УДК 004.043

РАЗРАБОТКА ФОРМАТА ТРАНСПОРТНОГО ФАЙЛА ЭКСПЕРИМЕНТАЛЬНЫХ ДАННЫХ УСТАНОВКИ КТМ

*А.В. Овчинников, В.М. Павлов, Ю.Н. Голобоков**Томский политехнический университет, Томск, Россия*

В настоящее время существует проблема интерпретации экспериментальных данных, получаемых удалёнными исследователями с установок токамак. Суть проблемы состоит в том, что возможности большинства форматов транспортных файлов ограничены в части хранения расширенных метаданных об эксперименте (например, данных о геометрии расположения сенсоров, используемых алгоритмах обработки и т.д.). При этом состав метаданных, сохраняемых в транспортный файл на различных установках, не регламентируется. В работе предлагается вариант унифицированного формата транспортного файла, который позволил бы расширить их возможности и тем самым предоставить удалённому от экспериментальной установки исследователю наиболее полную метаинформацию в унифицированном виде.

Ключевые слова: токамак, транспортный файл данных, формат файла.

THE DEVELOPMENT OF UNIFIED FILE FORMAT FOR TOKAMAKS DIAGNOSTIC DATA

*A.V. Ovchinnikov, V.M. Pavlov, Yu.N. Golobokov**Tomsk Polytechnic University, Tomsk, Russia*

The remote interpretation of the tokamaks diagnostic data is related to a certain difficulties. These difficulties are consequence of the limited capabilities of the most tokamak data file formats to store sufficient metadata (for example, sensors geometry or used data processing algorithms). In addition, the metadata structure provided by the most tokamak data files changes from device to device. The article presents a new data file format that expands the remote researcher opportunities and represent metadata structure in a unified way.

Key words: tokamak, data file, file format.

В настоящее время, как правило, экспериментальные термоядерные исследования совместно подготавливаются и проводятся многими лабораториями, расположенными на значительном расстоянии друг от друга. Зачастую это приводит к тому, что программа исследований на современных токамаках составляется с учётом научных интересов нескольких групп исследователей, удалённых друг от друга и от экспериментального комплекса. В настоящее время для таких групп существует проблема интерпретации данных. Для корректной интерпретации данных исследователю необходим определённый объём метаданных (например, данные о частоте дискретизации, месте размещения и углах обзора сенсора, значения токов в обмотках управления и т.д.). На практике эту информацию бывает довольно сложно получить, порой она распределена между многими источниками и не размещается в открытом доступе [1]. Одним из способов решения указанной проблемы на сегодняшний день является применение унифицированного формата транспортного файла. С целью определения такого формата для экспериментальных данных токамака КТМ [2] был проведён анализ массивов данных, получаемых с диагностических комплексов современных токамаков, а также форматов и программных средств управления данными, используемых в настоящее время.

Данные, получаемые с диагностик токамака, подразделяются на временные тренды, дву- и трёхмерные массивы, двумерные массивы, зависящие от времени, и медиаданные. Структура данных типа временной тренд используется для представления большинства необработанных данных, получаемых с модулей ввода аналоговых и дискретных сигналов, а также для хранения получаемых в результате обработки зависимостей параметров плазмы от времени. Структуры данных типа двумерный и трёхмерный массив, а также двумерный массив, зависящий от времени, часто используются на этапе после экспериментальной обработки для представления, например, пространственно-временных зависимостей. Медиаданные представляют собой массивы данных в одном из стандартных графических, видео- или аудиоформатов, например, JPEG, MPEG, MP3 и т.д. Кадры изображения регистрируются в качестве первичных данных с ПЗС-матриц видео- и инфракрасных камер. Этот тип данных выделяется отдельно, поскольку медиаданные имеют специализированный формат и передаются уже в обработанном, готовом для интерпретации виде.

Для удалённой интерпретации экспериментальных данных требуется, чтобы формат транспортного файла позволял хранить необходимый объём метаданных об эксперименте. Следовательно, рассмотренный состав информационных потоков необходимо также дополнить массивами метаданных, получаемых на установках токамак. Поскольку набор метаданных на различных установках не регламентируется, следует выделить общую, необходимую для обязательного внесения в файлы данных метаинформацию. В качестве такой метаинформации предлагается рассматривать данные, представленные в таблице.

