

# Betriebssysteme

## ***Kap. 3: Interprozesskommunikation (IPC)***

### ***3.3: IPC in UNIX***

Stand: WS 11/12 (6.12.11)

Prof. Dr. Wolfgang Kuechlin

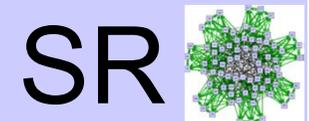
*Dipl.-Inform., Dr. sc. techn. (ETH)*

**Arbeitsbereich Symbolisches Rechnen  
Wilhelm-Schickard-Institut für Informatik  
Fakultät für Informations- und Kognitionswissenschaften**

**Universität Tübingen**

**Steinbeis Transferzentrum  
Objekt- und Internet-Technologien (OIT)**

**[Wolfgang.Kuechlin@uni-tuebingen.de](mailto:Wolfgang.Kuechlin@uni-tuebingen.de)  
<http://www-sr.informatik.uni-tuebingen.de>**



# Teil III: IPC in UNIX

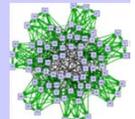
---

## ➤ Klassisches UNIX

- Signale
- Pipes

## ➤ System V

- Shared Memory
- Message Passing
- Semaphore

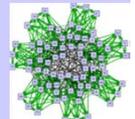


# Interprozesskommunikation (IPC)

---

## ➤ Zwei Kommunikationswege zwischen Prozessen

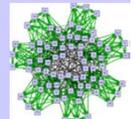
- Direkter Zugriff über Shared-Memory
  - memory based locks
- Vermittlung durch Betriebssystem
  - Signale
  - Pipes
  - POSIX mutexes / conditions
  - Shared memory (SV)
  - Message Passing (SV)
  - Semaphore (SV)



# Übersicht über IPC-Konzepte in UNIX

---

- UNIX (BSD)
  - Signale, Pipes, Sockets
- UNIX System V
  - Shared Memory, Messages, Semaphore
  - später übernommen z.B. in FreeBSD 5.2
- Solaris 2, Linux (ab 2.0)
  - zusätzlich Mutex, Conditions
  - (Signale, Mutex, Conditions
    - POSIX 4-Standard)



# Synchronisation in UNIX

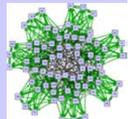
---

- einzig voll portable Synchronisationsoperation für Anwender:
  - Realisierung von `mutex_lock` durch das Erzeugen eines **Lock-Files**.
  - `creat` läuft atomar ab und liefert einen Fehler, falls das File schon existiert, d.h. ein anderer Prozess das lock hat.
- Missbrauch des Filesystems ist problematisch:
  - lock-files bleiben liegen, wenn ein Prozess abstürzt
  - ein Prozess hängt, wenn zufällig ein anderes File mit dem gleichen Namen wie das lock-file existiert.



# Signale (POSIX)

- UNIX Signale sind ein reines Software-Konzept
  - modelliert nach Vorbild Interrupt + Interrupt-Handler
  - im Prinzip ein asynchrones Kommunikations-Konzept
  - Prozess schickt Signal durch Systemaufruf
  - BS liefert Signal an Empfänger aus
  - BS aktiviert Signal-Handler des Empfängers
- Signale informieren einen Prozess über Ereignisse
  - Software-Ereignisse: Prozess verschickt Signal (via BS)
  - Hardware-Ereignisse: Interrupt-Handler verschickt Signal
    - Ctrl-C oder Ctrl-Z auf Tastatur
    - Hardwarefehler
- Auch synchrone Information ist möglich
  - SIGSEGV, SIGILL, ...; Warten auf ein Signal.



# Signale

Signal	Beschreibung	Aktion
SIGABRT	Abnormal Program Termination	T
SIGALRM	Ablaufen eines Timers	T
SIGFPE	Floating Point Exception	T
SIGHUP	Abbruch Terminal-Verbindung (hangup)	T
SIGILL	Illegale Instruktion	T
SIGINT	Interrupt-Taste	T
SIGKILL	Prozess-Termination	T
SIGPIPE	Pipe ohne Leseprozess	T
SIGSEGV	Ungült. Speicherzugr. (segment. viol.)	T
SIGTERM	Default-Signal, Termination	T
SIGUSR1	Benutzerdef. Signal 1	T
SIGUSR2	Benutzerdef. Signal 2	T
SIGCHLD	Term/Stopp eines Kindes	I
SIGCONT	Starten eines gestoppten Prozesses	I
SIGQUIT	Quit-Taste	T
SIGSTOP	Stoppen eines Prozesses	S
SIGSTP	Stopp-Taste	S
SIGTTIN	Backg.-Proz. Liest vom Terminal	S
SIGTTOU	Backg.-Proz. Schreibt auf Terminal	S

