Paralelizmus, synchronizace, GCD

IZA, Martin Hrubý, FIT VUT, 2019

Úvod

- Vlákna, **Grand Central Dispatch**.
- Větší pochopení principu činnosti programu.
- Bezpečnostní pravidla **interakce objektů v aplikacích**.
- Dnes si povídáme o knihovně **Foundation**, tj.
  - … o principech platných pro všechny platformy Apple.

Historie paralelizmu

- Task-switching.
- Apple — kooperativní multitasking (SIMLIB).
- Preemptivní multitasking.
- UNIX — fork(), více-uživatelský běh OS.
- Vlákna, POSIX threads.
  - Procesy versus vlákna.
  - Paměťová režie — dynamický zásobník, paměť pro registry.
- Multi-tasking versus Paralelizmus.

Paralelní programování a HW

- Máme zařízení s více jádry CPU.
- Program je paralelizovatelný. Přínosy?
- Dokážeme efektivně/komfortně/bezpečně napsat paralelizující program.
- Program je škálovatelný. Je schopen fungovat i jednovláknově.
  - Programování paralelizovatelného programu (C/C++, MPO).
  - GCD a systém bloků kódu.

Co je běh aplikace?

- OS (iOS/macOS) vytváří a spravuje vlákna.
- OS přiřazuje vláknům čas na CPU.
  - Vlákno **nelze zabít/přerušit**. Jde mu **nepřidělit další čas** CPU.
  - Vlákno vykonává kód. Až kód dokončí, řekně OS, že končí,
  - musí se ukončit **"z vlastní vůle a dobrovolně"**. Kooperativně.
- OS daruje aplikaci 1 MT a několik GT.
  - Main Thread, Global Threads (podle počtu jader CPU).
  - Tato vlákna "žijí v RunLoop" aplikace.

RunLoop aplikace

- Jádro aplikace.
- Dostává zprávy od OS (události UI) — fronta.
- Má fronty práce — fronta bloků (*closures*).
- Vlákna si berou bloky z front a vykonávají je.
- Přechod aplikace do pozadí:
  - OS přestane přidělovat čas vláknům aplikace.