Перечень метаданных для хранения в транспортном файле

Наименование	Состав метаданных
Данные об установке	Название установки. Геометрические параметры. Физические параметры. Трёхмерная модель установки с основными узлами, имеющими отношение к эксперименту.
Данные о диагностической подсистеме	Наименование диагностики. Место размещения сенсоров в трёхмерной модели. Текстовое описание диагностической подсистемы. Параметры подсистемы сбора данных.
Данные об используемых методах обработки	Перечень и параметры функций предварительной обработки. Перечень и параметры алгоритмов обработки данных. Формулы для обработки данных.
Данные об эксперименте	Дата и время эксперимента. Номер эксперимента с момента начала эксплуатации установки.

Далее рассмотрим используемые на исследовательских установках средства управления экспериментальными данными, а также форматы хранения данных. Для управления массивами данных на современных установках токамак широко используется СУБД MDSplus [3, 4]. Функционирование программных средств СУБД MDSplus может выполняться на платформах различных операционных систем (например, Windows, Linux, Mac OSX и т.д.). Анализ и применению MDSplus на различных установках токамак посвящено большое количество работ зарубежных и отечественных авторов [5–8]. Основной особенностью этой СУБД является то, что логическая организация массивов данных в MDSplus осуществляется посредством абстрактного дерева разряда (модели эксперимента). Типовая структура дерева разряда показана на рис. 1. Ветвями дерева разряда являются структурные узлы SUB1 и SUB2 типа CHILD, которые не содержат экспериментальных данных, а задают структуру дерева. Для хранения данных используются элементы типа MEMBER — NUM1 и NUM2. В целом средства MDSplus позволяют хранить большинство рассмотренных массивов данных, например, временные тренды, дву- и трёхмерные массивы, за исключением метаданных. В состав программных средств MDSplus входят утилиты для визуализации трендов, утилиты, обеспечивающие управление подсистемами сбора данных по заданному сценарию, а также средства автоматической загрузки данных с подсистем сбора данных в дерево разряда. При использовании MDSplus также существует возможность организации удаленного доступа к экспериментальным и метаданным [9].

Заметим, что возможности СУБД MDSplus ограничены в части хранения метаданных, поскольку они могут быть представлены только в числовом и текстовом виде. При этом состав и содержание метаданных не регламентируются, что

Рис. 1. Типовая структура дерева разряда СУБД MDSplus

приводит к трудностям при удалённой интерпретации данных. В концепции СУБД MDSplus также отсутствует понятие транспортного файла, что предусматривает организацию удалённого доступа ко всему дереву разряда для удалённого экспериментатора.

На установке MAST используется альтернативный вариант формата для хранения экспериментальных данных — HDF (Hierarchical Data Format) [10]. Абстрактная модель данных — ADM (Abstract Data Model) файла HDF определяет концепцию представления данных внутри файла. Ключевыми понятиями этой модели являются:

- Группа (Group) — объект, содержащий совокупность других именованных объектов, в том числе и групп;
- Массив данных (Dataset) — n -мерный массив элементов данных с атрибутами и метаданными;
- Пространство данных (Dataspace) — объект, определяющий параметры массива данных;
- Тип данных (Datatype) — объект, определяющий тип элементов данных;
- Атрибут (Attribute) — объект, определяющий дополнительный массив данных, связанный с группой, набором данных или типом данных;
- Перечень свойств (Property list) — объект, определяющий дополнительные опции для библиотеки доступа к файлу;
- Связь (Link) — именованный объект, определяющий связь между объектами.

Типовая логическая структура файла HDF-формата показана на рис. 2. Объекты, размещаемые внутри файла, представлены в виде древовидного направленного графа. В вершинах графа размещаются объекты

Рис. 2. Логическая структура файла в формате HDF

типа Group, Dataset или Datatype. Объекты типа Link представляют дуги графа. Каждая дуга имеет собственное имя. Объекты добавляются в граф путём операции связывания, которая создаёт именованную связь с объектами Group. Каждый объект файла является членом, по крайней мере, одной группы. Имена связей уникальны в пределах одной группы. Доступ к данным осуществляется с помощью указания соответствующего пути (path), по аналогии с файловой системой операционной системы UNIX. Таким образом, путь может быть абсолютным и относительным. Отличительная особенность от файловой системы заключается в том, что объекты не имеют собственных имён. Вместо имени используется путь доступа. Объекты типа Datatype и Dataspace создаются автоматически при создании объекта типа Dataset. Типы данных, под-

