

Open Source Programování

<http://rtime.felk.cvut.cz/osp/>

Pavel Píša

<pisa@fel.cvut.cz>

<http://cmp.felk.cvut.cz/~pisa>

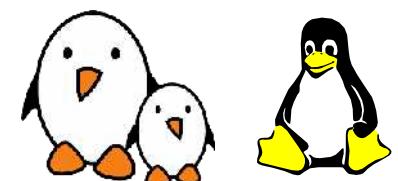
Michal Sojka

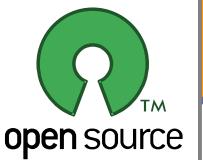
František Vacek

DCE FEL ČVUT



© Copyright 2004-2010, Pavel Píša, Michal Sojka, František Vacek,
Free-Electrons.com, GNU.org, kernel.org, Wikipedia.org
Creative Commons BY-SA 3.0 license Latest update: 14. IV 2010





Zdroje limitující aplikace

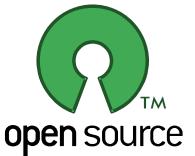


- ▶ Výkon a počet CPU (standard MIPS, FLOPS)
- ▶ Velikost fyzické paměti (počet stránek)
- ▶ Šířka pásma pro přístup k paměti
- ▶ Šířka pásma pro přístup k datům na disku
- ▶ Šířka pásma síťového připojení/infrastruktury

- ▶ Na různých úrovních
 - ▶ Na úrovni hardware
sběrnice, CPU, programový kanál, programový kanál s přerušením (IRQ), s přímým přístupem k paměti (DMA), scatter-gather, s I/O koprocesorem/intelligentním řadičem
 - ▶ V jádře operačního systému
 - ▶ **Na úrovni knihoven a systémových volání**
 - ▶ V grafickém subsystému a aplikačním frameworku
 - ▶ V síti uzlů (komunikace TCP/IP, Ethernet, HTTP, cluster OpenMP, PCI Express, ...)
 - ▶ Jako reakce na uživatele (pohyb myší, klávesnice atd.)
 - ▶ V řízeném systému se zpětnou vazbou
robot, řídicí aplikace, letadlo, vlak, drive-by-wire, haptic device, force feedback atd.

- ▶ Periodické testování změny, nastavené události (polling)
 - ▶ Nejprimitivnější, **plýtvá** časem procesoru v případě, že k události ještě nedošlo
 - ▶ Když k události dojde, tak je pro náhodný interval vzniku průměrná prodleva $T/2$, **velká latence**
 - ▶ Častěji \Rightarrow plýtvání, delší perioda \Rightarrow latence
 - ▶ **Trvalá zátěž** na každou sledovanou událost
 $O(n_{\text{registered}} + n_{\text{active}})$
- ▶ Automatické doručení informace o změně a čekání na události
 - ▶ IRQ \rightarrow CPU nebo raději DMA a IRQ po větším bloku dat
 - ▶ Nutnost dopravit událost z jádra OS přes nějaké **jednotné API**
 - ▶ Hlavní činnosti zatěžující systém a uživatele jsou **registrování** událostí a po jejich příchodu **distribuce** těm, kterým jsou **určeny**

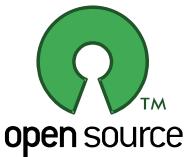
- ▶ Typicky se jedná o vstupně výstupní (I/O) události, časové limity (timeout) a události v absolutním čase
- ▶ Využití SMP při klient-server architektuře
 - ▶ Vytvářet na zpracování každé události nové vlákno většinou příliš velká režie a pro synchronní protokoly není potřeba, častěji **jedno vlákno na jednoho klienta** + vlákno pro příjem spojení a zakládání vláken, i to je však při tisícovkách klientů režie nad možnosti HW a propustnost klesá
 - ▶ Zpracovávat vše v jednom procesu/vlákně – pokud neběží další aplikace nebo systémové úlohy tak nevyužije více CPU. Neuplatňuje se režie na další vlákna (např. Linux každé vlákno přes 4 nebo 8kB nestránkovatelné paměti v jádře + několik stránek na zásobník a další data v userspace)
 - ▶ Většinou se používá kombinace přístupů, určité množství připravených vláken nebo procesů, které požadavky přebírají – **thread-pool**, je potřeba řídit přidělování úloh, buď z userspace nebo přímo v jádře OS, je výhodné řídit max. počet aktivních threadů, aby nedocházelo k přílišnému počtu přepínání (**interaktivní** versus **dávkové** úlohy). Obvykle pravidlo **2x** až **4x** více procesů/vláken než je CPU



