OpenPOD: Открытая спецификация API переносимых драйверов

Версия API - 0.1

Версия спецификации - 0.1

Комментарии присылать Дмитрию Завалишину на dz@dz.ru

Черновики исходных кодов - https://github.com/dzavalishin/openpod

Данная спецификация разрабатывается сообществом Российских разработчиков операционных систем во исполнение договорённостей, достигнутых на конференции OS Day Иннополис 2015. Спецификация открыта для комментариев. Настоящая версия является первым драфтом, и будет разрабатываться на русском языке до достижения консенсуса по основному содержанию. Далее планируется перейти на английский язык как основной язык документа (русская версия будет поддерживаться как перевод с английского).

Disclaimer от dz: дамы и господа, я "вылил" этот документ из головы, прошу не судить строго, но отнестись конструктивно. Это - самый первый черновик, который я предлагаю как затравку для начала работы. Документ явно будет реструктуризирован - разбит на overview и детализацию + примеры кода. Сейчас предлагаю сосредоточиться на сути. Я прислал вам ссылку, которая позволяет не править текст, но оставлять комментарии к нему. Для размещения комментария необходимо выделить спорный фрагмент текста, нажать правую кнопку и выбрать пункт меню "комментарий", а в комментарии изложить сомнения или свой вариант. Чужие комментарии можно комментировать.

Цели

Спецификация призвана обеспечить возможность написания драйверов, переносимых между различными операционными системами.

Ограничения

В настоящий момент спецификация верифицируется только для графических драйверов (frame buffer). Следующим этапом предполагается описание драйверов блочных, сетевых и символьных устройств.

Данная спецификация описывает собственно API (и, возможно, ABI) драйвера, плюс описывает и содержит референсную реализацию хелпер-функций и компонент для поддержки части описанных интерфейсов. Референсная реализация не входит в спецификацию как таковую, и необязательна.

Общее описание

Спецификация описывает программный интерфейс (API). В последующих версиях планируется описание бинарного интерфейса (ABI). Реализация ABI опциональна.

Данный документ представляет собой обзор спецификации. Параллельно будут представлены подробный референс по всем функциям, хедер-файлы и референсная реализация функций фреймворка.

Документ специфицирует только интерфейс - функции фреймворка предоставляются as is, без гарантии и не являются единственной возможной реализацией. Разработчик ядра волен использовать их, или переписать их самостоятельно.

Термины

Драйвер - программная компонента, отвечающая за взаимодействие с определённым аппаратным обеспечением компьютера. Никакие два драйвера не должны работать с одним и тем же подмножеством аппаратуры одновременно.

Устройство - программный объект, реализующий интерфейс драйвера к определённому функциональному подмножеству обслуживаемой драйвером аппаратуры. Например, драйвер дисковой подсистемы может экспортировать в ядро несколько устройств, соответствующих отдельным дискам.

Лицензия

TBD
Референсные хедер-файлы и код, прилагаемые к данной спецификации, распространяются по лицензии LGPL.

Авторы и контрибуторы

Основная рабочая группа, в порядке подключения к работе над текстом :) :

Дмитрий Завалишин, dz@dz.ru - оригинальный драфт
Антон Бондарев, anton.bondarev2310@gmail.com
Алексей Хорошилов, khoroshilov@ispras.ru

Кан Анна, kan_a@mail.ru
Мезенцев Илья, i.mezentsev@wisetech.pro
Годунов Александр, nkag@niisi.ras.ru
Петренко Александр, a.k.petrenko@gmail.com
Рубанов Владимир, rubanov@rosalab.ru

Контрибуторы

Здесь Могла Бы Быть Ваша Фамилия :)

Общая структура драйвера

Драйвер экспортирует в ядро интерфейс управления драйвером в целом и одно или несколько устройств, каждое из которых имеет определённый класс и, соответственно, экспортирует как универсальный, так и специфичный для класса интерфейс. Драйвер может быть динамически загружен, запущен, остановлен и выгружен (предусмотреть признак невыгружаемости драйвера?). Устройства динамически синтезируются драйвером в результате сканирования фактической аппаратуры, и могут появляться и исчезать во время работы. Драйвер может экспортировать в ядро устройства разных классов (например, драйвер IBM PS/2 keyboard and mouse будет экспортировать два устройства различных классов).

