

# Управление процессами

(часть 2)

# Планирование потоков

# Планирование потоков

Планирование – определение момента прерывания текущего активного потока и выбор следующего выполняемого потока из очереди.

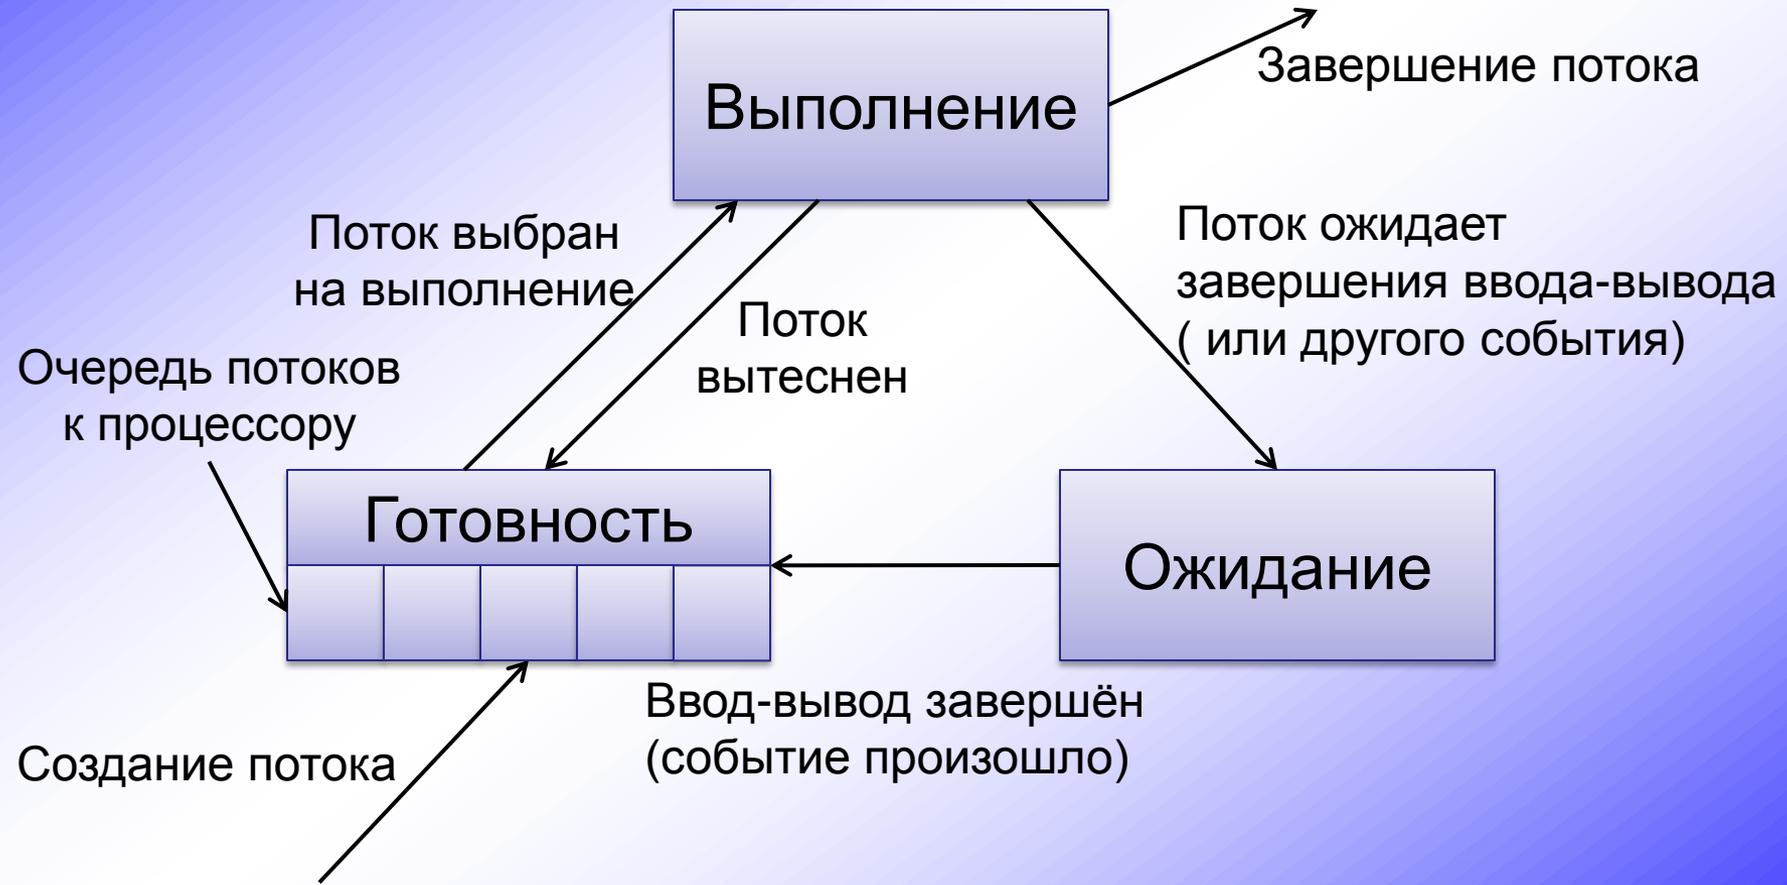
Динамическое планирование – планирование на основе анализа текущей ситуации.

Статическое планирование – планирование на основе расписания.

# Состояния потока

- Выполнение – активное состояние потока, во время которого поток обладает всеми необходимыми ресурсами и выполняется процессором.
- Ожидание (блокировка) – пассивное состояние потока, обусловленное ожиданием какого-либо внешнего события.
- Готовность – пассивное состояние потока, обладающего всеми необходимыми ресурсами, во время обработки процессором другого потока.

# Граф состояний потока



# Моменты перепланировки

Перепланировка – изменение состояния потоков и пересмотр очереди в связи с каким-либо событием, происшедшем в системе.

# События, приводящие к перепланировке

- Создание потока (перевод в «готовность»).
- Завершение потока (снятие задачи).
- Изменение приоритета потока.
- Прерывание от таймера об окончании отведённого потоку кванта (перевод из «выполнения» в «готовность»).
- Системный вызов с запросом активной задачи на занятый ресурс (перевод из «выполнения» в «ожидание»).