Více událostí na jedno vlákno



- ▶ Veškeré operace by měly být **neblokující** (pozor na DNS a jiné blok.)
POSIX open/fcntl O_NONBLOCK, Win32 CreateFile
FILE_FLAG_OVERLAPPED attribute
- ▶ Multiplex/dopravení události a vyhledání cíle
 - ▶ Na vyšší úrovni například
 - ▶ Zpráva/**broadcast** do stromu/podstromu grafických objektů (podle topologie, aktivace/focus, pozice)
 - ▶ **Signal-slot** mechanizmus
 - ▶ U **klient-server** aplikací a protokolů často **1:1**
 - ▶ Potřeba navázat vyšší vrstvu na vrstvy nižší (např. Glib na epoll)
 - ▶ Většinou přes **deskriptory** (zobecněných) **souborů** – file-handle
 - ▶ Možné i jiné přístupy (někdy dokonce nutné)
 - ▶ Synchronizační události **mutexy**, **signály**, **IPC**
 - ▶ Doprava událostí jako **zprávy** (např. Win32 grafika)
 - ▶ **Rendezvous** – setkání server/klient především u mikrojader



Vlastní zkušenosti na základě



- ▶ uLEvPoll Library - uLan/Universal Light Event Poll Library
<http://ulan.git.sourceforge.net/git/gitweb.cgi?p=ulan/ulevpoll>
<http://ulan.sourceforge.net/pdf/ulevpoll.pdf>
- ▶ Původní záměr: minimální obálka nad **libevent** a **glib** (Gtk, Qt)
- ▶ Jako první implementovaný pro jednoduché aplikace **poll**
- ▶ Po analýze omezení libevent-1.x i vlastní implementace **epoll**
- ▶ Postupně vyřešeno kombinování s **glib** a **libevent-1.x a 2.x**
- ▶ Pro minimální kompatibilitu s Windows přidán starý dobrý Unixový **select**
- ▶ V rozpracovaném stavu Windows **WaitForMultipleObjectsEx**



Kostra implementace serveru



```
int sockfd, client_fd;
struct sockaddr_in my_addr;
struct sockaddr_in client_addr;
int sin_size;
int yes = 1;
int retval;

sockfd = socket(PF_INET, SOCK_STREAM, 0);
setsockopt(sockfd, SOL_SOCKET, SO_REUSEADDR, &yes, sizeof(yes))

my_addr.sin_family = AF_INET;
my_addr.sin_port = htons(MYPORT);
my_addr.sin_addr.s_addr = INADDR_ANY;
memset(&(my_addr.sin_zero), 0, 8);

bind(sockfd, (struct sockaddr *)&my_addr, sizeof(struct sockaddr));
listen(sockfd, 10 /*BACKLOG*/);

while (1) { /* Wait for client to show up*/
    /* wait for activity on sockfd or other fds */
    /* accept new client */
    client_fd = accept(server_sock, (struct sockaddr *) &client_addr,
                        &size);
}
```



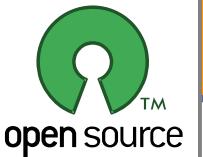
Volání select()



```
#include <sys/select.h>
fd_set rdfds, readable, wrfds, writable;

FD_SET(fd, &readable);
do {
    rdfds = readable; wrfds = writable;
    n = select(maxfd, rdfds, wrfds, exfds, &tout);
    if (FD_ISSET(fd, rdfds)) { read }
    FD_SET(fd, &writable);
    FD_CLR(fd, &readable);
} while (!exit_loop);
```

- ▶ Nevýhodné, trvalé procházení celého bitového pole deskriptorů jak na straně uživatele, tak na straně jádra a to do maximálního použitého FD
- ▶ Na straně jádra $O(fd_max+n_active)$ na každé volání, kratší pokud je již aktivní
- ▶ Na straně uživatele stejné nebo lze optimalizovat na $O(n_registered+n_active)$
- ▶ Limit pro všechna vlákna dohromady FD_SETSIZE (1024), na Linuxu lze i překročit



