InfiniBand és Linux

Vajon miért is jó, ha a hálózatunk távoli rendszere irkálhat a memóriánkba, hogyan küldhetnek felhasználói programok a rendszermag zaklatása nélkül adatokat, valamint néhány újabb adalék a nagy sebességű kapcsolattartásról.

Hosszú vajúdást követően végül megszületett az ***InfiniBand (IB)***, sőt a ***Linux IB*** támogatása is már fejlesztés alatt áll. Fizikai szinten az ***IB*** nagyon hasonlít a ***PCI Express***-re. Az adatokat több nagy sebességű soros csatornán továbbítja. Az ***InfiniBand*** első változatának leírása valamennyi csatornán azonos jelzésszélességet engedélyezett, mégpedig 2.5Gb/s-ot, akárcsak a ***PCI Express***.
A leírás legutóbbi változata (1.2), ugyanakkor már támogatja a csatornánkénti 5Gb/s és 10Gb/s sebességeket. Ezen kívül az IB az 1X, 4X, 8X és 12X, míg a ***PCI Express*** a X1, X2, X4, X8, X12, X16 és X32 szélességeket támogatja. A leggyakrabban használt ***IB*** sebesség manapság a 4X 2.5Gb/s/csatorna sebesség mellett, azaz összesen 10Gb/s. A 12X szélesség a 10Gb/s/csatorna sebességgel kombinálva azonban a jelenlegi ***IB*** leírás szerint akár a lenyűgöző 120Gb/s átviteli teljesítményt is támogatja.
Minthogy az ***IB*** általában hálózatépítésre használatos, a réz és optikai kábelezést egyaránt támogatja, míg a ***PCI Expressz*** kábelmeghatározásai még fejlesztés alatt állnak.
A legtöbb ***IB*** telepítés rézkábelezést alkalmaz (*1. ábra*) amely körülbelül 10 méterig használható. Az ***IB*** ezen kívül lehetővé tesz optikai kábelezést is, amely elméletileg akár 10 kilométerig is használható.

Az elmúlt években az ***IB***-t tekintették a ***PCI*** utódjának, de manapság már nem ez a helyzet. Az ***IB*** adapterek továbbra is inkább külső eszközök maradnak amelyek ***PCI***, ***PCI Express***, ***HyperTransport*** vagy hasonló periféria buszokon keresztül csatlakoznak a rendszerhez.
A rendszereket az ***IB*** hálózathoz csatoló hálózati eszközt ***Host Channel Adapternek (HCA)*** nevezik. Az eszköz igen magas sebessége mellett az ***IB HCA*** egy üzenetközvetítő felületet is biztosít, melynek segítségével az ***InfiniBand*** 10Gb/sec (vagy még nagyobb) sebességét ki tudják aknázni a rendszerek. Az ***IB*** sebességének kihasználásának kulcsa a zéró másolású hálózatkezelés támogatása; máskülönben az alkalmazások egyfolytában csak az adataikat másolnák.
A zéró másolást a ***HCA*** felület három kulcseleme teszi lehetővé: az elvont, magasszintű munkasor, a rendszermag megkerülés és a ***távoli közvetlen memória elérés (Remote DMA; RDMA)***. Az elvont munkasor annyit jelent, hogy az alkalmazások nem csomagról csomagra formálják meg és dolgozzák fel a hálózati csomagokat, hanem kérelmeket küldenek a ***HCA*** által kezelt soroknak.
Egy munkakérelmen belül küldött üzenetet legfeljebb 4GB hosszú lehet. A ***HCA*** felügyeli az üzenet csomagokra tördelését illetve várakozik a jóváhagyásokra és küldi

1. táblázat ***Összehasonlító tábla***

Technológia	Adatátviteli sebesség	Kábelezés
USB	12Mb/s	5m
Hi-Speed USB (USB 2.0)	480Mb/s	5m
IEEE 1394 (FireWire)	400Mb/s	4m
Gigagbit Ethernet	1,000Mb/s	100m (cat5 kábel)
10 Gigabit Ethernet	10,000Mb/s	10m (réz IB kábel), 1+ km (optikai)
Myrinet	2,000Mb/s	10m (réz), 200m (optikai)
1X InfiniBand	2,000Mb/s	10m (réz), 1+ km (optikai)
4X InfiniBand	8,000Mb/s	10m (réz), 1+ km (optikai)
12X InfiniBand	24,000Mb/s	10m (réz), 1+ km (optikai)