**T=Termination, S=Stop, I=Ignorieren**

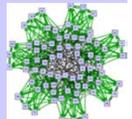
**man -s 5 signal**



# Verschicken von Signalen

---

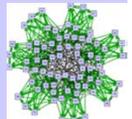
- `int kill (pid_t pid, int sig)`
  - `kill(2)` schickt Signal `sig` an Prozess mit ID `pid` (auch: Signal an Prozessgruppe)
- Verarbeitung von Signalen
  - Durch BS vorgegebene Aktion ausführen
  - Signal abfangen
    - Benutzerdefinierte Aktion (Signalhandler)
      - `signal (int sig, handler)` oder
      - `int sigaction (int sig, sigaction *act)`
  - Signal blockieren
    - `int sigprocmask (int how, sigset_t *set)`
- **SIGKILL** und **SIGSTOP** können nicht abgefangen werden.



# Weitere Signalfunktionen

---

- alarm (int secs);
  - schickt SIGALARM nach **secs** Sekunden an aufrufenden Prozess
- pause();
  - Blockiert den aufrufenden Prozess bis zu einem Signal
- sleep (int secs);
  - Blockiert **secs** Sekunden bzw. bis zu Signal



# Probleme mit Signalen

---

- Signalhandler asynchron zum normalen Programmfluss
    - Kann überall gestartet werden, wo Programm unterbrochen werden kann
      - MMU unterbricht mitten in Instruktion!
      - Datenstrukturen i.a. inkonsistent!
      - System-Calls durch Signale unterbrechbar
  - Signale nur mit 1 Bit gespeichert
    - Eintreffen wird nicht gezählt → Sign. kann verloren gehen
    - Nur 1 Bit Information wird übertragen
- Probleme werden mit POSIX 4 z.T. behoben



# Pipes

---

- Eine Pipe (Rohrleitung) ist eine FIFO Kommunikationsstruktur.
  - Pipes wurden traditionell mittels des Dateisystems realisiert.
  - Eine neue Realisierung benutzt sockets (→ „Verteilte Systeme“).
- Nach dem Öffnen können sie logisch wie eine Datei beschrieben bzw. gelesen werden, was für Transparenz und Überschaubarkeit sehr wichtig ist.

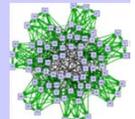


# Pipes

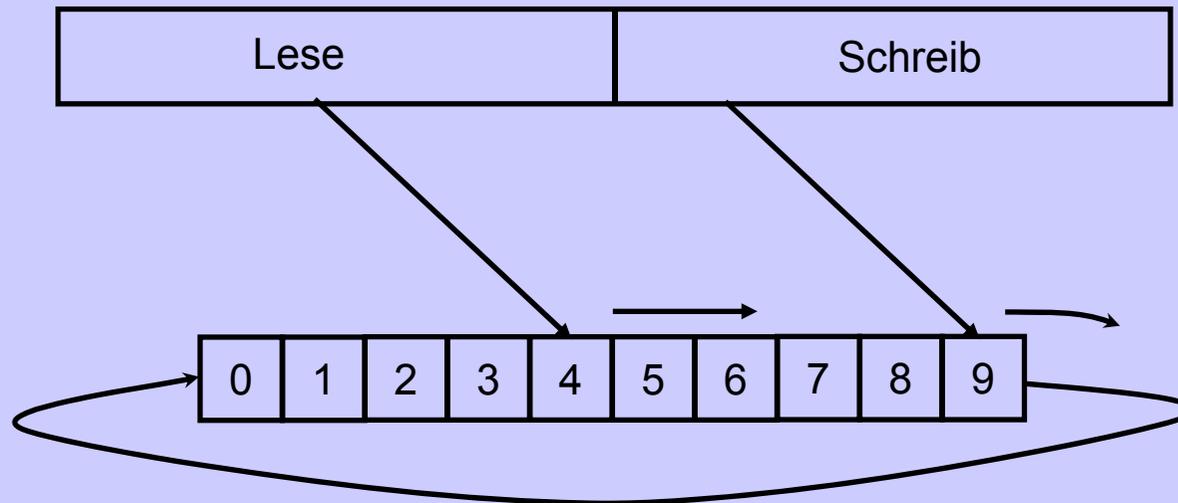
---

Mittels einer Datei kann eine Pipe wie folgt realisiert werden:

- Der Pufferspeicher der Pipe wird durch eine feste Anzahl von Blöcken ( in UNIX z.B. die 10 direkten Blöcke) der Datei realisiert, die logisch als Ringpuffer organisiert werden.
- Zudem gibt es einen Lesezeiger und einen Schreibzeiger, die auf die nächste zu lesende bzw. zu schreibende Position verweisen.
- Lese- und Schreibzeiger überholen sich nicht, sondern die entsprechenden Prozesse werden zuvor blockiert und dann wieder aufgeweckt, wenn wieder Platz ist.

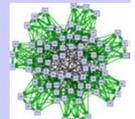


# Pipes



Implementierung einer pipe über inode

- Natürlich können mehrere Prozesse in die pipe schreiben oder aus ihr lesen.
- Es gibt benannte (named) und unbenannte (unnamed) pipes zur Kommunikation zwischen nicht verwandten bzw. zwischen verwandten Prozessen.



# Pipes – Systemaufrufe

## ➤ unbenannte pipe mittels Filedeskriptoren

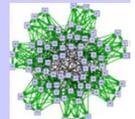
- fds[0] für das Lesen
- fds[1] für das Schreiben

```
int fds[2];  
pipe(fds);
```

```
mkfifo(path, access-mode)  
char* path, mode_t access-mode;
```

## ➤ pipe mit Namen path

- Liefert eine pipe mit Namen path.
- Die Lese- und Schreibdeskriptoren werden wie üblich durch nachfolgendes Öffnen der Datei zum Lesen bzw. Schreiben erhalten.
- Da die pipe einen Namen hat und explizit zum Lesen/Schreiben geöffnet wird, eignet sie sich zur Kommunikation nicht verwandter Prozesse.



# Pipes (UNIX)

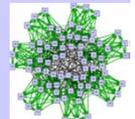
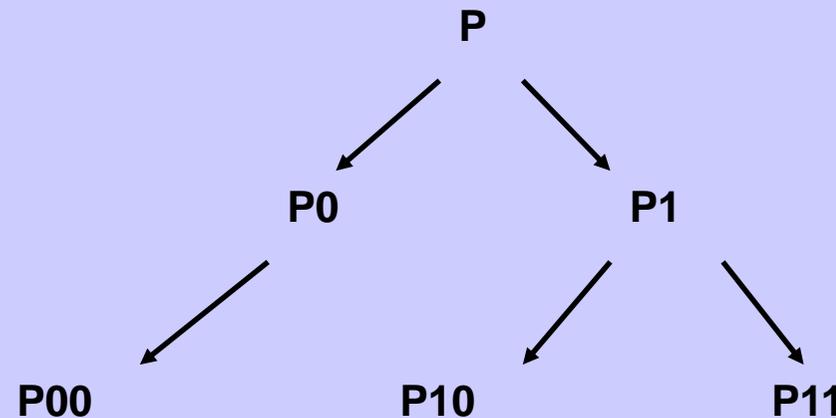
- FIFO-Buffer fester Größe
  - Früher über Files implementiert, jetzt auch über Sockets
- Unnamed Pipe

```

Int fdptr[2];
pipe (fdptr); liefert 2 Filedescriptors
int read (fdptr[0], char *msg, int size);
int write (fdptr[1], char *msg, int size);
int close (int fdptr[ ]);

```

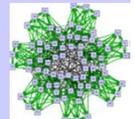
Berechtigte Prozesse:  
 Erzeugender Prozess und  
 Nachkommen:  
 $P_1$  vererbt auf  $P_{10}$  und  $P_{11}$



# Named Pipe

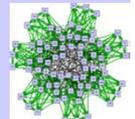
---

- `mkfifo (char *path, mode_t mode);`
  - erzeugt mit Namen (path) versehene Pipe
- Verwendung wie File:
  - `int open (char *path, int flags, int mode)`
  - `int write (int fdes, char *buf, int size)`
  - `int read (int fdes, char *buf, int size)`
  - `int close (int fdes)`
- Entfernung mit `unlink`