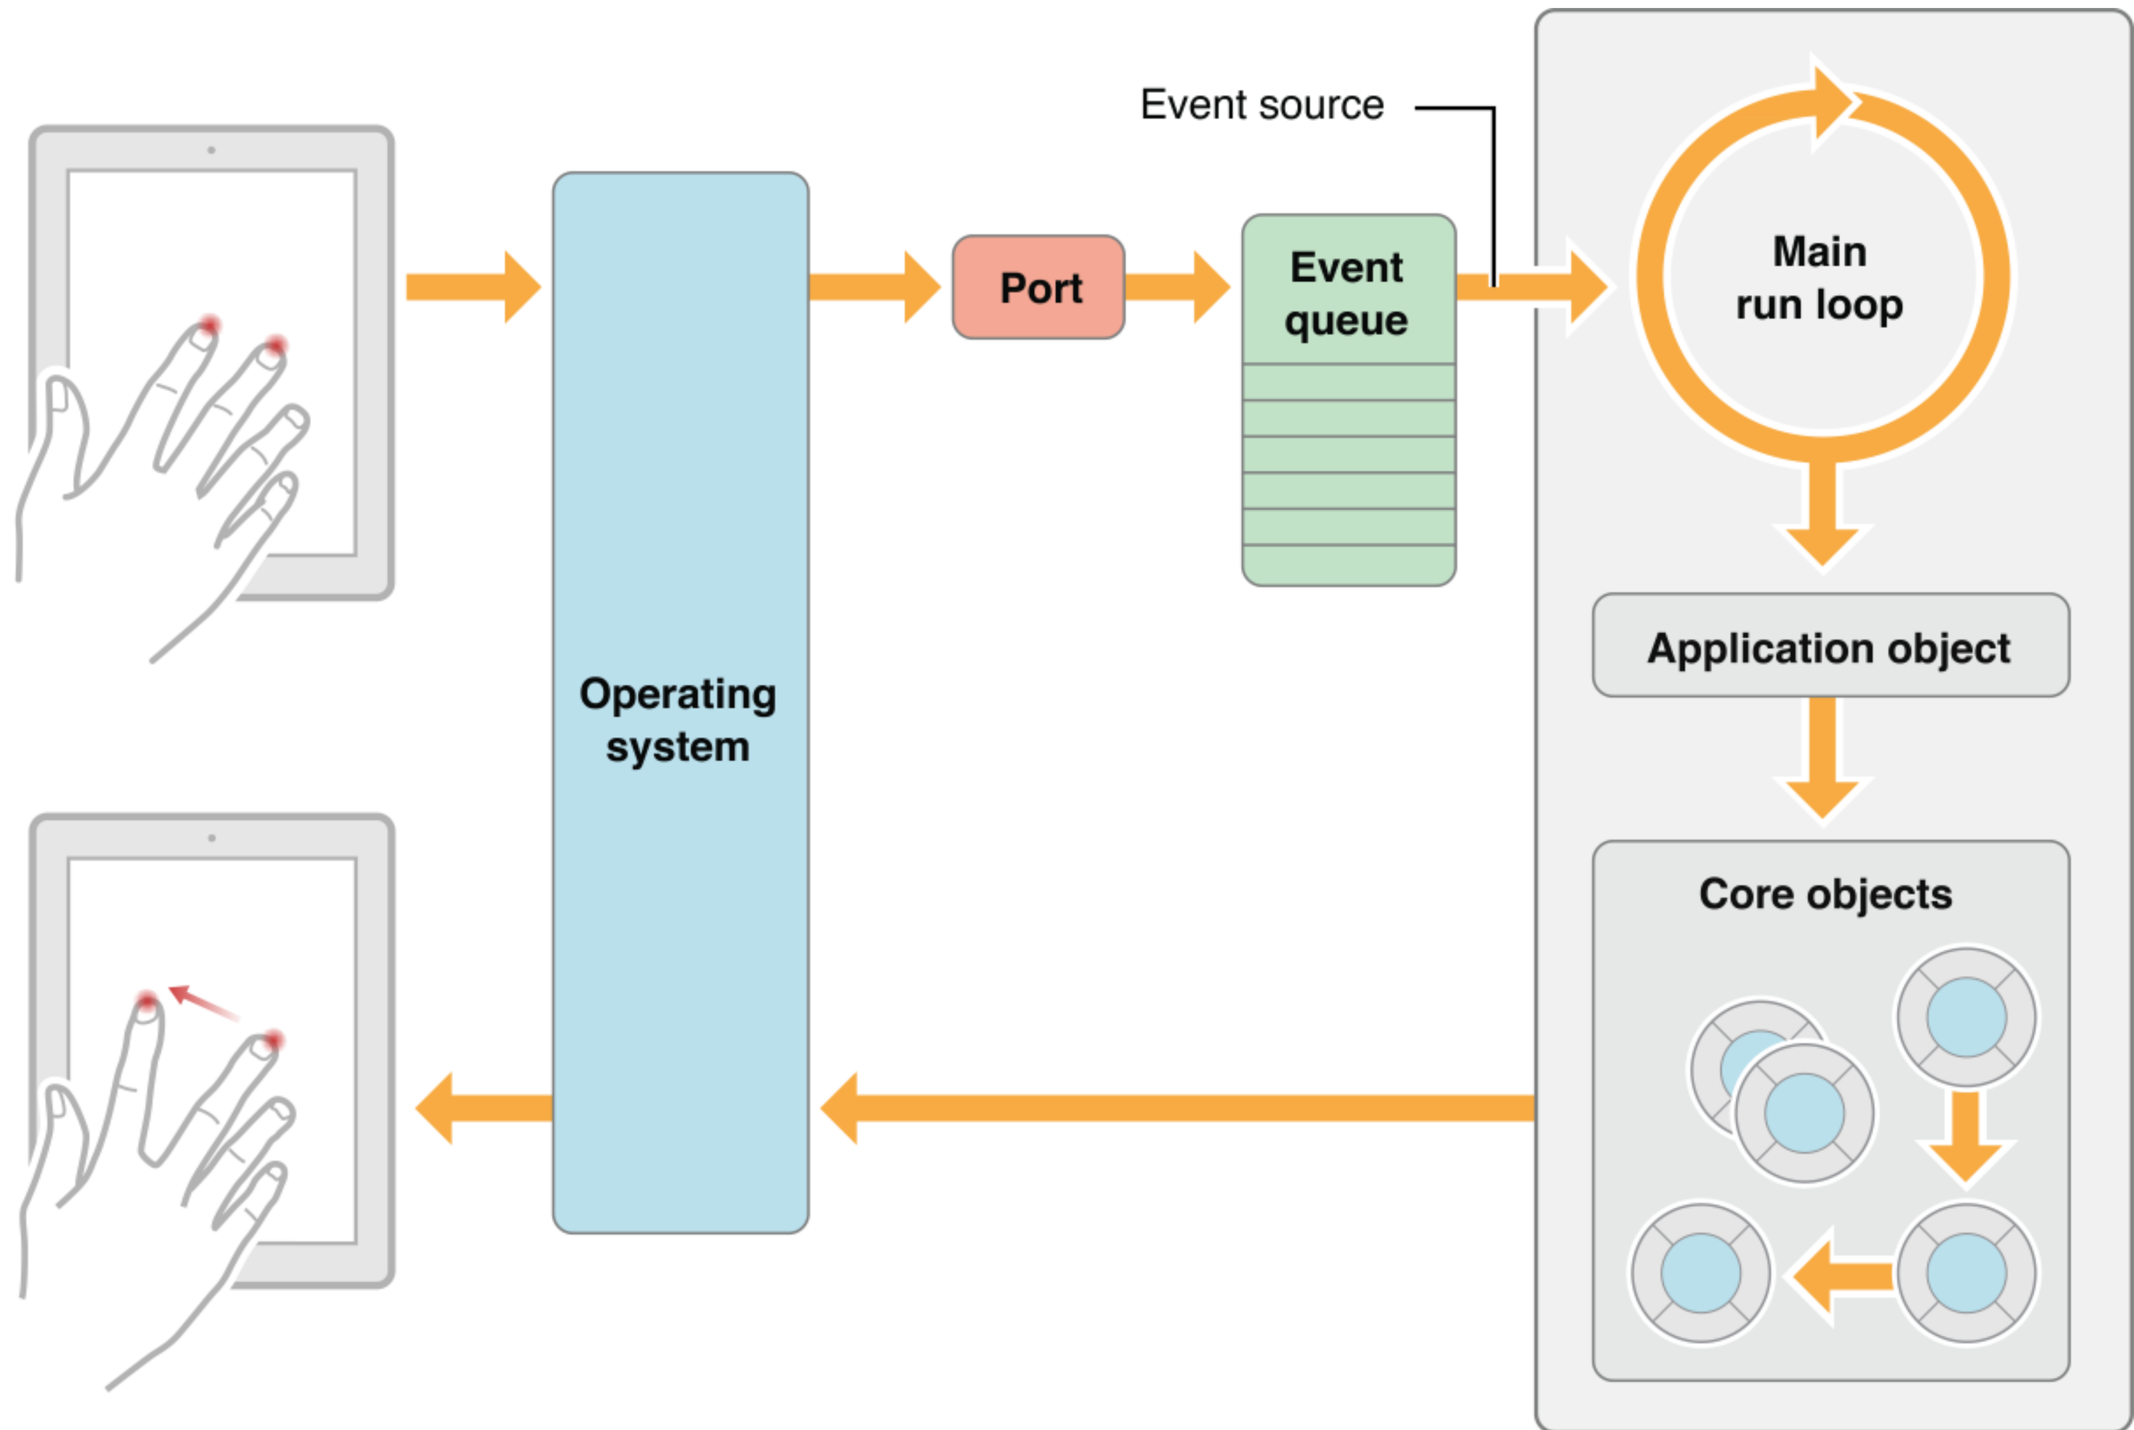
Event source
Port
Event queue
Main run loop
Operating system
Application object
Core objects