держиваемые форматом, подразделяются на простые (atomic) и сложные (composite). В состав простых типов данных входят такие типы, как integer, float, character, bitfield, opaque, enumeration и reference, в состав сложных типов — array, variable-length и compound. Для хранения метаданных об эксперименте форматом предусмотрен объект типа Attribute, который может содержать определённые пользователем текстовые наименования параметров и их значения. Для хранения значений параметров могут быть использованы все перечисленные типы данных. Формат HDF также предоставляет определённые возможности по управлению данными, также как логическое разбиение больших блоков данных на несколько взаимосвязанных частей (chunks), связанное хранение массивов данных в отдельных файлах, а также механизмы интеграции пользовательских программ сжатия.

В целом широкий выбор типов данных позволяет сохранять большинство экспериментальных и метаданных в файле формата HDF, в том числе и растровые изображения. Однако возможности формата ограничены в части хранения видеоданных, 3D-моделей и математических формул. Фактически файл формата HDF является контейнером для хранения разнородных данных, т.е. форматом файла не предъявляется каких-либо требований к составу обязательных метаданных. Также следует подчеркнуть общую сложность формата и ограниченную функциональность свободно доступных утилит редактирования и просмотра файлов HDF.

На российских установках токамак в качестве формата транспортного файла данных широко используется формат TFile [11, 12]. Структура файла в формате TFile показана на рис. 3, а.

Рис. 3. Структура транспортного файла в формате TFile (а) и структура поля паспорта данных (DASPassport) (б)

Транспортный файл в формате TFile представляет собой локальную копию записей базы данных DASSQL [11]. Записи размещаются в транспортном файле последовательно одна за другой. Каждая запись, помимо экспериментальных данных, также содержит дополнительные поля для хранения метаданных. В состав метаданных включаются поля, содержащие информацию о названии установки, номере плазменного разряда, наименовании диагностической подсистемы, дате и времени проведения эксперимента, типе записи, а также паспорт данных.

С точки зрения хранения метаданных наибольший интерес представляет поле паспорта данных — DASPassport. Структура поля DASPassport показана на рис. 3, б. Поле паспорта данных предназначено для хранения текстовых имён параметров, а также их значений. Значения параметров в поле DASPassport могут быть текстовыми, числовыми, представлять собой дату и время или бинарную структуру. В паспорте данных могут быть сохранены параметры настройки для подсистемы сбора данных, в параметрах типа «текст» существует возможность сохранять управляющие структуры XML и формулы для вычисляемых параметров, а в бинарных параметрах, при необходимости, может быть сохранен вложенный паспорт.

Отметим, что в целом формат TFile обладает всеми необходимыми средствами для хранения всех перечисленных структур экспериментальных данных. Также спецификация формата частично регламентирует состав полей метаданных. Обязательными являются название установки, номер плазменного разряда, наименование диагностики, дата и время проведения эксперимента, параметры настройки подсистемы сбора данных. Остальные метаданные из таблицы не являются регламентированными, однако формат не ограничивает возможности их добавления в файл, например, в виде документов структур MSOffice и XML. Возможности формата являются ограниченными лишь в части хранения трёхмерных моделей установки и узлов диагностики.

Таким образом, проведённый анализ массивов данных, получаемых на современных установках токамак, а также форматов и средств управления данными показывает, что используемые на сегодняшний день форматы транспортных файлов не в полной мере обеспечивают хранение требуемых метаданных, необходимых для удалённой интерпретации экспериментальных данных.

Для обеспечения удалённой интерпретации экспериментальных данных с установки КТМ авторами был разработан формат транспортного файла, учитывающий опыт предыдущих разработок. Формату было присвоено сокращённое название UED (Unified Experimental Data). В настоящее время проводится его внедрение на установке КТМ. Общая структура транспортного файла в формате UED показана на рис. 4.