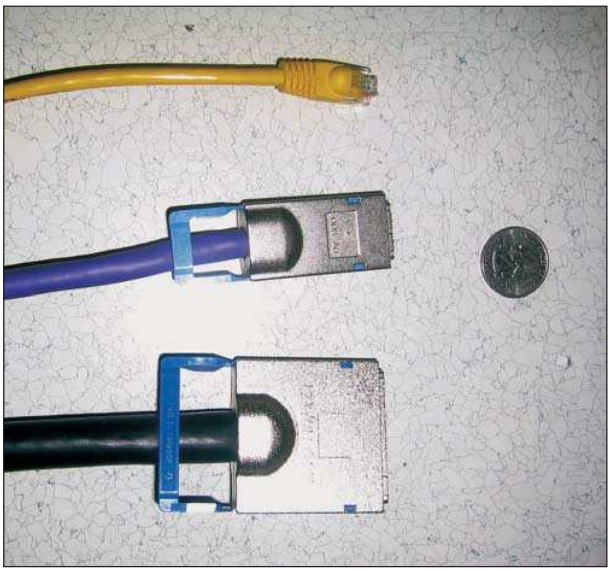

1. ábra Felülről lefelé: cat5 Ethernet kábel, 4X InfiniBand kábel és 12X InfiniBand kábel (méretarány kedvéért egy negyeddolláros érme látható)

1. lista IPoIB Meghajtó alaphelyzetbe állítása

```
struct ib_qp_init_attr init_attr = {
    .cap = {
        .max_send_wr  = IPOIB_TX_RING_SIZE,
        .max_recv_wr  = IPOIB_RX_RING_SIZE,
        .max_send_sge = 1,
        .max_recv_sge = 1
    },
    .sq_sig_type = IB_SIGNAL_ALL_WR,
    .rq_sig_type = IB_SIGNAL_ALL_WR,
    .qp_type     = IB_QPT_UD
};
priv->pd = ib_alloc_pd(priv->ca);
priv->cq = ib_create_cq(priv->ca,
            ipoib_ib_completion,
            NULL, dev,
            IPOIB_TX_RING_SIZE +
            IPOIB_RX_RING_SIZE + 1);
if (ib_req_notify_cq(priv->cq, IB_CQ_NEXT_COMP))
    goto out_free_cq;
priv->mr = ib_get_dma_mr(priv->pd,

IB_ACCESS_LOCAL_WRITE);
init_attr.send_cq = priv->cq;
init_attr.recv_cq = priv->cq,
priv->qp = ib_create_qp(priv->pd, &init_attr);
```

újra az elveszett csomagokat. Mivel a *HCA* alkatrész felügyeli a nagyméretű üzenetek kézbesítését bármiféle *CPU* felhasználás nélkül, az alkalmazások több *CPU* időt használhatnak fel a küldött és fogadott adatok elkészítéséhez és feldolgozásához.

A rendszermag megkerülése lehetővé teszi, hogy az alkalmazások közvetlenül küldjenek munkakérelmeket és fogadjanak befejezési eseményeket a *HCA* sorairól, így a rendszerhívásokkal járó felesleges környezetváltás elkerülhető. A rendszermag meghajtó beállítja a sorokat, ahol a szokásos memória védelem gondoskodik arról, hogy minden folyamat csak a saját erőforrásait érje el. Valamennyi nagysebességű irányítási (path) művelet ugyanakkor a felhasználói térben megy végbe.
Az utolsó elem, az *RDMA*, lehetővé teszi, hogy az üzenet magával vigye a célcímet ahová a memóriában majd kerülnie kell. Az adat helyének megadása például az *IB* alatti tárolók kialakításakor lehet hasznos, ahol a kiszolgáló lemezolvasásai teljesen rendszertelenek lehetnek. *RDMA* nélkül vagy a kiszolgálónak kell időt pazarolnia mikor áll elküldésre készen az adat vagy az ügyfélnek kell *CPU* erőt pazarolnia az adatok végső helyre másolásához.
Bár a távoli rendszerek memóriájába firkálással szemben vannak bizonyos fenntartások az *IB* használó alkalmazások szigorú határokat és jogosultságokat állíthatnak be az *RDMA* szolgáltatásnak. Az *IB RDMA* legalábbis biztonságosabb dolog mint a lemezvezérlő *DMA*-ját a memóriába engedni.
Nagy sebességén felül, az *IB* egyúttal a *fürtök (clusters)* készítését és kezelését is leegyszerűsíti, hiszen egyetlen eszköz szállítja a hálózati és tároló forgalmat valamint a fürt kommunikációt. Több csoport is hozott létre különféle *IB* felett futtatható felső szintű protokollokat, néhány ezek közül:

- *IP-over-InfiniBand (IPoIB)*: az *Internet Engineering Task Force (IETF)* szabványfejlesztő munkacsoportja az *IB* alatti *IP* forgalomküldés ösvényét tapossa ki. Ezek az ösvények idővel a *IpoIB RFC* szabványává válhatnak. Az *IPoIB* ugyanakkor nem használja maximálisan ki az *IB* képességeit, hiszen a forgalom továbbra is az *IP* vermen keresztül utazik és csomagról csomagra kerül elküldésre. Az *IPoIB* egyszerű lehetőséget biztosít régebbi alkalmazásaink futtatására vagy a vezérlőforgalom átküldésére *IB*-n keresztül.

- *Sockets Direct Protocol (SDP)*: az *InfiniBand Trade Association* maga adott meg egy olyan protokollt, amely a szabványos socket műveleteket helyi *IB RDMA* műveletekké alakítja. Ezáltal a socket alkalmazások változtatás nélkül futtathatók, ugyanakkor az *IB* teljesítményének szinte minden előnyét élvezhetik.

- *SCSI RDMA protokoll (SRP)*: a *SCSI* szabványokért felelős *InterNational Committee for Information Technology Standards (INCITS) T10* bizottság, kiadott egy szabványt, amely leírja hogyan kell a *SCSI* protokollt az *IB*-hoz rendelni. A második generációs *SRP-2* protokoll fejlesztése jelenleg folyik.

Sok más csoport is tanulmányozza az *IB* kihasználási lehetőségeit, például a *DAT Collaborative* és az *Open Group Interconnect Software Konzorciuma* készített *API*-kat, *RDMA* csatolásokat az *NFS*-hez valamint *IB* támogatást különféle *MPI* csomagokhoz.

2. lista IPoIB meghajtó küldési kérelem feladása

```
priv->tx_sge.lkey            = priv->mr->lkey;
priv->tx_sge.addr            = addr;
priv->tx_sge.length          = len;
priv->tx_wr.opcode           = IB_WR_SEND;
priv->tx_wr.sg_list          = &priv->tx_sge;
priv->tx_wr.num_sge          = 1;
priv->tx_wr.send_flags       = IB_SEND_SIGNALED;
priv->tx_wr.wr_id            = wr_id;
priv->tx_wr.wr.ud.remote_qpn = qpn;
priv->tx_wr.wr.ud.ah         = address;

ib_post_send(priv->qp, &priv->tx_wr, &bad_wr);
```

Természetesen nyílt forráskódú támogatás nélkül az egész csinos eszköz nem lenne különösebben érdekes a ***Linux*** világban. Szerencsére az ***OpenIB Alliance*** ipari szövetség feladata pontosan az, hogy egy teljesen nyílt forrású ***IB*** vermet hozzon létre. Az ***OpenIB*** jelenleg 15 tag-céggel rendelkezik, amelyek között egyaránt találunk ***IB*** alkatrész terjesztőket, kiszolgálócégeket, programcégeket és kutatási szervezeteket.

Az ***OpenIB*** programon 2004 februárjában kezdődtek meg a munkálatok, az első rendszermag meghajtó pedig 2004 decemberében került a rendszermag fába, közvetlen azután, hogy a 2.6.10-es kiadás után megszületett a 2.6.11-es fa. A rendszermagba illesztett első ***IB*** meghajtó kód csomag éppen csak annyit tud, hogy már azért működőképes. Tartalmaz egy középréteget, amely elfedi az alacsonyszintű alkatrészmeghajtókat a felsőszintű protokollok elől, egyetlen alacsonyszintű meghajtót a ***Mellanox HCA***-hoz, valamint egy ***IPoIB*** felsőszintű protokoll meghajtót amellyel egy alhálózat kezelőt futtathatunk a felhasználói térben.