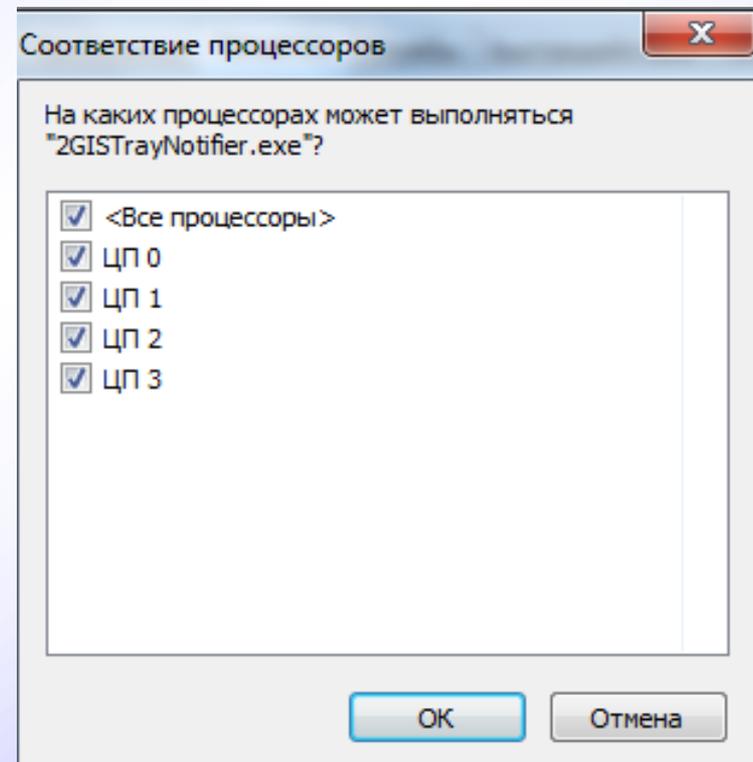
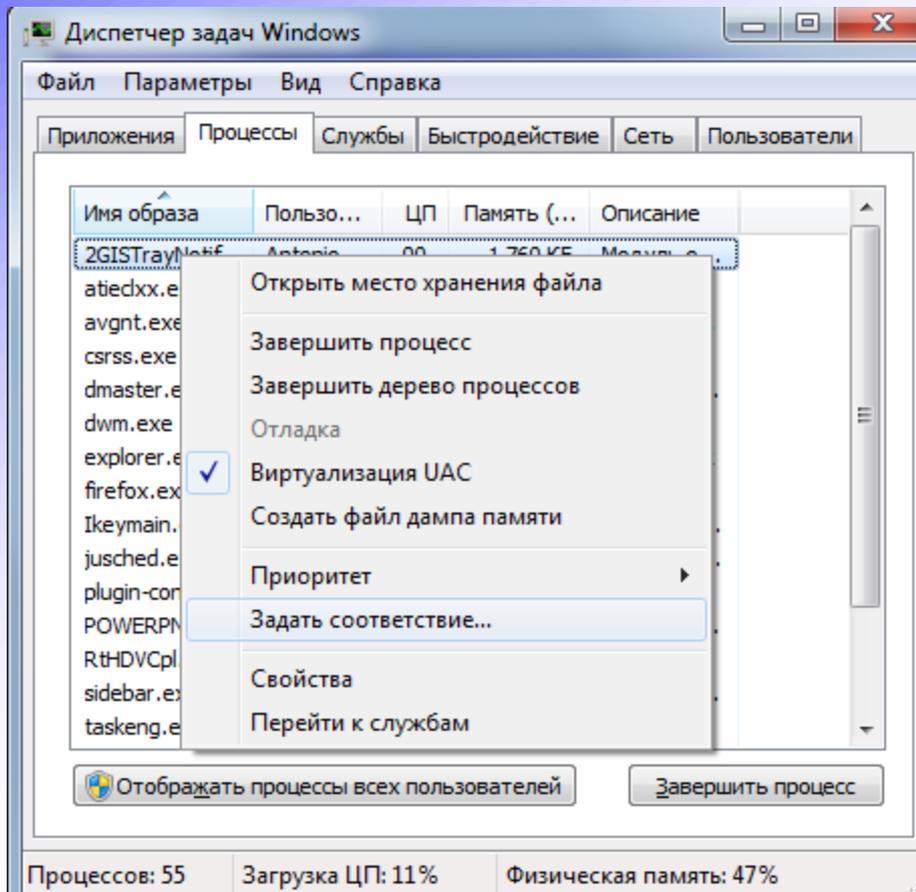
# События, приводящие к перепланировке

- Системный вызов с освобождением ресурса активной задачей (перевод из «ожидания» в «готовность» ожидающего ресурс потока).
- Внешнее прерывание о завершении устройством операции ввода-вывода (перевод из «ожидания» в «готовность» ожидающего ресурс потока).
- Внутреннее прерывание об ошибке при выполнении активной задачи (снятие задачи).

# Привязка потоков к процессору

- По умолчанию в ОС используется нежесткая привязка потоков к процессорам – при прочих равных условиях система пытается выполнять поток на том же процессоре, на котором он работал в последний раз.
- Преимущество – возможность повторного использования данных, сохранившихся в кэше процессора.

# Привязка потоков к процессору



# Вытесняющие и невытесняющие алгоритмы планирования

- Невытесняющие – активный поток выполняется до тех пор, пока не передаст управление ОС (функции планирования разделены между ОС и приложениями).
- Вытесняющие – переключением процессора с одного потока на другой управляет ОС (планирование осуществляется только ОС).

# Особенности невытесняющих алгоритмов планирования

- На время выполнения потока теряется управление системой для пользователя.
- Разработка части функций планировщика ложится на программиста.
- Более простое решение проблем совместного использования ресурсов.
- Более высокая скорость переключения с потока на поток.

# Действия при переключении ПОТОКОВ

- Сохранение контекста текущего потока.
- Загрузка контекста выбранного следующим потока.
- Запуск выбранного потока на выполнение.

# Факторы, влияющие на планирование

- Затраты времени на переключение процессов.
- Количество процессов, выполняющих вычисления (ограниченных возможностями процессора).
- Количество процессов, ограниченных возможностями устройств ввода-вывода.

# Стратегии планирования

Стратегия планирования определяет, какие процессы планируются на выполнение для достижения поставленной цели:

- по возможности заканчивать вычисления (процессы) в порядке их создания;
- отдавать предпочтение более коротким вычислительным задачам;
- предоставлять всем пользователям (их процессам) одинаковые услуги, в том числе и одинаковое время ожидания.

# Дисциплины планирования

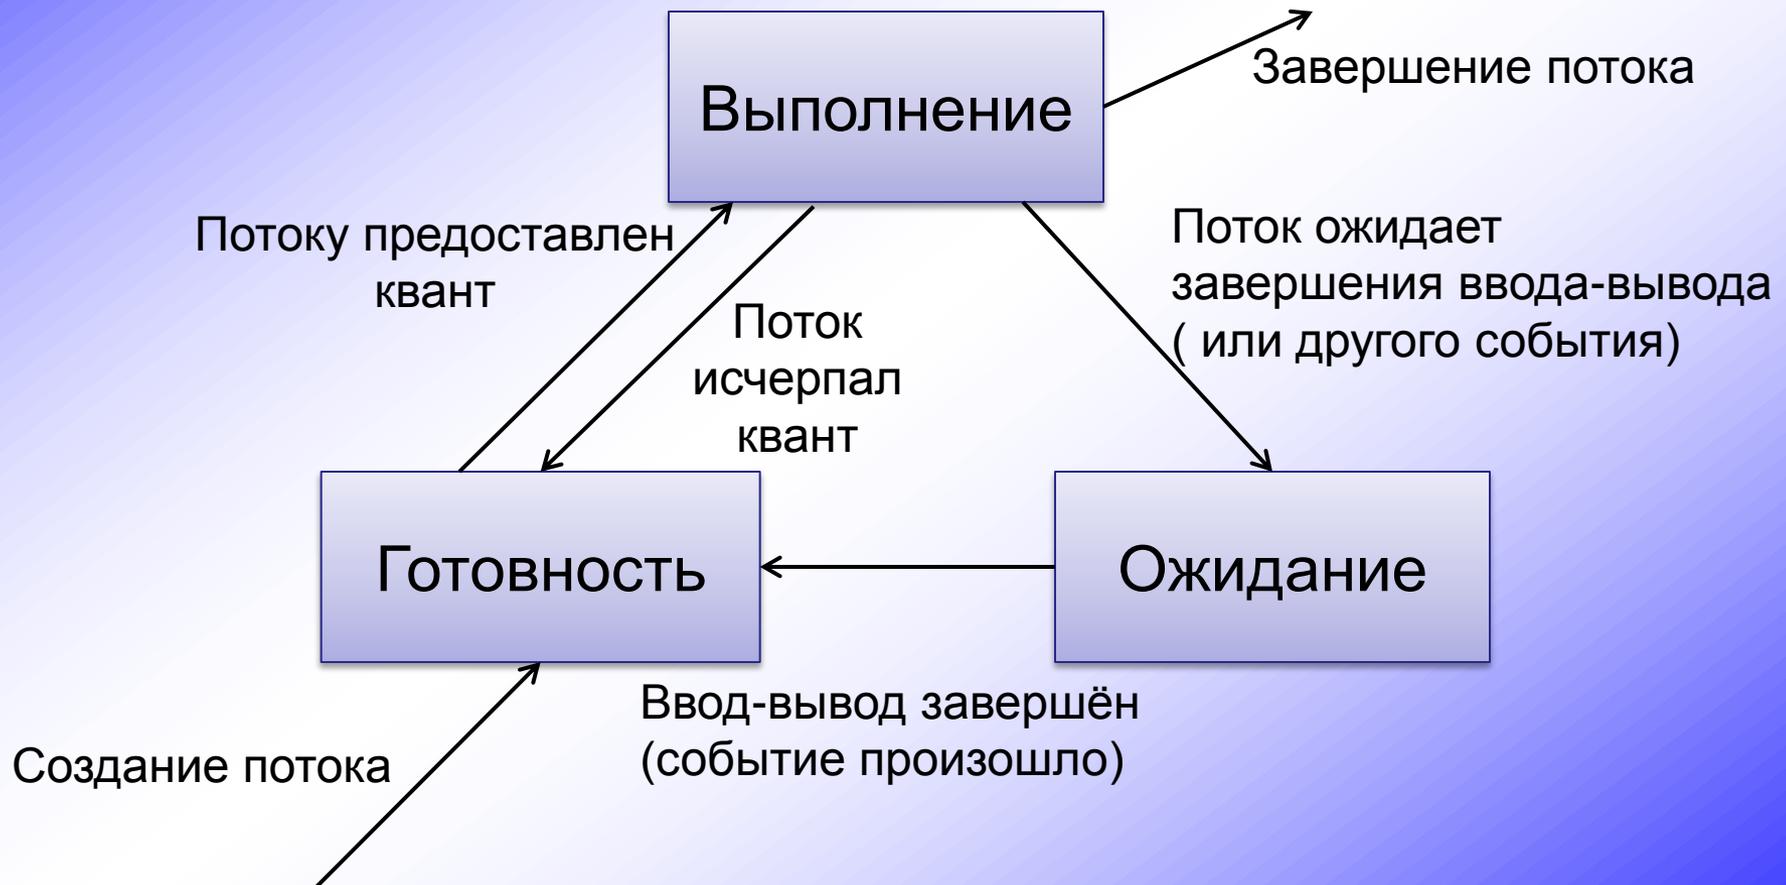
Дисциплина планирования – правило формирования очереди готовых к выполнению задач:

- алгоритмы, основанные на квантовании;
- алгоритмы, основанные на приоритетах.

# Алгоритмы планирования, основанные на квантовании

- Квант – выдаваемый потоку ограниченный непрерывный период процессорного времени.
- При исчерпании кванта поток переносится в конец очереди.
- Все алгоритмы не используют априорные знания о потоке, а используют только информации о работе потока в системе.

# Граф состояний потока в системе с квантованием



# Причины смены активного потока

- Поток завершился и покинул систему.
- Произошла ошибка.
- Поток перешёл в состояние ожидания.
- Поток исчерпал выделенный квант процессорного времени.

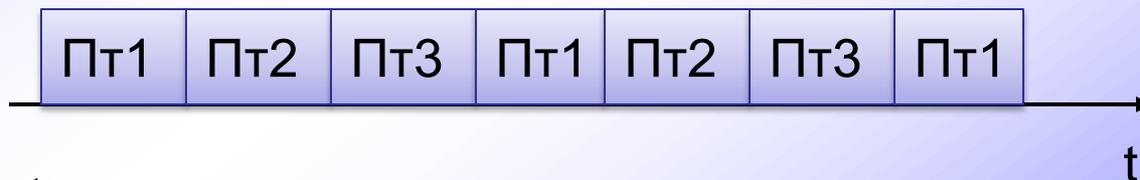
# Алгоритмы планирования, основанные на квантовании

- Одинаковая длительность квантов.
- Уменьшение длительности кванта после первого цикла выполнения потока.
- Увеличение длительности кванта после первого цикла выполнения потока.
- Предпочтение потоков, обращающихся к устройствам ввода-вывода.

# Алгоритм планирования с одинаковой длительностью кванта

При увеличении длительности кванта:

- увеличивается вероятность завершения работы потока за один цикл;
- приближение работы системы к однозадачной.

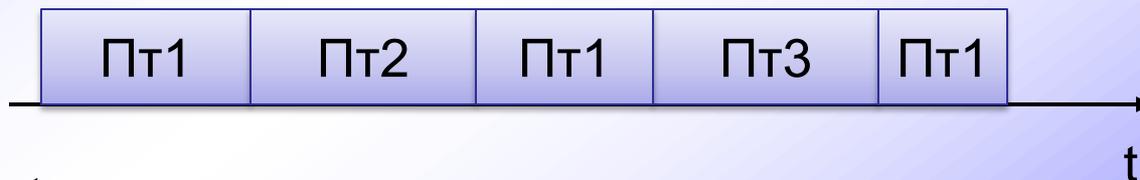


$t$  – процессорное время.

Пт – поток.

# Алгоритм планирования с уменьшением кванта

- При невыполнении потока за один цикл длительность каждого следующего кванта уменьшается до определённого значения.
- Быстрое выполнение небольших задач.
- Переход длительных задач в фоновый режим.

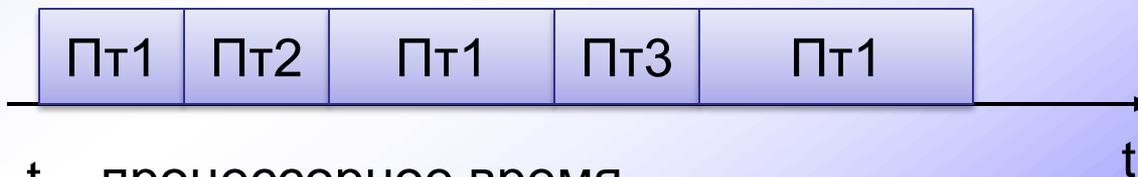


t – процессорное время.

Пт – поток.

# Алгоритм планирования с увеличением кванта

- При невыполнении потока за один цикл длительность каждого следующего кванта увеличивается до определённого значения.
- Используется в системах с большим количеством задач, требующих длительных вычислений.
- Снижаются расходы процессорного времени на переключения с потока на поток.



t – процессорное время.

Пт – поток.

# Алгоритм планирования с предпочтением потоков обращающихся к вводу-выводу

- Потоки часто обращающиеся к вводу-выводу используют квант процессорного времени не полностью.
- Отдельная очередь потоков, в предыдущем цикле не полностью использовавших квант, просматривается в первую очередь.



$t$  – процессорное время.