Для обеспечения кроссплатформенности в заголовок файла введено дополнительно поле, обеспечивающее идентификацию порядка байт, в котором используется файл. Поле «размер файла» используется для определения количества данных, содержащихся в файле, а также для контроля целостности данных.

Рис. 4. Структура транспортного файла в формате UED

Блок метаданных размещается в конце файла и представляет собой текстовое поле сложной структуры. Для записи метаданных используются символы ASCII. Метаданные могут включать в себя вложенные метаданные. Каждый элемент метаданных задаётся с помощью текстового выражения вида:

<name>{type = <тип параметра>; value = <значение параметра>; offset = <смещение данных>; compression = <алгоритм сжатия>; next = <смещение следующего элемента метаданных>; encoding= <тип кодировки>;...}.

Таким образом, описание элемента метаданных включает в себя наименование элемента (name), его тип (type), значение (value) и дополнительные свойства. Спецификацией формата предполагается использование элементарных типов, таких, как char, int32, uint32, long64, ulong64, float и double, а также сложные типы —string, file, struct и vector.

Элементы простых типов, а также сложные типы struct и string аналогичны соответствующим типам языка программирования СИ. Элемент типа «vector» представляет собой специальную конструкцию, с помощью которой задаётся диапазон изменения величины. Элемент типа «file» содержит ссылку на внешний файл. Типовая структура поля метаданных показана на рис. 5.

Рис. 5. Типовая структура метаданных файла UED

Поле HASH предназначено для хранения информации об используемой хэш-функции и её значении. В качестве алгоритмов хэширования предлагается использовать алгоритмы MD5, TTH, SHA1 и SHA2.

Поле метаданных SEGMENTS представляет собой массив из нескольких структур, каждая из которых описывает соответствующий сегмент экспериментальных данных. Принадлежность сегмента к тому или иному блоку данных определяется с помощью идентификационной текстовой строки (path) вида: «/DEV/EXP/SUB/CHAN», где DEV обозначает уникальное имя экспериментальной установки, EXP — номер эксперимента, в котором были получены данные, SUB — наименование подсистемы, с которой получены данные, CHAIN описывает номер измерительного канала. Идентификационная строка используется для быстрой идентификации сегмента и поиска сегментов одного блока данных. Описания сегментов одного блока данных размещаются в файле последовательно в порядке возрастания номера сегмента. Доступ к метаданным сегмента осуществляется с помощью параметра «offset», который содержит абсолютное смещение метаданных сегмента.

Описание метаданных сегмента производится с помощью полей DEVICE, SUB, PROCESSING, EXP и DATA. Поле метаданных DEVICE предназначено для хранения информации об экспериментальной установке. Поле содержит информацию о наименовании установки, её физических и геометрических параметрах, а также трёхмерную модель установки. Для каждого элемента, описывающего тот или иной параметр установки, указываются тип данных, значение параметра и текстовый комментарий с описанием параметра. Для хранения трёхмерной модели предлагается использовать свободный формат COLLADA [13]. Объекты COLLADA могут быть размещены как непосредственно в транспортный файл, так и в виде отдельного файла. В случае сохранения объектов COLLADA в файл они размещаются в сжатом виде, при этом в поле 3D указывается тип используемого алгоритма сжатия.

Поле SUB предназначено для хранения данных о подсистеме сбора данных. В поле размещаются текстовые параметры, содержащие наименование подсистемы и комментарии, а также числовые и текстовые значения параметров конфигурации модулей ввода-вывода.

Поле PROCESSING содержит информацию об алгоритмах обработки данных. Поле состоит из одного или нескольких элементов. Каждый элемент поля предназначен для описания алгоритма обработки данных и содержит текстовое описание алгоритма обработки данных, указание способа записи формул и формулы, по которым производилась обработка. Запись формул предлагается производить в нотации TeX или на языке СИ.

Поле EXP содержит информацию о номере эксперимента, дате и времени эксперимента. Дата и время записываются в виде текстовой строки вида «YYYY-MM-DD hh:mm:ss».