RunLoop a UI

- Fronty práce (*MainQueue*, sekvenční, paralelní).
  - Pool vláken — berou si z front bloky práce a vykonávají.
  - *MainThread* bere prioritně z *MainQueue* a *obsluhuje události*.
- UI fáze:
  - Modifikace stavu UI — atributy, setNeeds Display / Layout.
  - Rendering — generování bitmap Views a jejich kompozice.
  - Animace — nějaká změna rozfázovaná v čase.
  - Důsledek: Pro plynulost UI musí MT **často projít RunLoopem**.

UI běží pouze v MainThread

- UI výhradně v MainThread. Proč?
  - UI (kód UIKit + stav aplikace/UI) je **v app sdílený prostředek**.
  - Jak by vypadalo paralelní provádění UI?
  - Takže můžeme buď zamykat části UI (hromada problémů).
  - … nebo **rozhodnout UI pouze pro MainThread**.
- Důsledky:
  - RunLoop — dbát o "častou obrátku" v RunLoop.
  - MainThread — velmi krátké činnosti.

Odkud se bere spustitelný kód?

- Aplikace smí vytvářet *vlastní vlákna*.
  - Nežijí v RunLoop. Mají vlastní kód. OS přiděluje čas na CPU.
  - Toto není typické pro iOS aplikace.
  - Pozn.: běh aplikace na pozadí (aplikace není viditelná).
- Typicky aplikace definuje bloky a vkládá je do front (skoro Next-Event). *Escaping closures*.
  - Systém řízení bloků ve frontách se nazývá **Grand Central Dispatch (GCD)**.

```swift
protocol MThreadDelegate : class {
    //
    func updateUI(fromThread: MThread)
}

class MThread: Thread {
    //
    weak var delegate: MThreadDelegate?
    //
    override func main() {
        //
        while true {
            // dostal jsem zpravu cancel()?
            if isCancelled { break; }
            // pauza
            Thread.sleep(forTimeInterval: 1)
            // dostal jsem zpravu cancel()?
            if isCancelled { break; }
            // neco delej (pozor na MT)
            DispatchQueue.main.async {
                //
                self.delegate?.updateUI(fromThread: self)
            }
        }
    }
}
```

Periodická činnost, Timer

- Timer — registrace jednorázové / periodické akce v RunLoop.
  - reference, selektor, perioda. Aktivace nějaké metody.
  - Nepřehánět to s počtem časovačů v aplikaci (globální časovač rozesílající notifikaci do aplikace).
- AppDelegate — správa časovačů (přechod popředí, pozadí).
- Odložená invokace bloku / metody.

Grand Central Dispatch

- Do fronty X se naplánuje sync/async closure Y.
  - Co se naplánuje, už nejde odplánovat.
  - Closure Y ve frontě není explicitně referencovatelný, tj. nelze mu poslat zprávu (ani není jazykově-syntakticky jak…).
- Běh bloku nelze zastavit/zrušit/…
  - Vlákno X do něj vstoupí. Až ho dokončí, tak vystoupí.
  - Vlákno X ”proteče blokem”.

Opakování: Trailing closures

- Pokud je poslední argument funkce blokem, lze redukovat syntaxi volání funkce.

```
func gogo(closure: ()->Void) {
    print("Do something")
    closure()
}

// volam gogo
gogo(closure: { print("Hello") })

// volam gogo
gogo {
    print("Hello again")
}
```

sync/async dispatch

- DispatchQueue.frontaQ.async { blok1 }
    - Vlákno X vykonává async(blk: @escaping ()->()),
    - vloží blok1 do frontaQ a z metody vystoupí. LOCK.
    - Odesílatel se nezajímá o další osud bloku.
- DispatchQueue.frontaQ.sync { blok2 }
    - …, …vloží blok2 do fronty a
    - pasivuje se, dokud nedostane signál o dokončení blok2,
    - pak z metody sync vystoupí a pokračuje dál…

Sync/Async

```
DispatchQueue.main.async {
    //
    print("Hello")
}

DispatchQueue.global().async {
    //
    // otevri soubor
     // sync/async
    DispatchQueue.main.sync {
        //
        // posli zpravu UI, soubor otevren
    }
}
```

Synchronní vkládání

- Vkládající vlákno čeká, tj. je blokováno.

```
class VC: UIViewController {
    //
    override func viewDidLoad() {
        //
        super.viewDidLoad();

        // tady to slitne na EXC_BAD_INSTRUCTION
        DispatchQueue.main.sync {
            //
            print("Hello")
        }
    }
}
```