Az ***IPoIB*** meghajtó kódjának néhány apró részlete sokat elárulhat a rendszermag ***IB*** támogatásának felhasználási lehetőségeiről. Amennyiben egészében szeretnénk látni a kódot, a teljes ***IPoIB*** meghajtót kell megnéznünk, amelyet egyébként a ***Linux*** forrásfájának ***drivers/infiniband/ulp/ipoib*** könyvtárában találjuk meg.

Az *1. lista* bemutatja, mit is csinál az ***IPoIB*** meghajtó az ***IB*** erőforrások lefoglalásához. Először meghívja az ib_alloc_pd() függvényt, amely lefoglalja a ***védelmi tartományt (protection domain vagy PD)***, ez egy átlátszó tároló amelyre valamennyi ***IB*** felhasználónak szüksége van az erőforrások tárolásához.

Itt most kihagytuk a listából a helyes hibakezelést, annak ellenére, hogy minden valódi rendszermag kód valamennyi függvény visszatérési értékét ellenőrizné. Minden erőforrást foglaló és mutatót visszaadó ***IB*** függvény a szokásos ***Linux*** módszert alkalmazza a hibák visszaadására az `ERR_PTR()` makrón keresztül, következésképpen az állapotot az `IS_ERR()` segítségével le lehet kérdezni. Például a `ib_alloc_pd()` hívás a valódi rendszermag kódban a következőképpen nézne ki:

```
priv->pd = ib_alloc_pd(priv->ca);
if (IS_ERR(priv->pd)) {
        printk(KERN_WARNING "%s: failed "
                "to allocate PD\n", ca->name);
        return -ENODEV;
}
```

Ezek után a rendszermag meghívja az `ib_create_cq()` függvényt, amely létrehozza az ***befejeződési sort (completion queue, azaz CQ)***. A meghajtó igényli, hogy az befejeződési esemény bekövetkeztekor meghívódjon az `ipoib_ib_completion()` függvény, valamint, hogy a ***CQ*** legalább `IPOIB_TX_RING_SIZE + IPOIB_RX_RING_SIZE + 1` darab munkabefejezési struktúrát tárolhasson. Erre a méretre abban a különleges esetben van szükség, amikor a meghajtó a lehető legnagyobb számú üzenetet küldi és és fogadja majd nem tud lefutni, míg valamennyi el nem készül. Elég zavaró módon, a ***CQ***-k olyan ***IB*** erőforrások, amelyek nincsenek kapcsolatban a ***PD***-kel, ezért a függvénynek nem is kell átadnunk ***PD*** adatot.

Amikor a ***CQ*** elkészült a meghajtó az `ib_req_notify_cq()` függvényhez fordul és kérelmezi, hogy amikor a következő munkabefejezés a ***CQ*** sorba kerülésére hívódjon meg a befejezési esemény függvény. Az `ipoib_ib_completion()` eseményfüggvény feldolgozza a befejezéseket amíg a ***CQ*** ki nem ürül, majd meghívja az `ib_req_notify_cq()`-t. Így újra elindul, amint újabb befejezések válnak elérhetővé.

A meghajtó ekkor meghívja az `ib_get_dma_mr()`-t amely beállítja a rendszermag ***DMA*** osztó ***API***-tól kapott ***DMA*** címmel használható memóriaterületet (***MR***). Ennek kezeléséhez az ***IB HCA***-ban to elkészülnek az átalakító táblák, és egy helyi kulcsot (`L_Key`) adunk vissza, amelyet aztán tovább lehet adni a ***HCA***-nak, és hivatkozhat az adott ***MR***-re.

Végül a meghajtó az `ib_create_qp()`-t hívja meg, amely létrehoz egy sorpárt (***QP***). Ezt az objektumot azért nevezik sorpárnak mert két darab munkasort tartalmaz. Egyet a küldési kérelmeknek és egyet a fogadási kérelmeknek. A ***QP*** létrehozásához először ki kell töltenünk a meglehetősen méretes `ib_qp_init_attr` szerkezetet. A fedőstruktúra a készítendő küldő és fogadó sorok méretét adja meg. A `sq_sig_type` és az `rq_sig_type` mezőket `IB_SIGNAL_ALL_WR` értékre állítjuk, így minden munkakérelem befejezési eseményt vált ki .