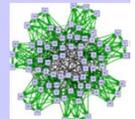
# IPC in System V: Übersicht

- UNIX System V enthält drei Mechanismen für IPC:
  - Shared Memory
  - Messages
  - Semaphores
- Diesen Mechanismen ist folgendes gemeinsam:
  - Eine Systemtabelle enthält alle Instanzen der Mechanismen.
  - Jeder Eintrag enthält einen Benutzer definierten (externen) numerischen Schlüssel key.
  - Ein get Systemaufruf durchsucht die Tabelle nach einem Eintrag mit Schlüssel key. Modifiziert durch flags können auch neue Einträge erzeugt oder Fehler geliefert werden, falls key schon existiert. get liefert einen eindeutigen internen Deskriptor ID, den die anderen Aufrufe benutzen.
  - Jeder Eintrag enthält Zugriffsrechte und andere Statusinformation (z.B. letzter zugreifender Prozess und Zeit des Zugriffs).
  - Jeder Mechanismus enthält einen control (ctl) Aufruf, um den Zustand eines Eintrags abzufragen oder zu verändern oder den Eintrag zu löschen.



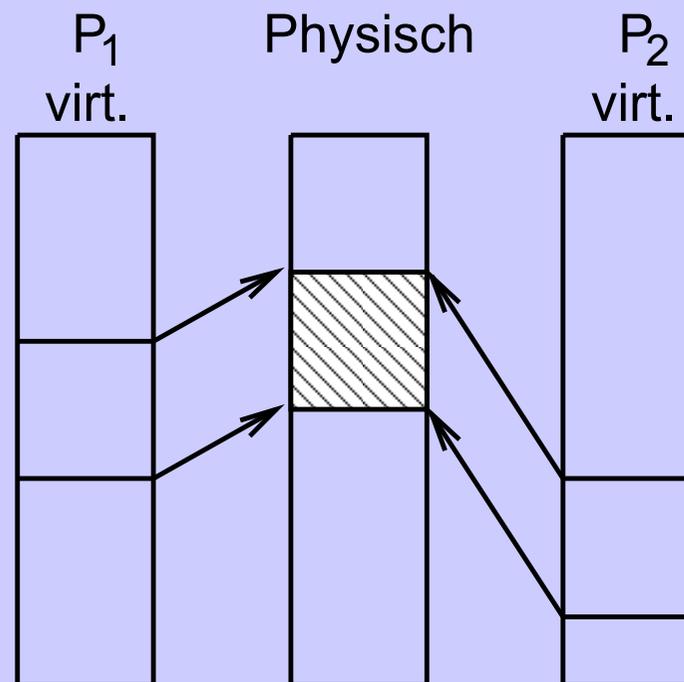
# IPC in UNIX System V (Übersicht)

- UNIX System V enthält drei Mechanismen für IPC:
  - Shared Memory
  - Messages
  - Semaphores
- Existenz einer Systemtabelle mit allen Bereichen, Queues, Semaphoren
- Beim Erzeugen eines neuen Sync-Objektes gibt der User dafür einen global nutzbaren Namen (key) an.
- Ein anderer Prozess findet das Objekt über den key
  - `int get (key, ...)`; liefert eine lokale ID zu dem globalen Objekt
  - durchsucht Tabelle, gibt ID (lokaler „handle“) des Eintrags zurück
  - falls Objekt noch nicht besteht wird es erzeugt
  - die ID's werden nicht recycled (d.h. erst nach sehr langer Zeit).
- ... `ctl` setzt Zugriffsrechte, löscht, fragt Informationen ab.



# IPC in System V – Shared Memory

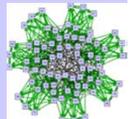
- Prozesse können direkt kommunizieren, indem sie sich einen Teil ihres virtuellen Adressraums teilen und dort Daten schreiben und lesen.



# Shared-Memory

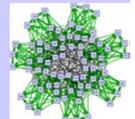
---

- `int shmget (key_t key, int size, int shmflg);`
  - findet bestehendes Speicherobjekt
  - oder alloziert neues Objekt mit Speicher der Größe `size`
- `char* shmat (int shmid, char *shmaddr, int flg)`
  - fügt Speicherobjekt mit ID `shmid` an Wunsch-Stelle `shmaddr` in virtuellen Adressraum ein
  - gibt tatsächliche Anfangsadresse zurück
- `int shmdt (char* shmaddr);`
  - Gibt Bindung an Speicherobjekt an Adresse `shmaddr` frei
  - Speicherobjekt bleibt bestehen
- `int shmctl (int shmid, int cmd, ...);`
  - Verschiedene Operationen auf Shared Memory (ink. Destroy)