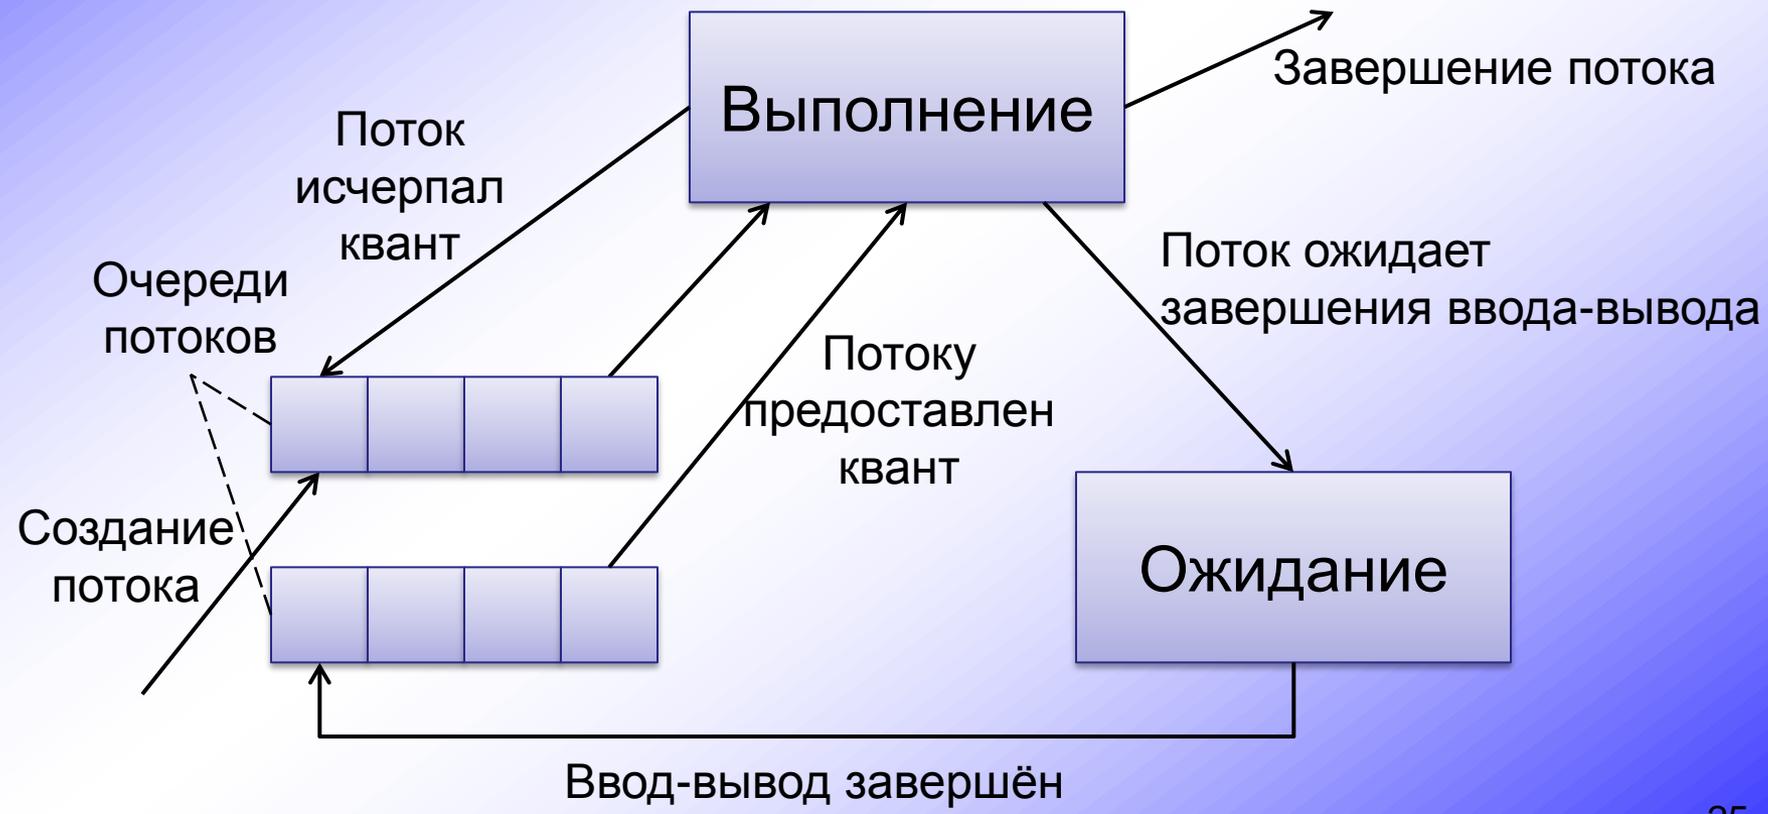
Пт – поток.

Обращение к устройству  
ввода-вывода потока1

Завершение операции  
ввода-вывода для потока1

$t$

# Граф состояний потока при предпочтении потоков, обращающихся к вводу-выводу



# Алгоритмы планирования, основанные на приоритетах

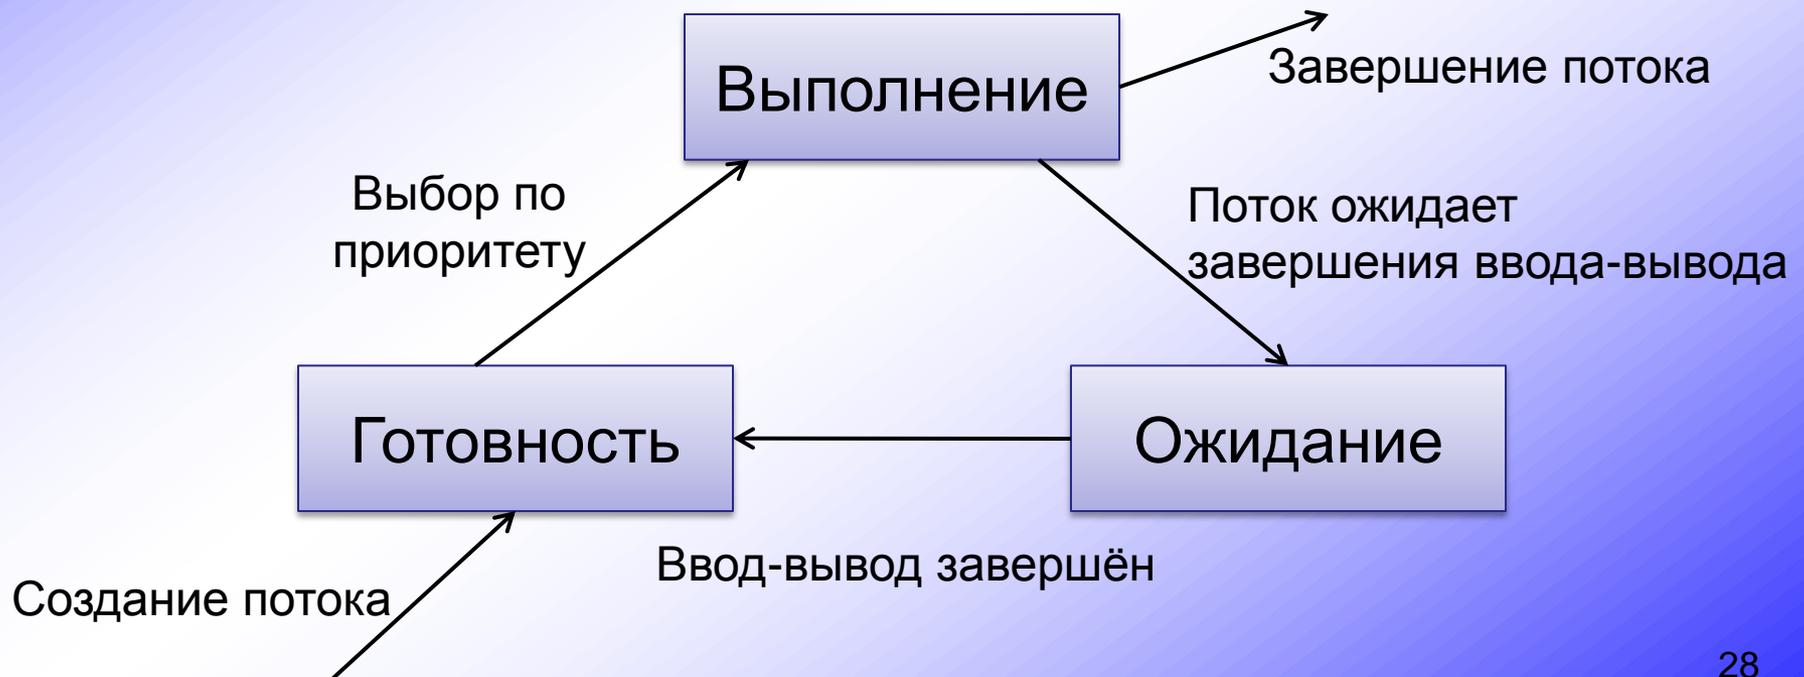
- Приоритет – число, присваиваемое потоку, которое характеризует его степень привилегированности при использовании ресурсов системы.
- При назначении приоритета ОС учитывает приоритет создателя данного потока (пользователя, другого потока).