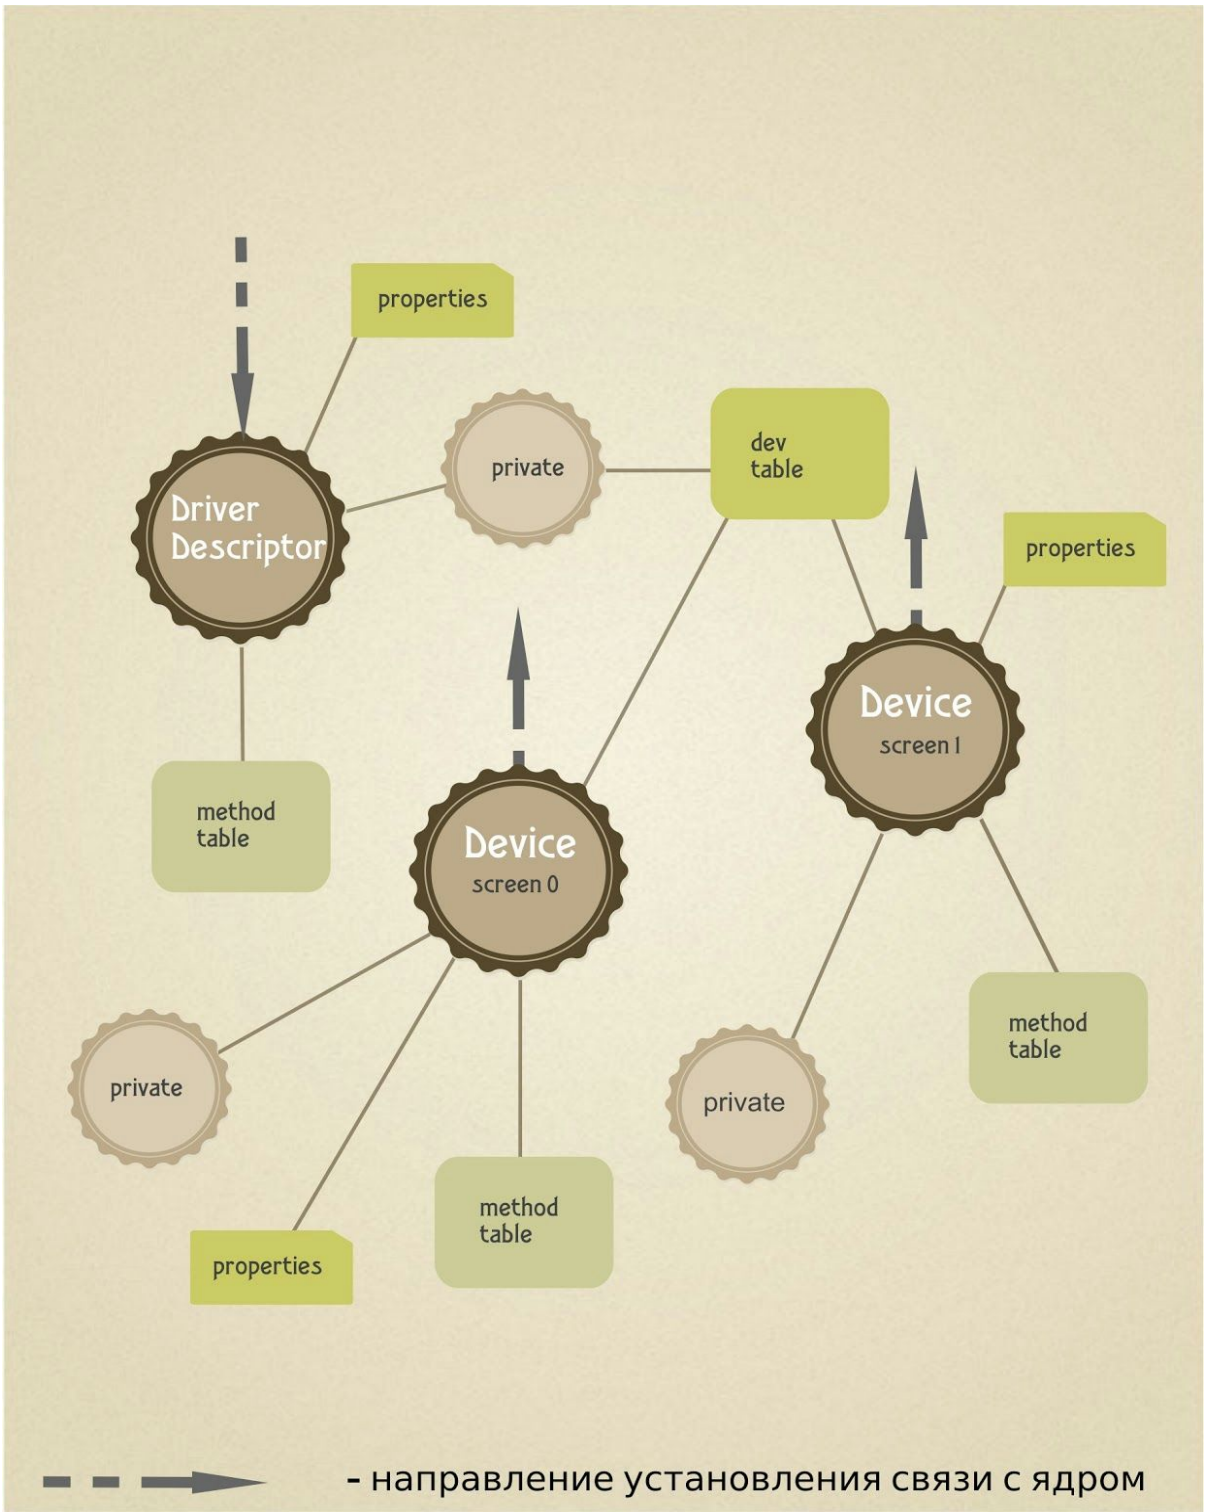

К спецификации прилагаются примеры драйверов и два скелета - для разработки минимального драйвера (одно статическое устройство без обнаружения, очереди запросов и нитей, несколько динамических устройств с поиском по PCI, нитями и очередью запросов).

Классы драйверов и устройств

Драйвер в целом и экспортируемые драйвером интерфейсы конкретных устройств должны быть отнесены к определённому классу, идентифицирующему специфический для данного типа устройств интерфейс ядра.

Если все устройства, которые экспортирует данный драйвер, единообразны, должен быть указан конкретный класс драйвера. Иначе для драйвера указывается класс **POD_DEV_CLASS_MULTIPLE**, а для устройства - конкретный класс.

```
#define POD_DEV_CLASS_VOID          0 // undefined or none
#define POD_DEV_CLASS_SPECIAL       1 // has user-defined non-standard interface
#define POD_DEV_CLASS_VIDEO         2 // framebuf, bitblt io
#define POD_DEV_CLASS_BLOCK         3 // disk, cdrom - block io
#define POD_DEV_CLASS_CHARACTER     4 // tty, serial, byte io
#define POD_DEV_CLASS_NET           5 // packet IO, has MAC address

#define POD_DEV_CLASS_KEYBD         6 // key (make/break) events
#define POD_DEV_CLASS_MOUSE         7 // mouse coordinate events

#define POD_DEV_CLASS_MULTIPLE      0xFF // driver only, has multiple dev types
```

Основной интерфейс драйвера

Lifecycle интерфейс

Определяет процесс инициализации, активации, сканирования аппаратуры, инициализации точек связи с ядром, деактивации и т.п.

pod_construct - инициализация структур данных драйвера, “статическая” связка с ядром ОС (подключение API, etc), но не сканирование или инициализация аппаратуры.

```
errno_t         pod_construct( pod_driver *drv );  // ENOMEM
```

pod_destruct - полное завершение работы драйвера (далее может следовать выгрузка). Должны быть закончены все нити, возвращены все ресурсы. Предполагается, что перед вызовом этого метода вызван deactivate. В противном случае destruct выполняет минимально возможные и наиболее жёсткие действия, аналогичные вызову deactivate.

```
errno_t         pod_destruct( pod_driver *drv );    // err?
```

pod_activate - инициализировать аппаратуру, запустить драйвер. До этого должно пройти сканирование аппаратуры. До запуска activate драйвер возвращает ошибку на