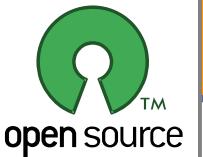
Volání poll()



```
#include <poll.h>

struct pollfd[MAX4THREAD];
array[i].fd = fd;
array[i].events = POLLIN;
do {
    n = poll(array, max, timeout);
    if (array[i].revents & POLLIN) { read }
    array[i].events = POLLOUT;
} while (!exit_loop);
```

- ▶ Na straně jádra $O(n_{\text{registered}} + n_{\text{active}})$ na každé volání
- ▶ Na straně uživatele stejné, nemá limit a overhead na FD použité v jiných threadech
- ▶ Výhoda je, že není třeba kopírovat požadavky mezi poli jako u *fd_set*, jsou od sebe oddělené *events* a *revents*



Volání epoll()



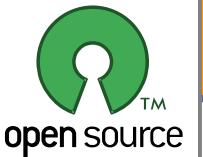
```
#include <sys/epoll.h>

epfd = epoll_create(0);
evt.data.fd = fd;
evt.events = EPOLLIN;
epoll_ctl(epfd, EPOLL_CTL_ADD, fd, &evt);

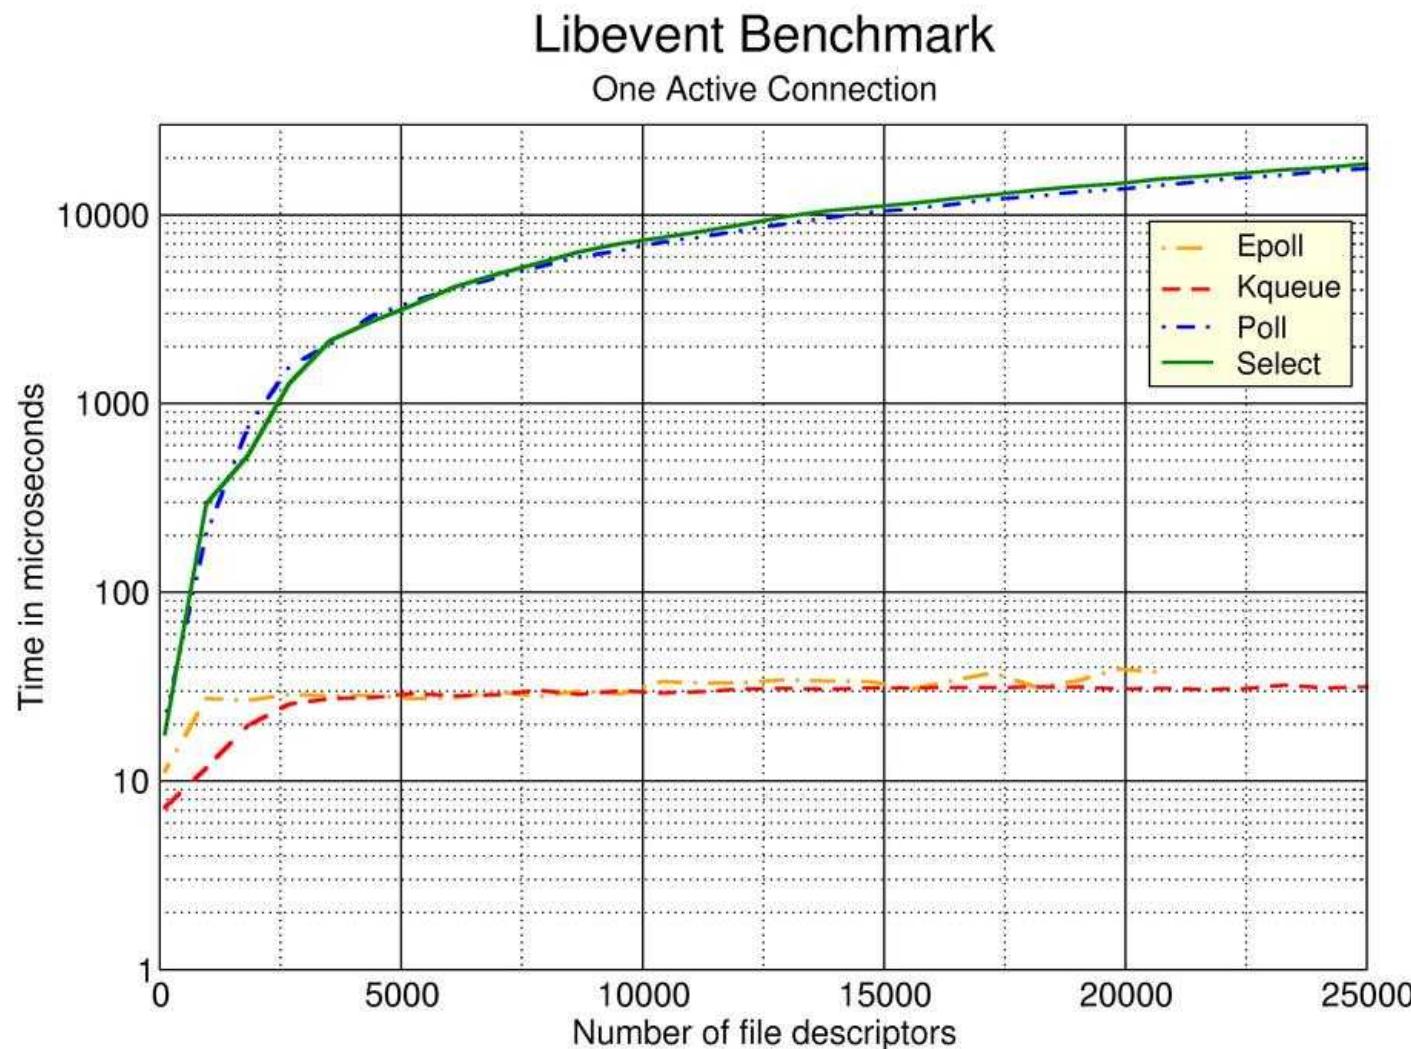
do {
    epoll_wait(epfd, res_buff, res_size, tout);

    evt.data.fd = fd;
    evt.events = EPOLLOUT;
    epoll_ctl(epfd, EPOLL_CTL_MOD, fd, &evt);
} while (!exit_loop);
```