A `qp_type` mezőt `IB_QPT_UD` értékre állítjuk, létrehozva ezzel a ***megbízhatatlan adatcsomag (unreliable datagram avagy UD) QP***-t. Az ***IB QP*** esetében négyféle szállításról beszélhetünk: ***megbízhatóan összekapcsolt (RC)***, ***megbízható adatcsomag (RD)***, ***megbízhatatlanul kapcsolt (UC)*** és ***megbízhatatlan adatcsomag (UD)***.

A megbízható szállítások esetében az ***IB*** alkatrész garantálni tudja, hogy minden egyes üzenet vagy sikeresen kézbesítődik, vagy hibát jelez amennyiben a hibát egy javíthatatlan hiba okozza (például kihúzzuk a kábelt). A kapcsolt adatszállítás esetében minden üzenet egyetlen célállomásra irányul, amelyet a ***QP*** beállításakor határozunk meg, az adatcsomag szállítás esetében minden egyes csomag különböző célokra irányulhat.

Amikor az ***IPoIB*** meghajtó elkészítette a ***QP***-t, a kapott csomagokat a ***QP***-n keresztül küldi a hálózati verembe.

A *2. lista* mutatja be, hogy mit kell tennünk akkor,

ha egy kérelmet akarunk helyezni a *QP* küldési sorába. Először is a meghajtó a küldési kérelemhez felállít egy gyűjtőlistát. Az `lkey` mező annak az *MR*-nek az `L_Key` értékét veszi fel, amelyet az `ib_get_dma_mr()`-ből kaptunk. Minthogy az *IPoIB* olyan csomagokat küld, amelyek egyetlen összefüggő részben találhatóak, a gyűjtőlistában mindössze egyetlen bejegyzés található. A meghajtónak csak a címet és csomag hosszát kell megadnia. A gyűjtőlistában található cím nem a virtuális cím hanem a `dma_map_single()` függvénnyel megkapott *DMA* cím lesz. Általánosságban a programok hosszabb gyűjtőlistákat is használhatnak, ezáltal rákényszerítve a *HCA*-t, hogy egyetlen üzenetbe gyűjtsön össze több puffert és így nem kell egyetlen pufferbe másolnia az adatokat.

A meghajtó ezután kitölti a munkakérelem maradék mezőit. Az `opcode`-ot `send`-re állítja, az `sg_list` és `num_sge` értékeket az éppen kitöltött gyűjtőlista címe kerül a `send_flags` értéke pedig `signaled` lesz, így a munkakérelem befejezést vált ki amikor végez. A távoli *QP* számot és címkezelőt beállítjuk, majd a `wr_id` mezőbe a meghajtó munkakérelem azonosítója kerül.

A munkakérelem kitöltése után a meghajtó meghívja az `ib_post_send()`-et, amely végül a kérelmet felveszi a sorba. Amikor a kérelmet teljesítette az *IB* alkatrész, a munka teljesítése a meghajtó *CQ* sorába kerül, amelyet végül az `ipoib_ib_completion()` dolgoz fel.

Az *InfiniBand* rengeteg mindenre képes és az *OpenIB Alliance* éppen csak elkezdte megírni a képességeit kihasználó programokat. Most, hogy már a Linux rendelkezik az alapvető *IB* támogatással, nekiláthatunk a felsőszintű protokollok elkészítésének, ideértve például az *SDP*-t és a tároló protokollokat. A másik komolyabb terület amely jelenleg foglalkoztat bennünket, a közvetlen felhasználói térbeli *IB* elérés, azaz a korábban említett rendszermag megkerülő képesség. Rengeteg érdekes dolgot lehet még csinálni az *IB*-hez és az *OpenIB Projekt* mindenki számára nyitott, kalandra fel tehát, csatlakozz a mókához.

Linux Journal 2005. május, 133. szám

Roland Dreier Linux InfiniBand meghajtók karbantartója és vezető fejlesztője az OpenIB.org projekt keretében. Roland a Kaliforniai Berkeley egyetemen szerezte matematika doktorátusát és több különféle titulusa volt már akadémiai körökben valamint a műszaki világban. 2001 óta a Topspin Communications alkalmazásában áll.

KAPCSOLÓDÓ CÍMEK

- www.openib.org
- www.infinibandta.org
- www.ietf.org
- www.t10.org
- www.datcollaborative.org