# Алгоритмы планирования, основанные на приоритетах

- ОС поддерживает свою очередь потоков для каждого значения приоритета. Потоки, перешедшие в состояние «готовность», помещаются в конец очереди, соответствующей приоритету потока.
- При использовании статических (неизменяемых) приоритетов существует возможность невыполнения низкоприоритетных задач.

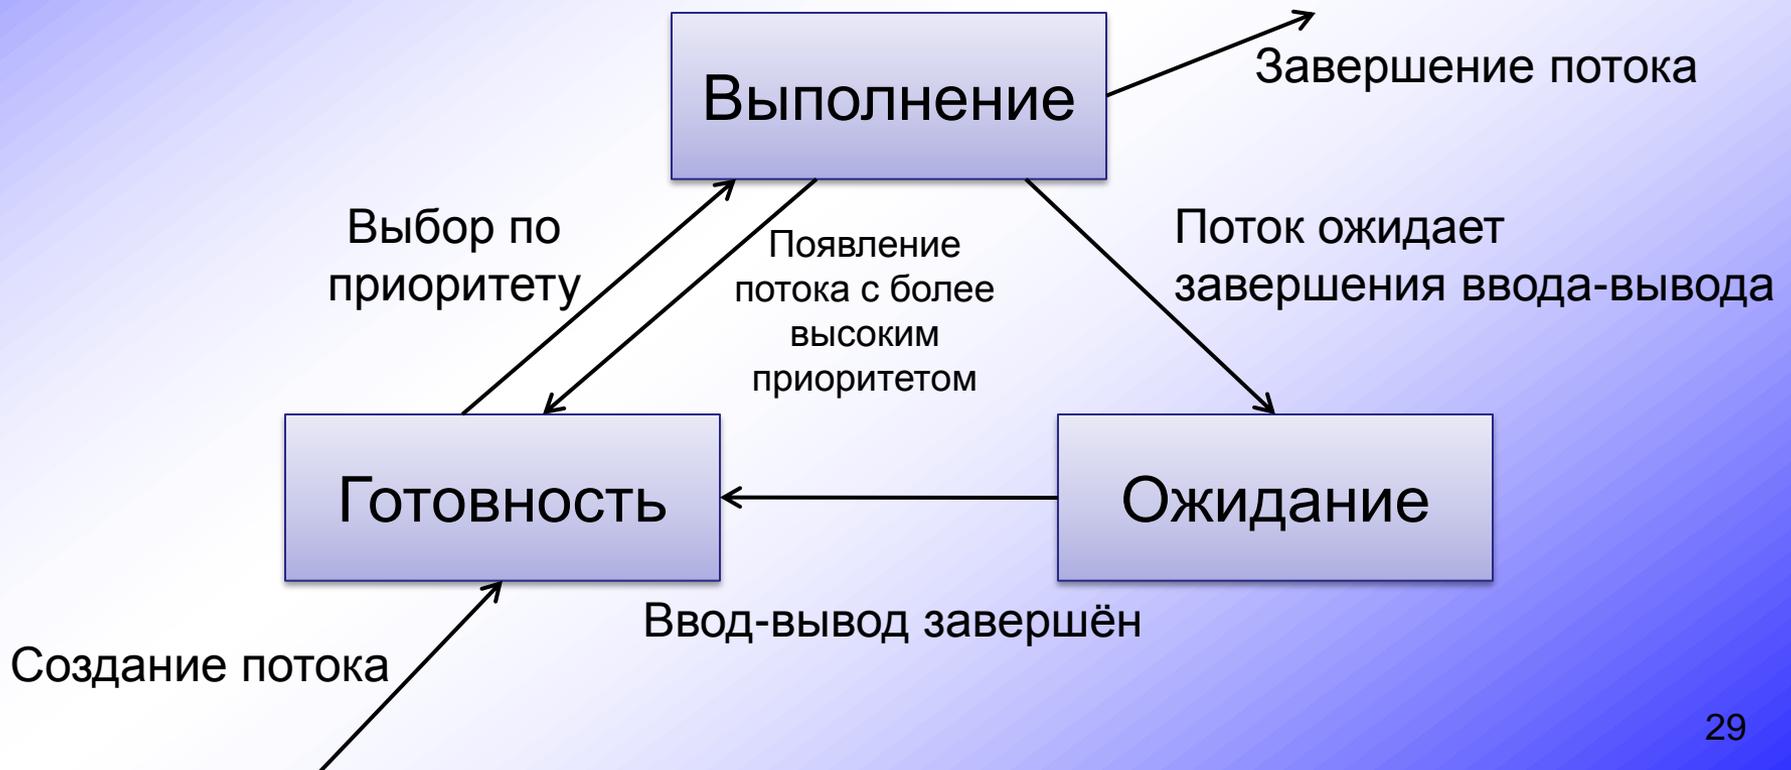
# Планирование с относительными приоритетами

При появлении в очереди потока с более высоким приоритетом активный поток выполняется до тех пор пока сам не покинет процессор.



# Планирование с абсолютными приоритетами

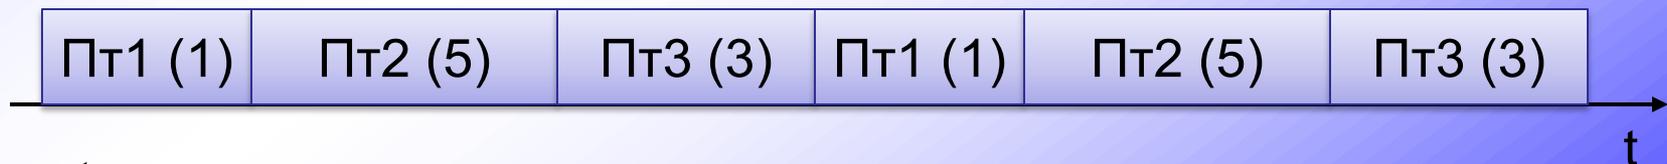
При появлении в очереди потока с более высоким приоритетом активный поток сразу завершает свою работу.



# Смешанные алгоритмы планирования

Основаны на квантовании, но величина кванта и/или порядок выбора потока из очереди определяются приоритетами:

- выбор из очереди каждого следующего потока, длительность кванта больше для потоков с более высоким приоритетом;



t – процессорное время.

Пт – поток (в скобках – приоритет потока).

# Смешанные алгоритмы планирования

- выбор из очереди по приоритетам, длительность кванта больше для низкого приоритета;



t – процессорное время.

Пт – поток (в скобках – приоритет потока).

- возможно разделение потоков на приоритетные группы, в которых также происходит градация по приоритетам.

# Динамические приоритеты

- Динамические приоритеты могут изменяться во время существования потока.
- Изначально потоку присваивается базовый уровень приоритета – уровень приоритета, получаемый комбинацией относительного приоритета потока и класса приоритета процесса, которому принадлежит данный поток.
- Изменение динамического приоритета может происходить по инициативе пользователя, самого потока или ОС.

# Приоритеты процессов в Windows NT

Класс приоритета	Описание
<b>Real-time</b>	Потоки в этом процессе обязаны немедленно реагировать на события, обеспечивая выполнение критических по времени задач. Такие потоки вытесняют даже компоненты операционной системы.
<b>High</b>	Потоки в этом процессе тоже должны немедленно реагировать на события, обеспечивая выполнение критических по времени задач. Этот класс присвоен, например, Диспетчеру задач, что даёт возможность пользователю закрывать больше неконтролируемые процессы
<b>Above normal</b>	Класс приоритета, промежуточный между normal и high.
<b>Normal</b>	Потоки в этом процессе не предъявляют особых требований к выделению им процессорного времени.
<b>Below normal</b>	Класс приоритета, промежуточный между normal и idle.
<b>Idle</b>	Потоки в этом процессе выполняются, когда система не занята другой работой. Этот класс приоритета обычно используется для утилит, работающих в фоновом режиме, экранных заставок и приложений, собирающих статистическую информацию.