- ▶ Na straně jádra $O(n_active+n_filter_changed)$ na volání; $O(1)$ na každou událost
- ▶ Na straně uživatele v podstatě stejné, přitom na jedno volání může být přeneseno kolik událostí, na kolik je nabídnut buffer
- ▶ Požadavky se registrují přímo ke zdrojům událostí v jádře, wait queue



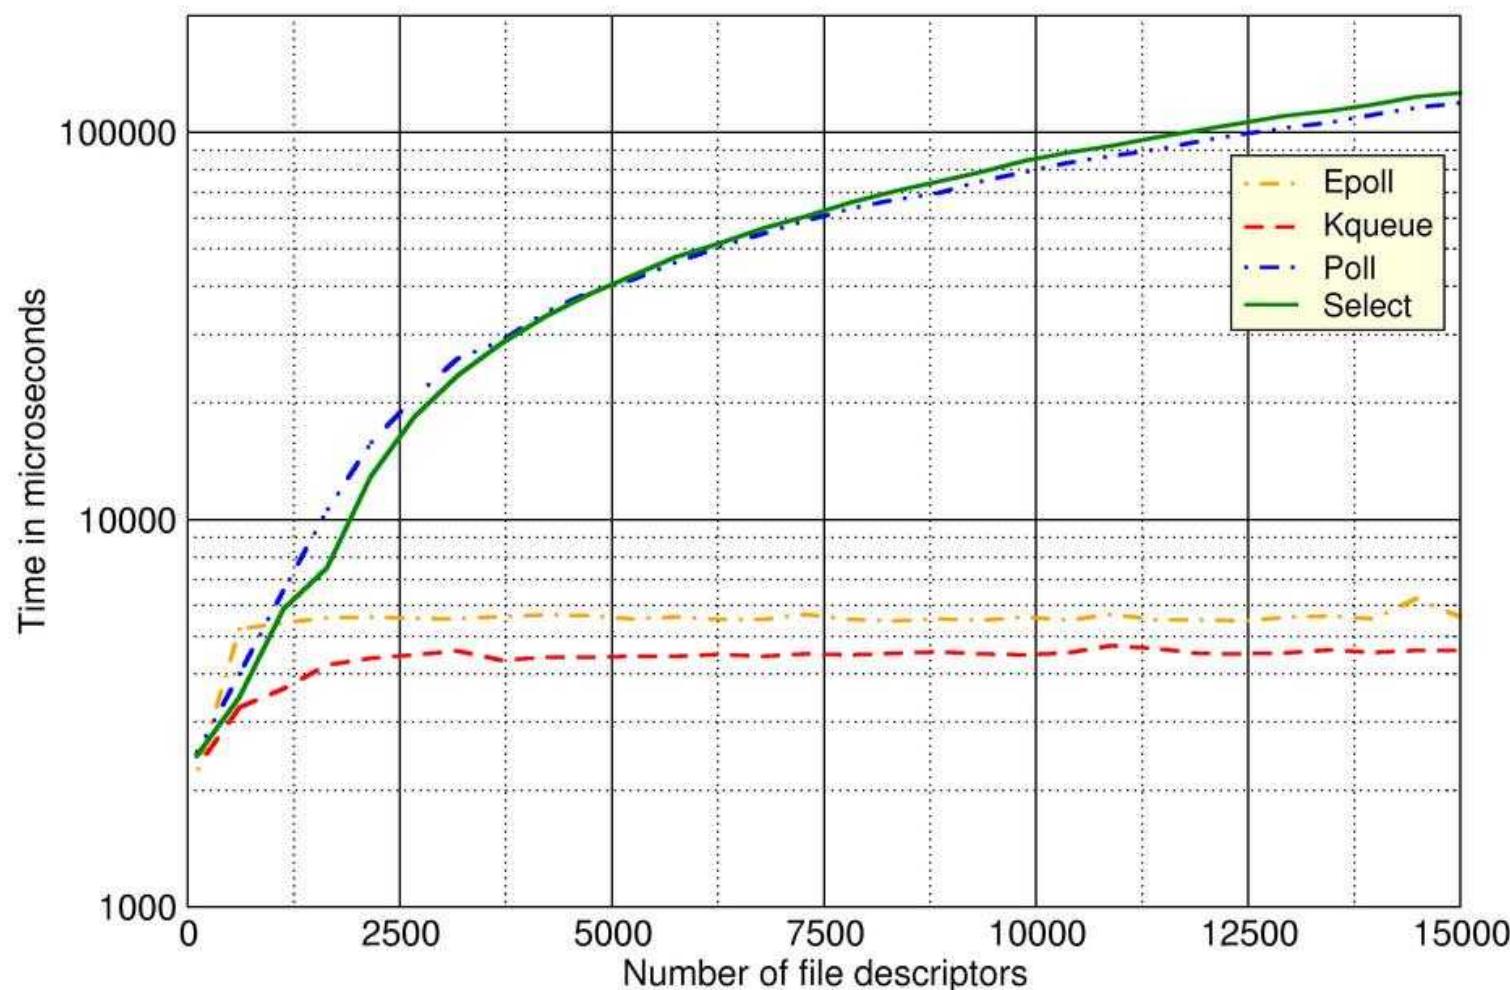
- ▶ BSD
 - ▶ kevent – náročnost stejná jako epoll, výhoda, že od svého vzniku podporuje přenos dalších typů událostí
- ▶ Solaris a další POSIX
 - ▶ /dev/poll
 - ▶ event ports
- ▶ Windows NT
 - ▶ IOCP – I/O Completion Port
 - ▶ Automatické řízení počtu aktivních vláken v threadpollu
- ▶ Java
 - ▶ Postupně implementovala tyto metody a zakrývá je pod `java.nio.channels.SelectorProvider`



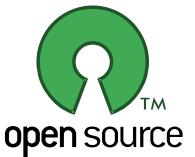
zdroj: libevent - <http://www.monkey.org/~provos/libevent/>

Libevent Benchmark

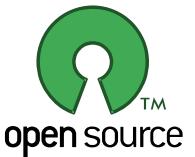
100 Active Connections and 1000 Writes



zdroj: libevent - <http://www.monkey.org/~provos/libevent/>



- ▶ Předchozí řešení jsou vhodná pro fronty nezávislých událostí
- ▶ **epoll** v kombinaci s více vlákny případně **I/O Completion Port** jsou pro tyto případy v podstatě optimálním řešením
- ▶ Velké databáze a paralelní práce nad velkými soubory vyžaduje zcela jiný přístup – i `mmap()` představuje problém, načítání (výpadek) stránky zcela blokuje daný thread, přitom zvyšování počtu threadů je řešení problematické (viz předchozí diskuze)
- ▶ Je potřeba přenést plánování I/O požadavků do user-space a zpracovávat data v tom pořadí, jak se je podaří načíst
- ▶ K tomu slouží služby pro **asynchronní I/O**, v Linuxu
 - ▶ standardizované **POSIX AIO**
 - ▶ nativní (pro Linux specifické) **libAIO**
 - ▶ Alternativa **mmap()** + **madvise()**