Fronty GCD a synchronizace

- Neříkám, pro které vlákno to plánuju, ale má to proběhnout:
  - *Sekvenční* (serial) — blok se zahájí po dokončení předchozího bloku ***z této fronty***.
  - *Paralelní* (concurrent) — bloky se zahajují podle možností pracujících vláken v pořadí z této fronty.
- DispatchQueue.*main, .global*(qos)
- Uživatelské fronty:
  - let myQueue = DispatchQueue(label: qos:)

QoS — Quality of Service

- Je atribut fronty, určuje prioritu bloků ve frontě (pro rozhodování vlákna v RunLoop).
  - user-interactive — musí běžet v real-time, GUI.
  - user-initiated — blok pro interakci s uživatelem bez prodlení.
  - utility — delší činnost, na kterou uživatel čeká.
  - background — delší činnost, na jejíž výsledek se nespěchá.
- GlobalQ je tedy nejspíš multi-fronta.

Rozložení zátěže

```
// objekty pro zpracovani
var data = [nejaky obsah]

// posli pracovni bloky do global
// neni synchronizace na vlakno
for i in data {
    //
    DispatchQueue.global().async {
        // pracuj nad objektem
        work(i)
    }
}
```

Operation & OperationQueue

- Nad GCD je zbudován systém Operation a Queue.
  - Objektu Operation lze poslat zprávu (je to objekt).
  - Jeho "main" metodu spouští blok GCD, tj. vlákno X proteče jeho metodou "main".
- Operation jsou třídy / objekty. Mají uživatelské uložené properties (data, stav, …).
  - Mohou do sebe uložit výsledek práce.
  - *CloudKit*. Callbacks.

Řízení Operations, OQ

- Lze definovat precedenci: operace B se spustí až po dokončení operace A.
- OperationQueue.main — MQ.
  - Všechny ostatní jsou GT, sekvenční i concurrent.
  - maxConcurrentOperationCount: Int; OQ je KVO!
- OQ.waitUntilAllOperationsAreFinished()
  - Blokuje současné vlákno!
  - Implementace bariéry. 1) Detekovat okamžik, kdy se práce z fronty dokončila. 2) Blokovat se, dokud se nedokončí.

Bariéra, BlockOperation

```
// uzivatelska fronta. Je typu GlobalQueue.
// sekvencnost/paralelnost urcuje
// myQueue.maxConcurrentOperationCount
let myQueue = OperationQueue();
// operace, kterou chci spustit jako posledni
let finishOp = BlockOperation {
    // prevedu do MT
    DispatchQueue.main.async {
        //
        print("Hotovo")
    }
}
//
for i in 0..<10 {
    // prace v jedne iteraci
    let op = BlockOperation {
        //
        print("Ahoj")
    }
    // precedencd op <- finishOp
    finishOp.addDependency(op)
    //
    myQueue.addOperation(op)
}
//
myQueue.addOperation(finishOp)
```

… shrnutí …

- Máme GCD bloky a operace.
  - Rozdíl: možnost referencovat kód a jeho data.
- Vkládají se do různých typů front.
- Vlákna z RunLoop je vykonávají.
- Paralelizace. Odlehčení MQ (flexibilnější GUI).
- Problém: interakce mezi běžícími kódy.
  - Povíme si zásady bezpečného programování.

V čem je problém?

- Paralelní běh kódu není problém.
- Problém nastává, když mají objekty (z jiných vláken) *komunikovat*.
  - *Sekvenční kód* — řádek kódu 1, 2, 3, 4, …
  - *Jedno-vláknový kód* — sada bloků, které se 1vláknově vykonají v nějakém pořadí (aspoň precedence).
  - *Multi-vláknový kód* — sada bloků, které se v čase překrývají.
- Správná synchronizace a současně výlučnost.

Aplikace v single-thread

- Všechny bloky se odehrávají v MT — OK.
  - Překvapit může uživatel. Pořadí akcí vzniká dynamicky.
  - Akce—Reakce. Skoro se to nedá pokazit.
- Asynchronní volání do knihovny.
  - Stav aplikace — před volání, po volání, po obdržení odpovědi.
  - Předpokládáme, že callback z knihovny je v MT.