# Относительные приоритеты потоков в Windows NT

Относительный приоритет потока	Описание
<b>Time-critical</b>	Поток выполняется с приоритетом 31 в классе real-time и с приоритетом 15 в других классах.
<b>Highest</b>	Поток выполняется с приоритетом на два уровня выше обычного для данного класса.
<b>Above normal</b>	Поток выполняется с приоритетом на один уровень выше обычного для данного класса.
<b>Normal</b>	Поток выполняется с обычным приоритетом процесса для данного класса.
<b>Below normal</b>	Поток выполняется с приоритетом на один уровень ниже обычного для данного класса.
<b>Lowest</b>	Поток выполняется с приоритетом на два уровня ниже обычного для данного класса.
<b>Idle</b>	Поток выполняется с приоритетом 16 в классе real-time и с приоритетом 1 в других классах.



# Принципы формирования динамического приоритета

- Потоки, выполняющиеся в режиме ядра имеют более высокий приоритет.
- ОС может дифференцированно повышать приоритет в зависимости от типа события, не позволившего использовать квант полностью (большее повышение при ожидании ввода данных, меньшее – при дисковых операциях).

# Принципы формирования динамического приоритета

- ОС может изменять приоритет в зависимости от полноты использования кванта процессорного времени (понижать в случае полного использования и наоборот).
- ОС разделения времени может повышать приоритет активной задачи (с окном которой работает пользователь) для обеспечения её быстрого отклика.
- ОС может повышать приоритет задачи, долгое время не выбиравшейся на выполнение.

# Задачи алгоритмов планирования

Системы пакетной обработки:

- обеспечение наиболее быстрого выполнения вычислений;
- минимизация количества переключения потоков.

Системы разделения времени:

- обеспечение наиболее быстрого выполнения операций ввода-вывода;
- обеспечение ощущения непрерывной работы с приложениями у пользователя.

Системы реального времени:

- обеспечение выполнения всех критических операций в срок.

# Синхронизация процессов и потоков

# Межпроцессное взаимодействие

Возникающие проблемы:

- передача информации от одного процесса к другому (только для процессов);
- предъявление различными потоками требований на одни и те же ресурсы;
- согласование действий потоков в случае, если выходные данные одного потока являются входными данными другого.

# Синхронизация потоков

Синхронизация потоков – согласование скоростей параллельно выполняющихся потоков путём приостановки потока до наступления какого-либо события и последующей его активизации при наступлении этого события.

# Задачи, решаемые с помощью синхронизации

- Обработка процессом некоторых аппаратных прерываний.
- Терминальное управление процессами.
- Синхронизация параллельных процессов, выполняющих действия с общей областью оперативной памяти.
- Синхронизация параллельных процессов, выполняющих информационный обмен при использовании общей области оперативной памяти.

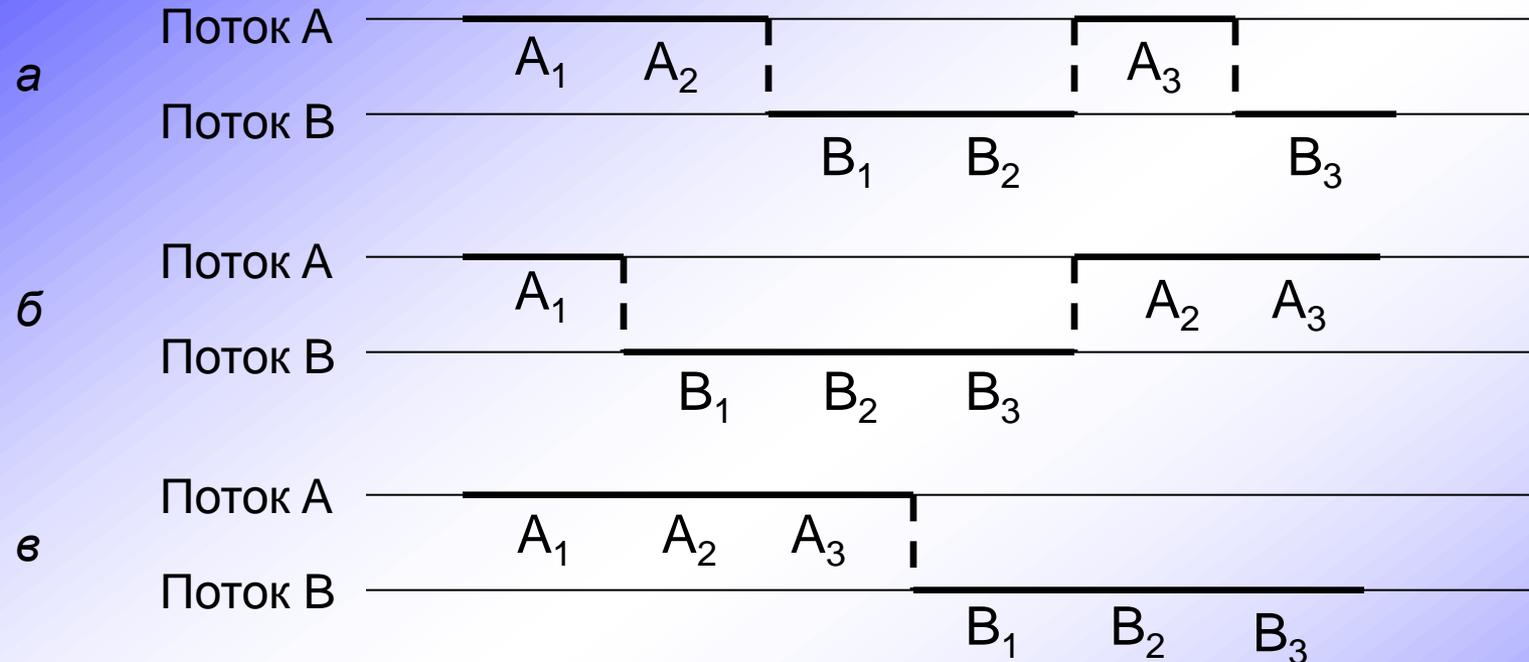
# Состояние состязания (гонка)

Состояние состязания – ситуация, когда два или более потоков работают с разделяемыми ресурсами (устройствами или данными) и конечный результат зависит от соотношения скоростей выполнения потоков.

# Состояние состязания

1. Считывание из базы данных в буфер записи о клиенте ( $A_1$  – при изменении поля «Заказ»,  $B_1$  – при изменении поля «Оплата»).
2. Внесение нового значения в поле «Заказ» ( $A_2$ ) или «Оплата» ( $B_2$ ).
3. Внесение изменённой записи в базу данных ( $A_3$  – при изменении поля «Заказ»,  $B_3$  – при изменении поля «Оплата»).

# Состояние состязания



- *а* – потеря данных о заказе;
- *б* – потеря данных об оплате;
- *в* – корректное изменение записей;
- пунктир – смена активного потока.

# Критические области

Критическая область – часть кода программы, в которой есть обращение к ресурсам, используемым текущим потоком совместно с другими потоками, что может привести к непредсказуемым последствиям.