# IPC in System V – Shared Memory

- Die gemeinsamen Speicherregionen werden in einer Tabelle gehalten.
- `shmid = shmget (key, size, flag)`
  - gibt Zugriff auf eine gemeinsame Speicherregion (ähnlich file open)
  - ein externer Name `key` wird auf eine intern verwendbare ID `shmid` abgebildet. Nachfolgende Aufrufe verwenden `shmid`.
  - `shmget` sucht zuerst nach einer Region `key` in der Tabelle
  - Falls keine da ist (und `flag = IPC_CREAT`), wird ein neuer Eintrag der Größe `size` erzeugt.
  - Seitentabellen für die Region werden erst beim ersten `shmat` erzeugt.
- `virtaddr = shmat (id, addr, flags)`
  - bildet (durch Anlegen von Seitentabellen) eine Speicherregion in den virtuellen Adressraum des Aufrufenden ab (möglichst an Stelle `addr`).
  - Der tatsächliche Ankerpunkt ist `virtaddr`. Ist `addr == 0`, ist die Wahl dem System überlassen; sonst muss der Aufrufer selbst Konflikte (z.B. mit dem Stack) vermeiden.



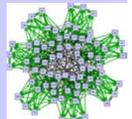
# IPC in System V – Shared Memory

- `shmdt(addr)`
  - löst die Bindung einer Speicherregion an die virtuelle Adresse `addr`.
  - Region existiert weiter
- `shmctl(id, cmd, shmstatbuf)`
  - kann den Status (z.B. Zugriffsrechte) einer Region ändern. `shmstatbuf` enthält den neuen Status.
  - `shmctl(id,IPC_RMID,0)` gibt die Region zum Auflösen frei (dies geschieht tatsächlich erst beim letzten `shmdt`).

