочный язык, предназначенный для хранения и передачи структурированных данных. Он поддерживает иерархию, атрибуты, пространства имён и валидацию через схемы (XSD).

Особенности структуры:

- Данные заключаются в открывающие и закрывающие теги (<name>Иван</name>).
- Поддерживает вложенность и самодокументируемость.
- Может включать инструкции по обработке и ссылки на схемы.

Устойчивость к повреждениям:

– Средняя. XML требует корректного завершения всех тегов и соблюдения иерархии. Однако многие парсеры (особенно SAX-типа) могут работать в режиме «восстановления после ошибки» (error recovery), пропуская повреждённые фрагменты.

– Если повреждён только один узел (например, не закрыт тег <note>), парсер может продолжить обработку других частей документа.

– Тем не менее, повреждение корневого элемента или пролога (<?xml ...?>) часто делает файл полностью непригодным.

Пример устойчивости. При потере одной записи в большом XML-файле с журналом событий система может извлечь остальные записи, если используется потоковый парсер.

Excel (.xlsx). Формат .xlsx (начиная с Microsoft Office 2007) основан на стандарте Office Open XML (ECMA-376). Файл представляет собой ZIP-архив, содержащий множество XML-файлов, описывающих листы, стили, связи и метаданные.

Особенности структуры:

- Модульная архитектура: каждый лист хранится отдельно (/xl/worksheets/sheet1.xml).
- Поддержка формул, форматирования, изображений и макросов (в .xlsm).
- Встроенные механизмы контроля целостности (например, резервные копии в некоторых версиях Excel).

Устойчивость к повреждениям:

– Высокая по сравнению с текстовыми форматами. Благодаря архивной структуре, повреждение одного компонента (например, одного листа) не всегда делает недоступным весь документ.

– Современные программы (Excel, LibreOffice, библиотеки Python openpyxl, pandas) могут восстанавливать часть данных даже из частично повреждённых файлов.

– Однако если повреждён корневой файл архива ([Content_Types].xml) или архив не может быть распакован, восстановление становится невозможным.

Пример устойчивости. Если при передаче повреждён XML-файл с третьим листом, Excel может открыть первые два листа без ошибок, предупредив пользователя о проблеме.

Анализ показал, что устойчивость форматов данных к повреждениям варьируется в широких пределах. CSV и JSON обладают низкой надёжностью из-за отсутствия механизмов локализации ошибок и строгой зависимости от целостности всего документа. XML предлагает средний уровень устойчивости при использовании потоковых парсеров. Наиболее надёжным в условиях частичной потери данных оказывается формат Excel (.xlsx) благодаря своей модульной архитектуре и встроенной избыточности.

При проектировании систем межсистемного взаимодействия рекомендуется учитывать не только удобство обработки, но и потенциальные риски повреждения данных. В критически важных сценариях следует применять форматы с поддержкой частичного чтения, использовать контрольные суммы и предусматривать механизмы восстановления.

Заключение. Устойчивость формата данных к повреждениям – важный, но часто недооцениваемый фактор при проектировании систем обмена информацией. Текстовые форматы, такие как CSV и JSON, просты в использовании, но крайне уязвимы к синтаксическим ошибкам. В то же время структурированные и модульные форматы, включая XML и Excel, демонстрируют большую гибкость при частичной потере данных. При разработке надёжных систем следует выбирать форматы с поддержкой частичного чтения, использовать механизмы валидации и предусматривать резервные пути восстановления информации.

ЛИТЕРАТУРА

1. McKinney, W. Python for Data Analysis. – O'Reilly Media, 2022.
2. Bray, T. (Ed.). The JavaScript Object Notation (JSON) Data Interchange Format. – RFC 8259, 2017.
3. Microsoft. Excel Specifications and Limits. – Документация Microsoft, 2023.
4. PostgreSQL Global Development Group. PostgreSQL Documentation. – <https://www.postgresql.org/docs/>