любой операционный вызов (запрос на ввод-вывод) и не инициирует обмен с ядром со своей стороны.

errno_t pod_activate(pod_driver *drv); // ENOMEM

pod_deactivate - остановить драйвер, деинициализировать аппаратуру.

errno_t pod_deactivate(pod_driver *drv); // err?

pod_sense - ядро просит драйвер произвести поиск устройств, но не инициализировать их. В рамках этого вызова драйвер может произвести цикл запросов к ядру для сканирования аппаратуры.

errno_t pod_sense(pod_driver *drv); // err?

pod_probe - ядро предлагает драйверу (PCI?) устройство, которое, по мнению ядра, этому драйверу соответствует. Драйвер верифицирует устройство и принимает или отказывается от обслуживания.

errno_t pod_probe(pod_driver *drv, bus?, dev?); // ENOMEM, EFAULT

Основной сценарий:

Ядро вызывает **pod_construct**, драйвер инициализирует структуры данных.

Ядро вызывает **pod_sense** и/или **pod_probe**, драйвер обследует аппаратуру и определяется с составом обслуживаемых устройств.

Ядро вызывае **pod_activate**, драйвер регистрирует в ядре известные ему устройства (**pod_dev_link**) и активируется.

Нормальная работа драйвера. Если в процессе работы драйвер обнаруживает или теряет устройства, происходят вызовы **pod_dev_link**/**pod_dev_unlink**.

Ядро вызывает **pod_deactivate**, драйвер останавливает (и дерегистрирует?) все устройства.

Ядро вызывает **pod_destruct**, драйвер освобождает все занятые ресурсы и может быть выгружен.

Работа драйвера:

Для каждого известного ему устройства драйвер вызывает **pod_dev_link**.

Нормальная работа устройства.

Драйвер вызывает **pod_dev_unlink**.

Работа устройства, в основном, состоит из вызовов rq_start ядром и ответных коллбеков драйвера по исполнении запроса. Если устройство предоставляет специфический для класса набор методов (поле **class_interface**), ядро может, также, вызывать эти методы. Пример специфического метода - get_mac_address для драйвера сетевого устройства.

Иллюстрации для стейт-машины TBD

Операционный интерфейс

Все точки входа этого раздела должны вызываться в контексте процесса/нити (не прерывания), могут быть кратковременно заблокированы (для работы с очередями), и не могут быть долговременно заблокированы. Первым параметром каждого вызова является структура устройства:

```
struct pod_device {
        uint32_t                magic;

        uint8_t                 class;
        uint8_t                 pad0;
        uint8_t                 pad1;
        uint8_t                 flags; // operating or not

        pod_driver              *drv;

        pod_dev_f               *calls; // dev io entry points

        pod_properties          *prop;

        void                    *class_interface; // dev class specific interface
        void                    *private_data;

        // ------------------------------------------------------------------
        // Fields below are used by default framework code

        // Request queue, used by pod_dev_q_ functions
        pod_q                   *default_r_q;       // default request q
        pod_request             *curr_rq;           // request we do now
        pod_thread              *rq_run_thread;     // thread used to run requests
        pod_cond                *rq_run_cond;       // triggered to run next request
};
```

pod_dev_stop - остановить устройство (например, чтобы отсоединить или выключить)
pod_dev_start - запустить устройство

errno_t pod_dev_stop(pod_device *dev);
errno_t pod_dev_start(pod_device *dev);

pod_rq_enqueue - запросить ввод-вывод

pod_rq_dequeue - снять запрос, если это ещё возможно (фактически, вызов необязательный - имеет право всегда говорить, что уже поздно)

pod_rq_fence - гарантировать, что все предыдущие запросы будут отработаны до любого последующего

pod_rq_raise - изменить (обычно - повысить:) приоритет запроса. Необязательно к реализации, но отсутствие может серьёзно влиять на отзывчивость системы.