Shared Memory wird bei `fork` vererbt

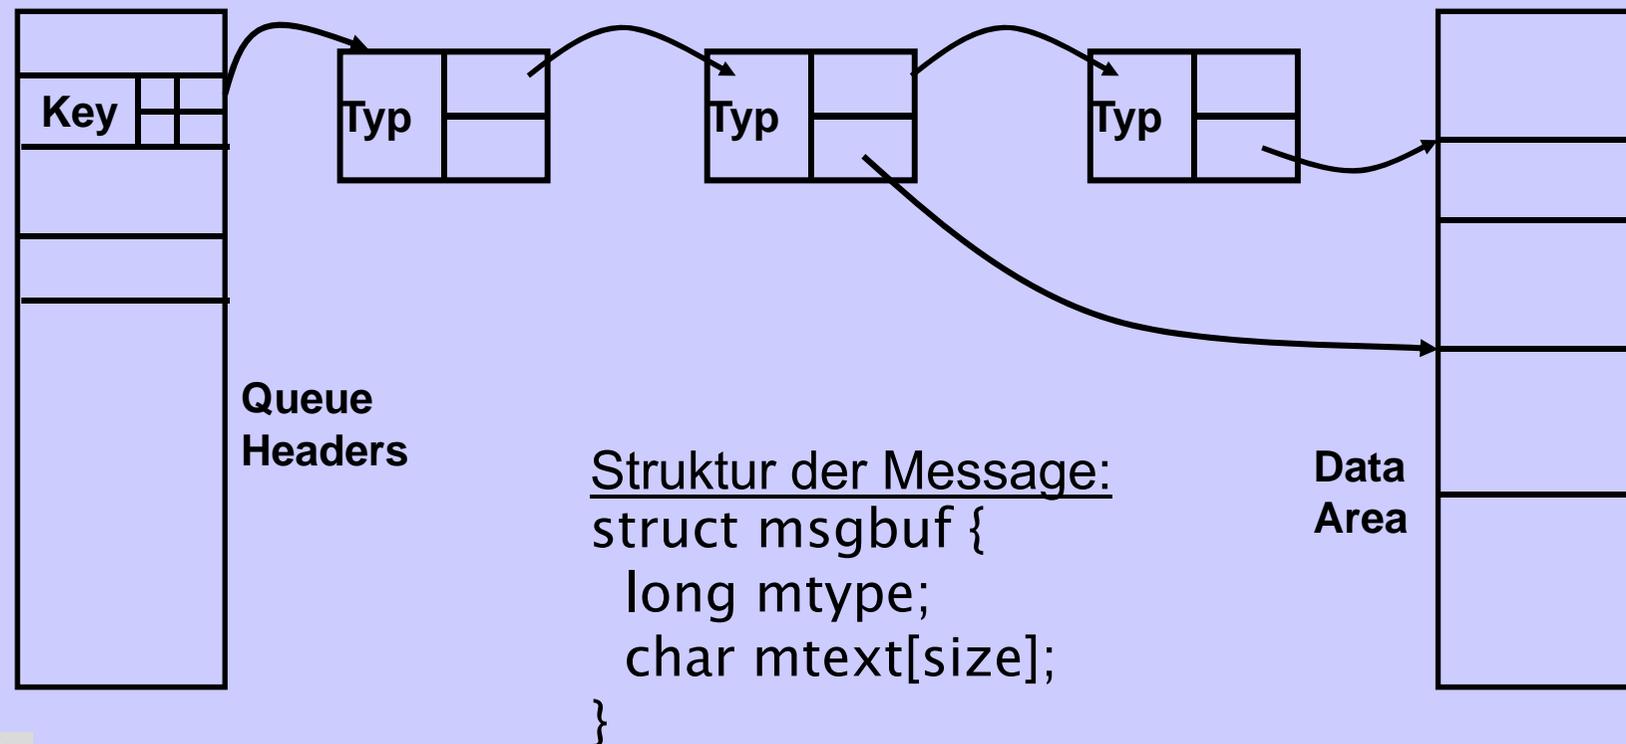
Bei `exec` und `exit detached`

(nicht vererbt, aber auch nicht freigegeben!)



# UNIX System V messages

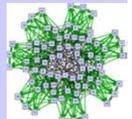
- Messages dienen zum Austausch formatierter Daten.
- Messages werden in Message-Queues gespeichert



# UNIX System V messages

---

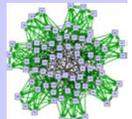
- `int msgsnd (int id, msgbuf *p, int size, int flg);`
  - schreibt size Bytes aus Buffer p auf Queue id
- `int msgrcv (int id, msgbuf *p, int size, long type, int flag)`
  - liest max. size Bytes aus Queue id in Buffer p falls Typ type kompatibel
    - type = 0: Erste Message der Queue id
    - type > 0: Erste Message mit type
    - type < 0: Erste Message mit minimalem Typ (max. - type).
      - Bsp: `msgrcv ( , , -7, )` auf 7,17,5,2,7,2



# IPC in System V – Messages

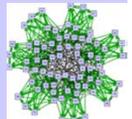
---

- `msgqid = msgget (key, flag)`
  - liefert (und falls nötig erzeugt) einen Deskriptor auf eine Liste von Nachrichten (Briefkasten).
- `msgsnd (msgqid, msg, count, flag)`
  - sendet Nachricht `msg` der Länge `count` in die WS `msgqid`.
  - `msg` selbst ist eine Struktur aus einem Integer Typ und der Nachricht als char array.
  - Es werden Prozesse geweckt, die auf eine Nachricht von diesem Typ warten.