Элемент DATA предназначен для хранения информации о структуре экспериментальных данных сегмента. Для задания независимых переменных, от которых зависят экспериментальные данные, форматом предлагается несколько способов. Наиболее простым является способ задания переменной путём использования типа «vector». Переменная типа «vector» определяется диапазоном изменения величины и шагом её изменения в пределах диапазона. Усложнённым вариантом описания независимых переменных является использование элемента типа ARGUMENT. Например, в случае описания функции вида $y = f(x, t)$ определение элемента имеет вид:

ARGUMENT{type = struct; offset = 1234; value = {t{type = double; value = {type = vector; begin = 0,0; end = 0,5; step = 0,1; measure = ms}}, x{type = int32 [1000]; measure = nm}}}

В приведённом примере для каждого значения переменной t в области данных существует 1000 значений переменной x , начиная со смещения 1234, и для каждой пары значений t, x существует значение зависимых переменных.

За каждым элементом типа ARGUMENT следует элемент типа VAR, определяющий массив зависимых переменных, соответствующих независимым. Элемент типа VAR представляет собой элемент метаданных, описывающих структуру зависимых переменных, которые представляют собой экспериментальные данные. В обязательном свойстве «offset» указывается абсолютное смещение начала соответствующей области зависимых переменных от начала области данных в байтах. Описание зависимых переменных приводится в порядке, соответствующем расположению экспериментальных данных. В случае, когда данные, например, представлены временными трендами из n значений, полученных на каждый из 16 каналов модуля АЦП, описание структуры данных будет выглядеть так:

$\text{VAR}\{\text{type} = \text{struct}; \text{offset} = 1234; \text{value} = \{\text{type} = \text{struct} [16]; \text{value} = \{\text{type} = \text{float} [n]; \text{measure} = V\}\}\}.$

Данные в сегменте размещаются в бинарном виде, последовательно, в порядке возрастания номера канала, т.е. сначала записываются n значений для первого канала АЦП, затем n значений для второго канала и т.д. Если экспериментальные данные представляют собой трёхмерный массив типа «float», зависящий от времени, то запись, описывающая структуру данных, выглядит следующим образом:

$\text{VAR}\{\text{type} = \text{struct}; \text{offset} = 1234; \text{value} = y\{\text{type} = \text{struct} [2]; \text{value} = \{\text{type} = \text{struct} [2]; \text{value} = \{\text{type} = \text{struct} [2]; \text{value} = \{\text{type} = \text{float} [2]\}\}\}\}\}.$

В данном случае описаны два временных среза и трёхмерный массив для каждого временного среза с двумя элементами по каждой координатной оси. В сегменте совместно размещаются данные, располагающиеся на соседних значениях координатной оси с наибольшим уровнем вложенности (рис. 6, а).

В случае хранения переменных со свойством «satellite» записывается сначала массив значений одной переменной, затем массив значений другой переменной, затем прочие переменные. Например, в случае задания данных структурой:

$\text{ARGUMENT}\{\text{type} = \text{struct}; \text{offset} = 0; \text{value} = V\{\text{type} = \text{double} [2]; \text{measure} = V\}, I\{\text{type} = \text{double} [4]; \text{measure} = A\}, \text{lambda}\{\text{type} = \text{double} [2]; \text{measure} = \text{nm}; \text{satellite} = V\}\}.$

На рис. 6, б показано, как сохраняются данные.

Рис. 6. Способы организации сегмента данных трёхмерного массива величин, зависящих от времени

В качестве другого примера может быть взят случай, когда необходимо описать структуру сегмента медиаданных, например, кадры jpeg:

$\text{VAR}\{\text{type} = \text{struct}; \text{offset} = 1234; \text{value} = y\{\text{type} = \text{struct} [2000]; \text{value} = \{\text{type} = \text{file}; \text{format} = \text{jpeg}; \text{extension} = \text{.jpg}\}\}\}.$

В приведённом примере экспериментальные данные содержат 2000 кадров, размещаемых в файле, начиная со смещения 1234 в формате JPEG.