done - внутри структуры запроса ввода-вывода есть указатель на функцию, которая будет вызвана по исполнению запроса. Функция **done** может быть вызвана контексте прерывания. Ядро должно самостоятельно обеспечить проверку на контекст прерывания и, при необходимости, конвертацию вызова в контекст нити ядра или иной уместный контекст.

```
struct pod_request {
	uint8_t		request_class;	// block/character/net/video io
	uint8_t		operation;	// op id - read/write/clear screen/etc

	// request priority, more = earlier
	uint32_t	io_prio;

	pod_rq_status	err;		// результат исполнения, 0 = ок

	// Req struct part specific for request class and op id
	void		*op_arg;

	// Driver will call this when done
	void		(*done)( pod_request *rq);

};


// ENOMEM если очередь переполнена
errno_t	pod_rq_enqueue( pod_device *dev, pod_request *rq );
```

// если ещё не сделано - остановить
errno_t pod_rq_dequeue(pod_device *dev, pod_request *rq);

// гарантировать, что предыдущие запросы будут отработаны до исполнения следующих
errno_t pod_rq_fence(pod_device *dev, pod_request *rq);

// изменить приоритет
errno_t pod_rq_raise(pod_device *dev, pod_request *rq, uint32_t io_prio);

Комментарий: в данной спецификации предполагается, что драйвер самостоятельно хранит и обрабатывает (сортирует и т.п.) очередь запросов. Решение принято в связи с тем, что современная аппаратура зачастую готова реализовывать очереди аппаратно. Кроме того, это необходимо для драйверов virtio.

Стандартные хелперы (обеспечиваются фреймворком)

Очередь запросов, базовая реализация.

// создать очередь
errno_t pod_q_construct(pod_q **q);

// уничтожить очередь
errno_t pod_q_destruct(pod_q *q);

// поставить запрос в очередь
errno_t pod_q_enqueue(pod_q *q, pod_request *rq);

// забрать запрос из очереди
errno_t pod_q_dequeue(pod_q *q, pod_request *rq);

// выставить ограду
errno_t pod_q_fence(pod_q *q, pod_request *rq);

// отсортировать с учётом оград
errno_t pod_q_sort(pod_q *q, pod_request *rq, int (*cmp)(*rqa, *rqb));

// функция сравнения по приоритету
int rq_prio_cmp(pod_request *rqa, pod_request *rqb)

// Dequeue request - return (and delete from q) last request.
// returns ENOENT and sets rq to 0 if q is empty.

```
errno_t                 pod_q_get_last( pod_q *q, pod_request **rq );
```

Комплект функций фреймворка, которые реализуют дефолтный механизм работы с очередью запросов - для типового драйвера с одной очередью.

```
errno_t         pod_dev_q_construct( pod_device *dev );
errno_t         pod_dev_q_destruct( pod_device *dev );
errno_t         pod_dev_q_enqueue( pod_device *dev, pod_request *rq );
errno_t         pod_dev_q_dequeue( pod_device *dev, pod_request *rq );
errno_t         pod_dev_q_fence( pod_device *dev, pod_request *rq );
errno_t         pod_dev_q_raise( pod_device *dev, pod_request *rq, uint32_t io_prio );

// должна быть реализована в драйвере, запускает запрос на исполнение
errno_t         pod_dev_q_exec( pod_device *dev, pod_request *rq );

// реализована в фреймворке, вызывается кодом драйвера по завершении в/в, можно из прерывания
errno_t         pod_dev_q_iodone( pod_device *dev );
```