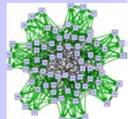
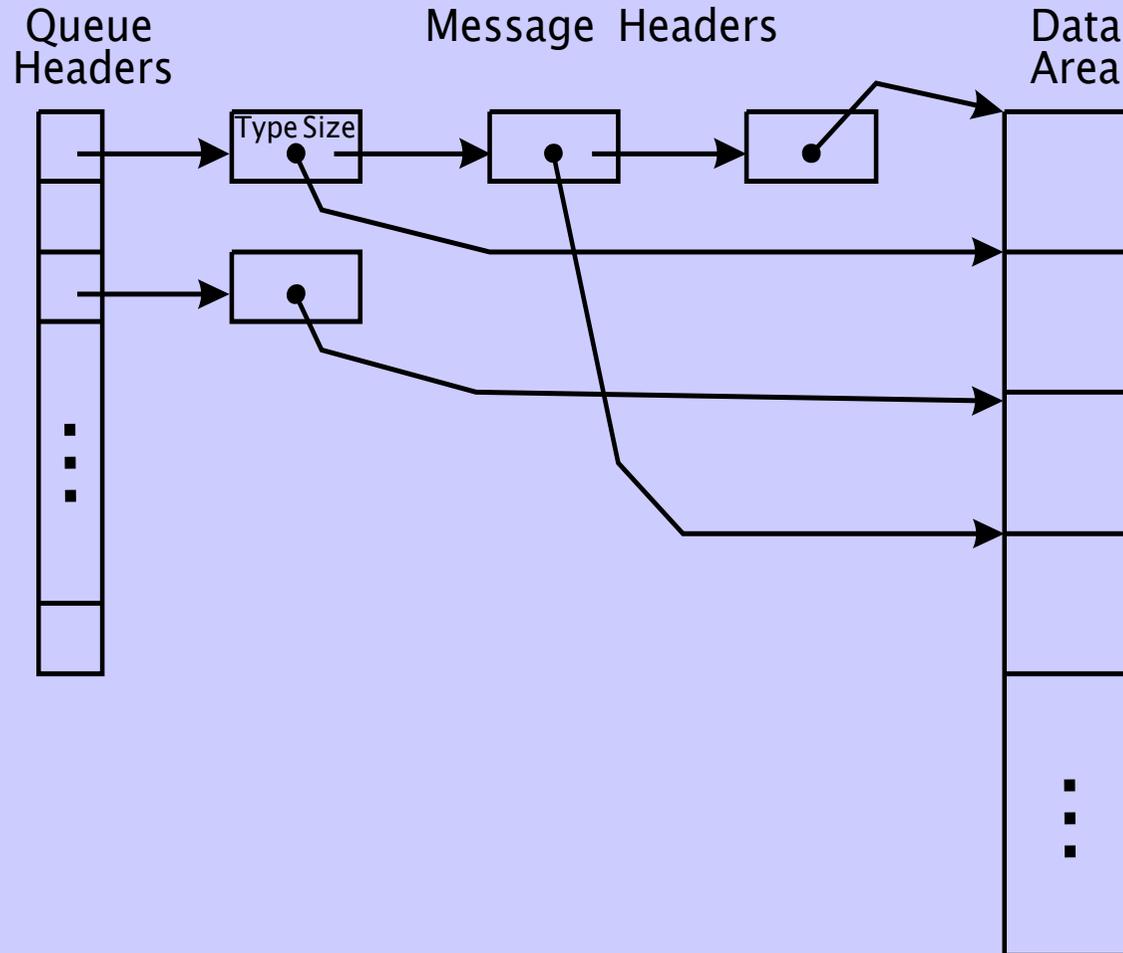


# IPC in System V – Messages

- `count = msgrcv (id, msg, maxcount, type, flag)`
  - empfängt eine Nachricht des Typs `type` und der max. Länge `maxcount` von Schlange `id`, die in der Struktur `msg` abgelegt werden soll.
  - `count` ist die aktuelle Anzahl übermittelter Bytes.
  - Es wird die erste Nachricht übermittelt, deren Typ = `type` ist; falls `type = 0`, wird die erste Nachricht übermittelt.
- `msgctl(id, cmd, mstatbuf)`
  - liest oder setzt den Status eines Nachrichtendeskriptors.
- `msgctl(msgqid, IPC_RMID, 0)`
  - löscht einen Deskriptor (eine NachrichtenWS).