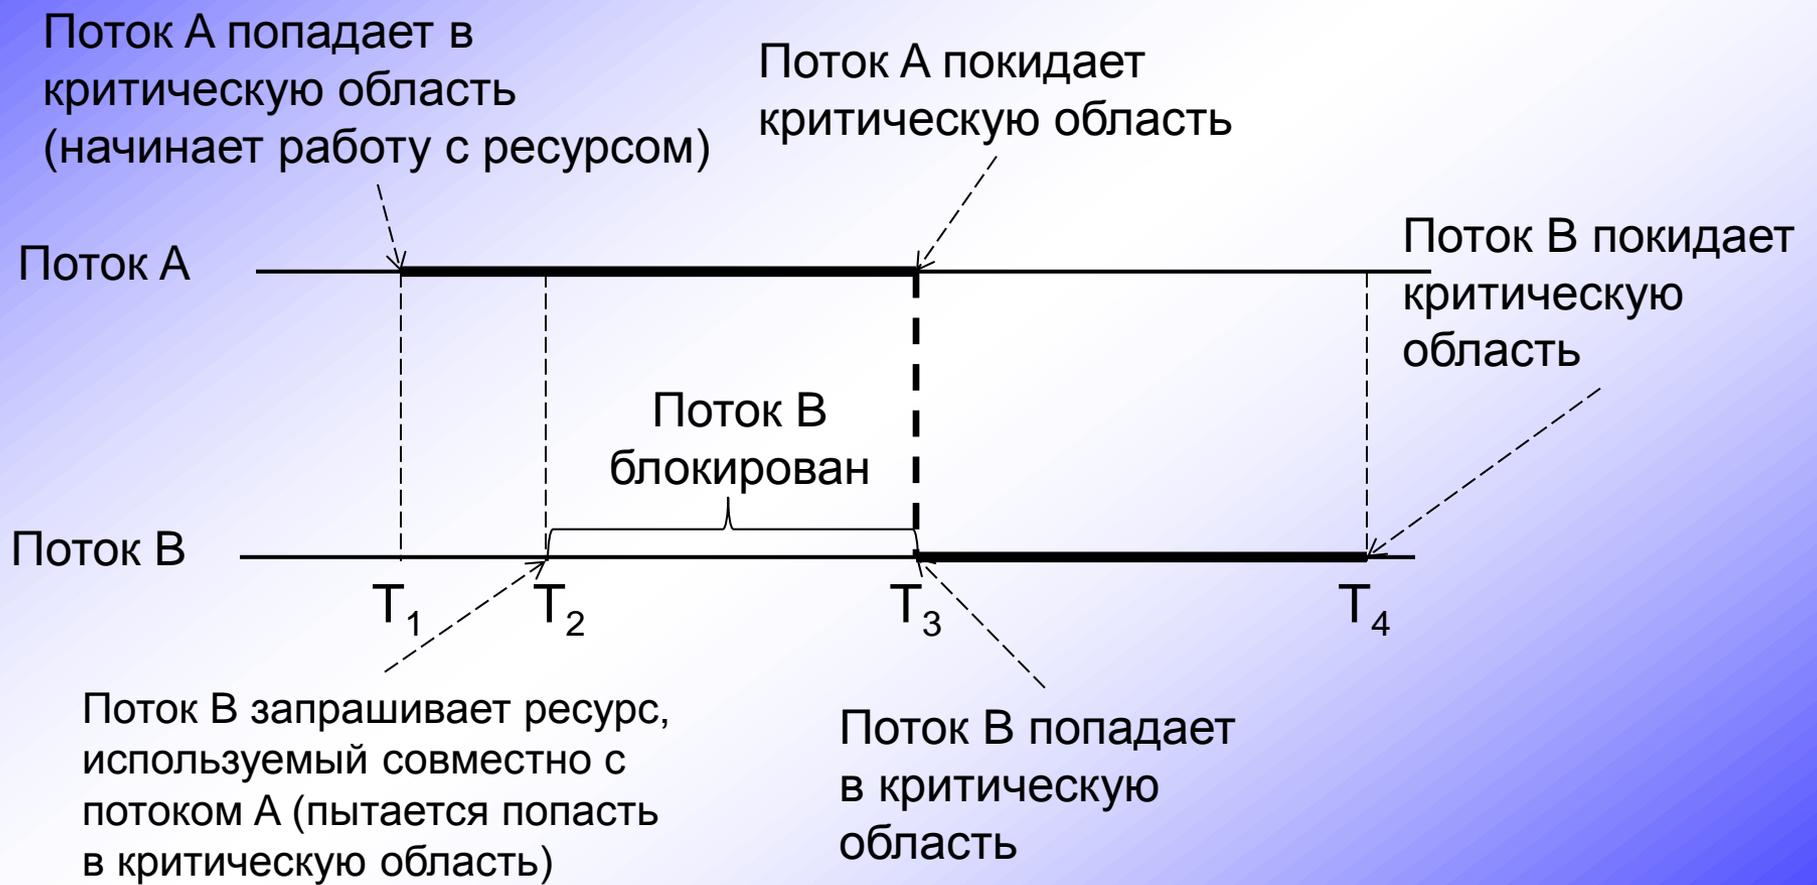
Подобные ресурсы называются критическими.

# Взаимное исключение

Взаимное исключение – запрет для всех потоков на использование совместно используемых ресурсов во время их использования текущим потоком, вне зависимости от его состояния.

Таким образом, в критической области в каждый момент времени может находиться только один поток.

# Взаимное исключение с использованием критических областей



# Условия правильной совместной работы параллельных потоков

- Два потока не должны одновременно находиться в критических областях.
- В программе не должно быть предположений о скорости или количестве процессоров.
- Поток, находящийся вне критической области, не должен блокировать другие потоки.
- Невозможность ситуации, в которой поток вечно ждёт попадания в критическую область.

# Взаимное исключение с активным ожиданием

- Запрет всех прерываний при входе потока в критическую область и разрешение при выходе.
- Блокирующие переменные.
- Команда TSL.

# Запрет всех прерываний

- Активный поток не может смениться, так как запрещены все прерывания, включая прерывание по таймеру.
- Используется в ОС, например, в моменты перепланировки.
- Недостатки: пользовательский поток может надолго занять процессор; возможна некорректная работа в мультипроцессорных системах.

# Блокирующие переменные



$F(D)$  – блокирующая переменная для ресурса D.

# Команда TSL

TSL (Test and Set Lock – проверить и заблокировать)



# Недостатки алгоритмов взаимного исключения с активным ожиданием

- В течение времени, когда один поток находится в критической области, другой поток, требующий тот же ресурс, при предоставлении ему процессорного времени будет выполнять цикл опроса занятости ресурса.
- При вытесняющем приоритетном планировании поток с более низким приоритетом может занять критическую область, а поток с более высоким приоритетом вытеснит его и будет бесконечно выполнять цикл опроса.

# Поток как объект синхронизации

Потоки при помощи системных вызовов могут синхронизировать своё выполнение с состоянием некоторого объекта.

Например в зависимости от поставленных условий:

- возможен перевод потока  $X$  в состояние «ожидание» при помощи системного вызова `sleep(X)`, пока его не запустит другой поток;
- возможен перевод потока  $X$  в состояние «готовность» при помощи системного вызова `wakeup(X)`.

Выполнение потока может быть синхронизовано с одним или несколькими объектами.

# Мьютекс

Мьютекс – переменная, которая может находиться в одном из двух состояний: заблокированном или неблокированном (двоичный семафор).

# Мьютексы и системные вызовы для работы с критическими областями



# Семафоры

Семафор – переменная, которая может содержать целые неотрицательные значения и используется для синхронизации вычислительных процессов.