Asynchronní I/O – POSIX AIO (1)



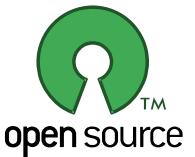
- ▶ Požadavky popsané **struct aiocb** se vkládají do seznamu ke zpracování do určitého (nastaveného) limitu je jejich zpracování startováno okamžitě/paralelně
- ▶ Při dokončení požadavku může být procesu nebo threadu doručen asynchronní **signál**, thread může na dokončení alespoň jednoho ze skupiny požadavků čekat **aio_suspend**.

```
/* Asynchronous I/O control block. */
struct aiocb
{
    int aio_fildes;          /* File descriptor. */
    int aio_lio_opcode;      /* Operation to be performed. */
    /* LIO_READ/LIO_WRITE/LIO_NOP */
    int aio_reqpri;           /* Request priority offset. */
    volatile void *aio_buf;   /* Location of buffer. */
    size_t aio_nbytes;        /* Length of transfer. */
    struct sigevent aio_sigevent; /* Signal number and value. */

    /* Internal members. __error_code, __return_value/size */

    off_t aio_offset;        /* File offset. */
};

};
```



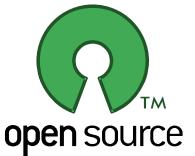
Asynchronní I/O – POSIX AIO (2)



```
#include <aio.h>

int aio_read      (struct aiocb *aiocbp);
int aio_write     (struct aiocb *aiocbp);
int lio_listio    (int wait_mode, struct aiocb * const list[],
                    int nent, struct sigevent *notice);
int aio_cancel    (int fildes, struct aiocb *aiocbp);
int aio_suspend   (struct aiocb *const list[],
                    int nent, const struct timespec *timeout);
int aio_fsync     (int operation, struct aiocb *aiocbp);
/* O_DSYNC/O_SYNC */
int aio_error     (const struct aiocb *aiocbp);
/* EINPROGRESS/0 (OK) /ENOSYS/EINVAL */
ssize_t aio_return  (struct aiocb aiocbp); /* size/fsync ret */
```

- ▶ Současná implementace v **GLIBC** je založená na thread-pool(u) v user-space
- ▶ Toto řešení není výhodné a je snaha vytvořit pro Linux nativní podporu pro asynchronní operace v jádře – systémové volání **io_submit**



Nativní asynchronní I/O

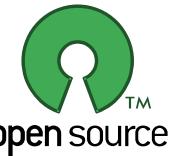


```
#include <libaio.h>

struct iocb iocbq[MAX_PARALLEL]; int iocbq_used;
struct stat st;
io_context_t myctx;

fstat(srcfd, &st);
length = st.st_size;
memset(&myctx, 0, sizeof(myctx));
io_queue_init(aio_maxio, &myctx);
offset = 0;
/* Prepare memory for requests 0 .. iocbq_used-1*/
iocbq[i] = (struct iocb *) malloc(sizeof(struct iocb));
posix_memalign(&buf, alignment, iosize)
io_prep_pread(iocbq[i], -1, buf, iosize, offset);
offset += iosize;
io_set_callback(iocbq[i], rd_done);

rc = io_submit(myctx, iocbq_used, iocbq);
rc = io_queue_run(myctx); /* nonblocking */
rc = io_queue_wait(myctx, NULL /*&timeout*/);
```



Odkazy na další informace



- ▶ Dan Kegel: The C10K problem
<http://www.kegel.com/c10k.html>
- ▶ Nick Mathewson a Niels Provos
<http://www.monkey.org/~provos/libevent/>
/dev/poll, kqueue(2), event ports, select(2), poll(2), epoll(4), Win IOCP
- ▶ uLEvPoll Library - uLan/Universal Light Event Poll Library
<http://ulan.git.sourceforge.net/git/gitweb.cgi?p=ulan/ulevpoll>
<http://ulan.sourceforge.net/pdf/ulevpoll.pdf>