ЗАКЛЮЧЕНИЕ

Используемые на современных установках токамак форматы транспортных файлов не в полной мере обеспечивают хранение требуемых метаданных, необходимых для удалённой интерпретации экспериментальных данных. В частности, возможности большинства форматов транспортных файлов ограничены в части хранения расширенных метаданных об эксперименте (например, данных о геометрии расположения сенсоров в пространстве, используемых методах и алгоритмах обработки и т.д.). При этом состав метаданных, сохраняемых в файл на различных установках токамак, не регламентирован. Для обеспечения удалённой интерпретации экспериментальных данных с установки КТМ авторами был разработан формат транспортного файла, учитывающий опыт предыдущих разработок. Формату было присвоено сокращённое название UED (Unified Experimental Data). В настоящее время проводится его внедрение на токамаке КТМ. Формат позволяет расширить возможности транспортных файлов и тем самым предоставить удалённому от экспериментальной установки исследователю наиболее полную метаин-

формацию в унифицированном виде. Полученные в работе результаты анализа форматов транспортных файлов и средств хранения экспериментальных данных также могут быть полезны для соответствующих модификаций имеющихся форматов.

Работа выполнена при финансовой поддержке Министерства образования и науки РФ.

REFERENCES

1. **Voznesenskiy V.A., Marusov N.L., Semenov I.B.** — Grid-technology for CTF: the concept of a unified information space and works with installation ITER data. M.: RRC «Kurchatov Institute», 2010. 21 p. (in Russian).
2. **Azizov E.A., Velikhov E.P., Tazhibaeva I.L., Shkol'nik V.S. et al.** Kazakhstan material testing tokamak KTM and controlled fusion questions. — Almaty, 2006. 236 p. (in Russian).
3. **Stillerman J.A., Fredian T.W., Klare K.A., Manduchi G.** MDSplus data acquisition system. — Rev. Sci. Instrum., 1997, vol. 68 (1), pp. 939—942.
4. **Official** website of system MDSplus developers. URL: <http://www.mdsplus.org/>. Access: 25.11.2011 (in Russian).
5. **Luchetta A., Manduchi G., Taliervo C.** Integration of MDSplus in real-time systems. — Fusion Engineering and Design, 2006, vol. 81, pp. 1835—1840.
6. **Lianzheng Q.U., Jiarong L.U.O., Lingling L.I., Mingxing Zhang, Yong Wang.** Application of MDSplus on EAST Tokamak. — Plasma Science and Technology, 2007, vol. 9, № 1.
7. **Kwon M.K., Choi I.S., Choi J.W., Hong J.S., Keum M.C., Kim K.H., Kim M.G., Park M.K., Seo S.H., Baek S., Jhang H.G., Kim J.Y.** The control system of KSTAR. — Fusion Engineering and Design, 2004, vol. 71, pp. 17—21.
8. **Voznesenskiy V.A., Semenov I.B., Sokolov M.M.** Organization of experimental data exchange exploiting MDSplus system. — VANT. Ser. Termoyadernyi sintez (Problems of Atomic Science and Technology. Ser. Thermonuclear Fusion), 2003, issue 4, pp. 68—72 (in Russian).
9. **Gardner H.J., Karia R., Manduchi G.** A web-based, dynamic metadata interface to MDSplus. — Fusion Engineering and Design, 2007, vol. 83, pp. 448—452.
10. **Official** website of HDF format developers. URL: <http://www.hdfgroup.org/>. Access: 25.11.2011 (in Russian).
11. **Sokolov M.M.** The possibility of Tokamak-10 measuring and computing system utilization in other experimental installations — VANT. Ser. Termoyadernyi sintez (Problems of Atomic Science and Technology. Ser. Thermonuclear Fusion), 2003, issue 4, pp. 73—78 (in Russian).
12. **Sokolov M.M.** Development of information systems for work with experimental data of controlled thermonuclear fusion installations. Dis. for cand. of techn. sciences scientific degree. M., 2004, 147 p. (in Russian).
13. **Official** website of COLLADA format developers. URL: <http://www.collada.org/>. Access: 25.11.2011 (in Russian).

AUTHORS

Ovchinnikov A.V. Tomsk Polytechnic University, prospect Lenina 30, 634050 Tomsk, Russia; ovchinnikov@tomics.tomsk.ru.

Pavlov V.M. Tomsk Polytechnic University, prospect Lenina 30, 634050 Tomsk, Russia; pavlov@tpu.ru.

Golobokov Yu.N. Tomsk Polytechnic University, prospect Lenina 30, 634050 Tomsk, Russia; golobokov@tpu.ru.

Received 2 January 2012
Problems of Atomic Science and Technology
Ser. Thermonuclear Fusion, 2012, issue 2, pp. 114—121.