Операции для работы с семафором  $S$ :

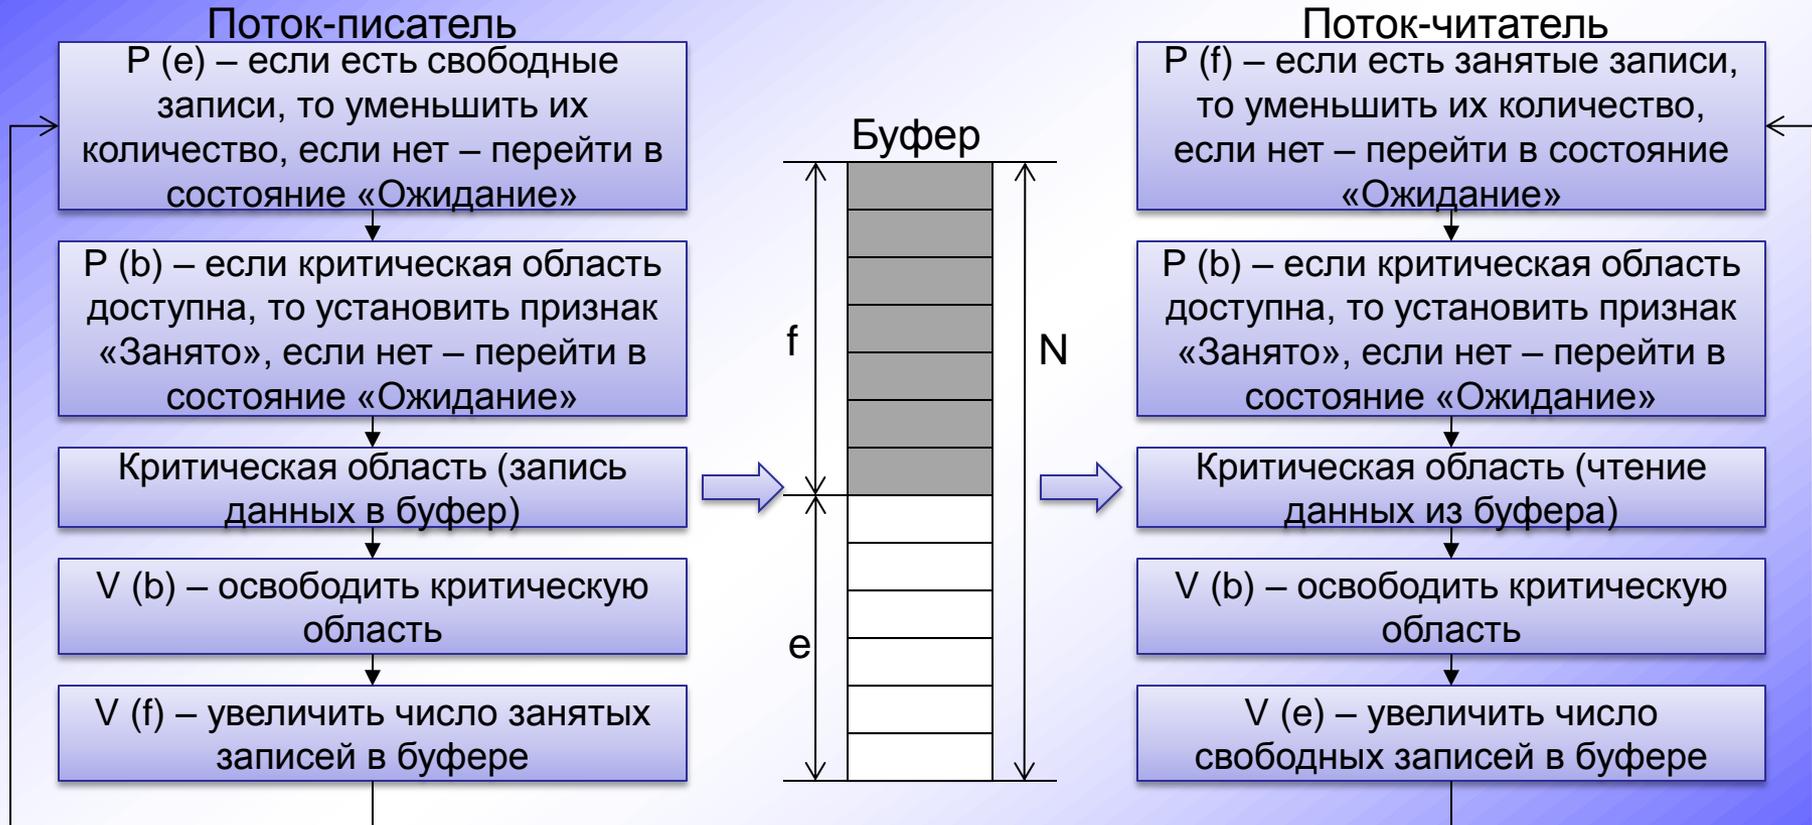
- $V(S)$  – переменная  $S$  увеличивается на 1
- $P(S)$  – переменная  $S$  уменьшается на 1, если это возможно. Если  $S=0$ , то поток, вызывающий операцию  $P$ , переходит в состояние «ожидание» и ждёт пока уменьшение станет возможным.

Обе операции являются элементарными действиями, т.е. едины и неделимы.

# Проблема производителя и потребителя

- Два потока одновременно используют буфер ограниченного размера.
- Один поток помещает данные в буфер, а другой – считывает данные.
- Необходимо обеспечить корректную работу потока-писателя, если буфер полон, и потока-читателя, если буфер пуст.

# Пример работы семафоров. Проблема производителя и потребителя



Семафоры:

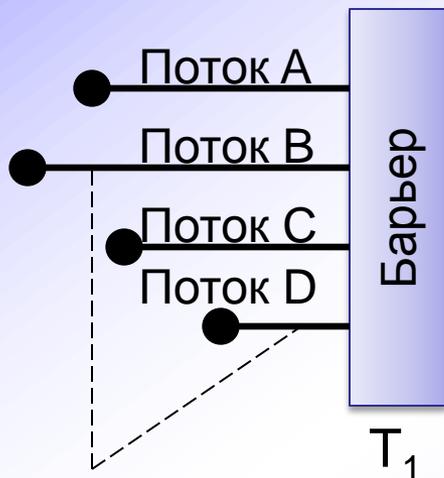
$e$  – количество пустых записей в буфере (начальное значение -  $N$ );

$f$  – количество заполненных записей в буфер (начальное значение -  $0$ );

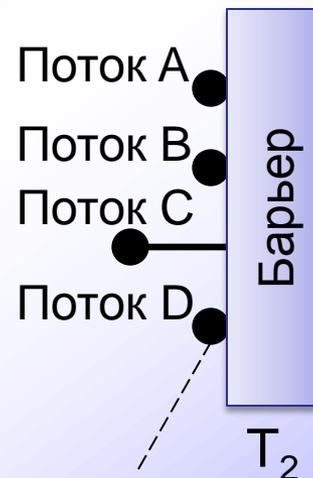
$b$  – двоичный семафор.

# Барьеры

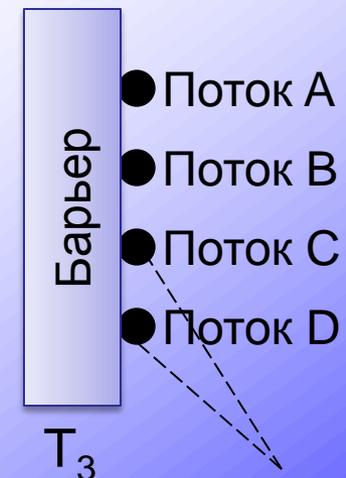
Барьер – механизм синхронизации для групп потоков с несколькими фазами выполнения. В конце каждой фазы ставится барьер. Для прохождения барьера, его должны достигнуть все потоки в группе.



Процессорное время,  
необходимое потоку для  
достижения барьера



Выполнение потока  
достигло барьер



Все потоки достигли барьер  
и продолжают выполнение

# Рассмотренные вопросы

- Состояния потоков.
- Стратегии и дисциплины планирования.
- Синхронизация процессов и потоков.
- Методы и средства синхронизации.

**Всем спасибо –  
все свободны,  
если нет вопросов**