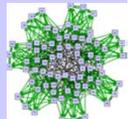
# IPC in System V – Messages



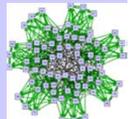
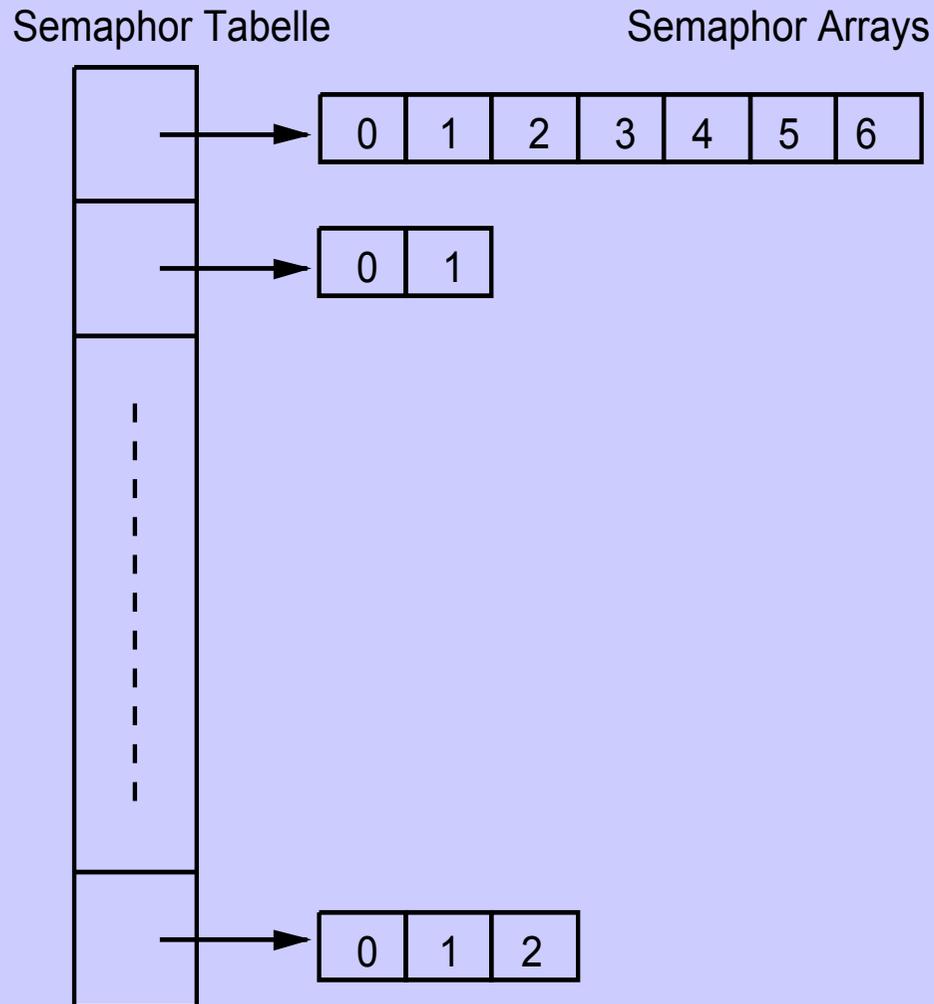
# IPC in System V – Semaphore

---

- Ein System V Semaphor besteht aus:
  - Dem Wert des Semaphors.
  - Der Prozess ID des letzten Prozesses, der das Semaphor manipuliert hat.
  - Der WS der Prozesse, die darauf warten, dass sich der Wert des Semaphors erhöht.
  - Der WS der Prozesse, die darauf warten, dass der Wert des Semaphors Null wird.

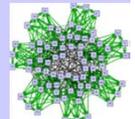


# IPC in System V – Semaphore



# IPC in System V – Semaphore

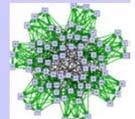
- `semget id = semget (key, count, flag);`
  - gibt Zugriff auf einen Eintrag in der Semaphor-Tabelle mit einem Array aus Semaphoren mit count Elementen. key ist ein Benutzer definierter Name für den Eintrag und flag spezifiziert Zugriffsarten (z.B. ob Eintrag erzeugt werden soll, falls er noch nicht existiert).
  - Der Tabelleneintrag enthält auch die Zeiten der letzten `semop` und `semctl` Aufrufe sowie Zugriffsrechte für `semop` Aufrufe.
- `semctl`
  - Verschiedene Kontrolloperationen auf der Menge.
  - u.a. damit auch Löschen von Semaphoren möglich



# IPC in System V – Semaphore

---

- Semop oldval = semop (id, oplist, count)
  - id ist der Deskriptor aus semget,
  - oplist ist ein Zeiger auf ein Array der Länge count aus Semaphor-Operationen.
  - oldval ist der Wert des letzten Semaphors in der Liste vor der Operation.
  - Jedes Element von oplist enthält:
    - den Index des Semaphors im Array
    - die Semaphor-Operation in Form einer Konstanten Op die zum Sem-Wert addiert wird
    - Flags



# IPC in System V – Semaphore

- Als Resultat einer semop ändert der Kern die Werte der beteiligten Semaphore
  - $Op > 0$ : „Up“: Alle Prozesse werden geweckt, die darauf warten.
  - $Op = 0$ : Der Prozess wartet, bis der Semaphor-Wert = 0 wird.
  - $Op < 0$ : „Down“: Wert = Wert + Op, falls Wert + Op > 0
    - Sonst warten bis Wert groß genug
- Wert + Op = 0: Die auf 0 wartenden Prozesse werden geweckt.
- In jedem Fall wird eine semop atomar durchgeführt.
  - Blockiert der Prozess bei einer Teiloperation → Originalwerte werden auf dem Semaphor-Array temporär wieder hergestellt
  - Dies macht System V Semaphore sehr kompliziert und aufwändig