Запросы для видеодрайверов

Запросы отрабатываются через pod_request (структура передаётся через указатель op_arg), или через таблицу методов class_interface устройства.

```
// значение поля operation или индекс в таблицу методов class_interface
enum pod_video_operartions {
        nop, getmode, setmode,
        clear_all, clear,
        move,
        write, read,
        write_part, read_part
};

// формат пикселя
enum pod_pixel_fmt {
        pod_pixel_rgb,          // 24 бита
        pod_pixel_rgba,         // 32 бита, a is ignored by hw
        pod_pixel_r5g6b5,       // 16 бит, 5-6-5
        pod_pixel_r5g5b5,       // 16 бит, 5-5-5
};

// флаги блиттера (режим копирования пикселей на экран - с экрана читаем всегда!)
```

```
enum pod_v_flags {
        pod_video_ignore_zbuffer, // игнорировать z координату
        pod_video_ignore_alpha,   // игнорировать альфа-канал
};

// clear
struct pod_video_rq_sqare
{
        uint32_t        x, y;
        uint32_t        x_size, y_size;
};

// move from screen to screen
struct pod_video_rq_2sqare
{
        uint32_t        from_x, from_y;
        uint32_t        from_x_size, from_y_size;

        uint32_t        to_x, to_y;
        uint32_t        to_x_size, to_y_size;
};

// write, read - пересылка полного битмапа на экран или с экрана
struct pod_video_rq_rw
{
        uint32_t        x, y;
        uint32_t        x_size, y_size;

        uint32_t        z;
        pod_v_flags     flags;

        char            *buf;

        pod_pixel_fmt       buf_fmt;        // формат пикселя буфера ядра
};

// write_part, read_part - пересылка части битмапа на экран или с экрана
struct pod_video_rq_rw_part
{
        uint32_t        from_x, from_y;             // point to start in buf
        uint32_t        from_x_size, from_y_size;   // full size of bitmap in buf

        uint32_t        to_x, to_y;                 // point to start on screen

        uint32_t        move_x_size, move_y_size;       // size of sqare to move
```

```
        uint32_t        z;                              // z position
        pod_v_flags     flags;

        char            *buf;

        pod_pixel_fmt       buf_fmt;        // формат пикселя буфера ядра
};


// getmode, setmode
struct pod_video_rq_mode
{
        // если невалидно - ставим ближайший вверх, если нет - ошибка
        uint32_t        x_size, y_size;
        // формат пикселя экрана, желательно rgba
        pod_pixel_fmt       buf_fmt;

        // Возвращаемое значение.
        physaddr_t    vbuf;           // может быть 0? тогда всё через методы?

};
```

Запросы для дисковых драйверов

```
// значение поля operation или индекс в таблицу методов class_interface
enum pod_block_operartions {
        nop, read,write, trim
};

// trim
struct pod_block_rq
{
        diskaddr_t    block_no;
        uint32_t        block_count;
        uint32_t        block_size;
};

// read, write
struct pod_block_io_rq
{
        diskaddr_t    block_no;
        uint32_t        block_count;
        uint32_t        block_size;
```

```
        physaddr_t    physmem_addr;
};
```

Дополнительный интерфейс драйвера

Не обязателен к реализации. Точки входа должны присутствовать, но могут работать частично или не работать вообще. Неработающие функции или подфункции должны возвращать разумный код ошибки.

Свойства (rich man's ioctl)

Именованные свойства драйвера или устройства.

errno_t pod_get_property(pod_properties *p, const char *pName, char *pValue, int vlen);
errno_t pod_set_property(pod_properties *p, const char *pName, const char *pValue);
errno_t pod_list_properties(pod_properties *p, int nProperty, char *pName, int vlen);

pod_getproperty - получить значение свойства. Вызов не может приводить к изменению состояния драйвера или устройства.

pod_setproperty - установить значение свойства. Может иметь сайд-эффект по изменению состояния драйвера или устройства (фактически - может являться вызовом метода без параметров.)

pod_listproperties - Получить имя очередного свойства. Для получения всех имён свойств вызывается циклически, до получения ненулевого (ошибочного) значения функции.

pName - имя свойства, ascii строка, завершённая нулём.
pValue - значение свойства, ascii строка, завершённая нулём.
vlen - размер буфера для получения значения или имени.

Возвращаемые значения

ENOENT - нет свойства с указанным именем или (для listproperties) нет больше свойств.
EFAULT - не удалось получить значение свойства (но имя свойства верное)
EINVAL - не удалось установить значение свойства (но имя свойства верное), недопустимое значение свойства.

Сохранение и восстановление состояния драйвера

pod_save_state - сохранить состояние драйвера в XML. Выполняется deactivate, но полное состояние драйвера и устройства сохраняется.
pod_load_state - состояние восстанавливается из XML, выполняется activate.

Между вызовами возможна полная остановка аппаратуры и перезагрузка ОС.

Управление энергопотреблением

pod_sleep - аппаратура устройства переводится в режим экономии энергии. драйвер должен быть деактивирован. Возможно указание степени засыпания - в частности, в терминах скорости восстановления.
pod_awake - аппаратура переводится в нормальный рабочий режим.

Интерфейс ядра ОС

Ядро ОС должно предоставлять драйверу описанный ниже набор функций. Драйвер не должен использовать никакие иные точки входа в ядро.

При статической линковке или если технология загрузки загружаемого драйвера допускает динамическую привязку к экспортируемым функциям ядра, доступ к точкам входа ядра осуществляется напрямую. Если это невозможно, ядро должно прописать в поле **kernel_driver_api** таблицу указателей на соответствующие функции.

TBD

Специфический интерфейс ядра для драйвера

pod_dev_link - драйвер сообщает ядру о наличии/появлении устройства, ядро подключает устройство к себе и, если нужно, стартует его

pod_dev_unlink - драйвер сообщает, что устройство более не валидно. После возврата из этого вызова драйвер имеет право деаллоцировать структуры данных устройства, видимые ядру.

pod_dev_event - репорт о событии (ошибке, отказе?) устройства

Управление ресурсами

pod_get_bus_list - получить все имеющиеся в железе шины
pod_get_pci_bus - возвращает главную шину PCI
pod_get_usb_bus - … USB
...more…

pod_bus_scan - искать устройство на шине по определённым параметрам
pod_bus_enum - перечислить все устройства на шине

pod_bus_reserve_resource - захватить ресурс (порт, память, прерывание)
pod_bus_release_resource - освободить ресурс

Управление памятью

pod_alloc_physmem - выделяет физическую память без отображения, постранично
pod_alloc_kheap - выделяет виртуальную память ядра (не пейджируемую)
pod_alloc_vaddr - выделяет виртуальное адресное пространство без памяти

pod_free_physmem
pod_free_kheap
pod_free_vaddr

map/unmap physmem (kernel can verify that driver maps just what it allocated)

pod_map_mem - физ адрес, вирт адрес, флаг некешируемости?
pod_unmap_mem

// нужно это? или требовать от ядра, чтобы все запросы приходили на привязанную память? для блочных оно так и есть - в запросе вообще приходит физпамять.

pod_wire_mem - для невиртуальной памяти nop, виртуальную пейджирует в, гарантирует от вытеснения (память превращается в непейджируемую) - НЕЛЬЗЯ вызывать в контексте точки входа, только из треда драйвера.
pod_unwire_mem - отменить непейджируемость

Логирование

syslog?

Нити и синхронизация

В целом планируется в рамках pthread, дополнения приветствуются.

Загрузка загружаемого или привязка статического драйвера

Структура дескриптора драйвера

```
pod_driver {
        uint32_t        magic;          // magic number

        // Minor change means API is extended, but compatible
        uint8_t         API_version_major;
        uint8_t         API_version_minor;

        // i32, i64, arm32, arm64, mips32, mips64, ...
        uint8_t         arch_major;
        uint8_t         arch_minor;   // undefined, must be 0

        uint8_t         class_id;
        uint8_t         pad0;
        uint8_t         pad1;
        uint8_t         pad2;

        //uint32_t      capabilities; // tbd.

        char            *name;

        lifecycle_f     *calls;         // lifecycle entry points function pointers

        pod_properties  *prop;

/**
 * таблица функций ядра для драйвера - используется если нельзя пролинковать
 * напрямую (функции заменяются матросами, которые через эту таблицу идут в
 *  ядро - см. pod_kernel_api.h)
**/
        kernel_f        *kernel_driver_api;

        void            *private_data; // private driver's data structure
```

};

Статическая линковка

Привязка статически линкованного драйвера к ядру должна осуществляться посредством ссылки из ядра на структуру дескриптора драйвера. Вопрос поддержки ядром списка доступных ему драйверов в этом документе не обсуждается.

Связка загружаемого драйвера

Для elf (pe) модулей - загрузить модуль, найти в таблице get_pod_driver, вызвать, получить дескриптор, работать через него. Если нет таблицы символов - считать, что get_pod_driver находится в начале сегмента кода. Если нельзя найти сегмент кода - искать маджик дескриптора (структуры pod_driver) по всему бинарному драйвера.

pod_driver * get_pod_driver(void);