Aplikace v multi-thread

- Minimalizovat interakce kódu mezi MT a GT.
- Obecné schéma:
  - Vytvořit blok/operaci do GT.
  - Předat kopii všech parametrů (zadání mise).
  - GT akce běží a dokončí. Žádné interakce mimo svůj kontext.
  - **V režimu MT odešle výsledek** — delegate, Notification.
  - Je to zcela bez nebezpečných interakcí?
- Zdravá "nedůvěra" mezi objekty. Rozhraní.

Demo, GTWorker

```
//
protocol GTWorkDelegate : AnyObject {
    //
    func workDone(from: GTWork)
    func workDone(from: GTWork, andResult: String)
}
// objekt bude zit v kontextu GT
class GTWork : Operation {
    //
    weak var delegate: GTWorkDelegate?
    // tady bude cekat vysledek prace operace
    var result: String = ""
    //
    override func main() {
        // delam nejakou praci
        // mam hotovo
        DispatchQueue.main.async {
            // delegat si bude brat vysledek v dobe
            // kdy uz tato operace bude ne-bezici
            self.delegate?.workDone(from: self)
        }
    }
}
```

Demo, GTUser

```
// prevazne zije v kontextu MT
class GTUser : GTWorkDelegate {
    // pripadny spusteny vypocet
    var _gtWorkRunning: GTWork?
    let _opQueue = OperationQueue()
    // MT
    func runGT() {
        // explicitne registruju zmenu stavu pred/po spusteni GTwork
        guard _gtWorkRunning == nil else { return }
        // vytvoreni a predani VSECH relevantnich vstupu
        _gtWorkRunning = GTWork()
        _gtWorkRunning!.delegate = self
        // spusteni
        _opQueue.addOperation(_gtWorkRunning!)
    }
    // zasada: dostavam tuto zpravu v MT
    func workDone(from: GTWork) {
        // je to zprava od objektu, kterou ocekavam?
        if let __gtrun = _gtWorkRunning, __gtrun == from {
            // beru vysledky
            let result = __gtrun.result
            // menim stav objektu
            _gtWorkRunning = nil
        }
    }
}
```

GTDemo, rozbor

- Pohled GTWorker:
  - ″Můj vlastník mě stvořil neaktivního a vložil do mě zadání. Vložením do OperationQueue nade mnou dočasně ztrácí kontrolu. Až dokončím, pošlu mu v MQ async zprávu. Vlastní mě, takže si ze mě vezme výsledky.″
  - Rozbor vlastnictví v průběhu života GTWorkeru.
- Pohled GTUser:
  - ″Někdo invokoval workDone. Předpokládám je neaktivní. Ověřím nejprve jeho totožnost.″

GTDemo, stručněji v GCD

```
//
class GTUser {
    // stav[12] jsou promenlive!!!
    var stav1 = 1
    var stav2 = 1234
    var _gtRunning = false

    // volano v MT
    func someWork() {
        //
        guard _gtRunning == false else { return }
        // vzorkuju stav zadani
        let _stav1 = stav1
        let _stav2 = stav2
        // menim vnitrni stav
        _gtRunning = true
        // planuju praci do GT
        DispatchQueue.global().async {
            // prace, vypocet nad _stav1, _stav2
            let result =_stav1 + _stav2
            //
            DispatchQueue.main.async {
                // beru si vysledek result
                self._gtRunning = false
            }
        }
    }
}
```

Zásada č. 1

- MT / MQ je nejpřirozenější forma řešení výlučnosti a synchronizace.
  - … protože je sekvenční, tj. MT ví, že se nemůže nic dalšího z MQ spustit.
  - blok kódu v režimu MT nemusí nic zamykat, pokud může věřit solidnosti kódu běžícím v GT.
- Zásada č. 1: veškerou interakci mezi objekty provádět v režimu MT / MQ.

Interakce mezi objekty

- Vědět, jak se vykonávají interakce mezi objekty:
  - Poslání zprávy přes referenci na objekt.
  - Poslání zprávy přes NotificationCenter.
  - Setter uložené property. Getter property.
  - **Akce mají skryté důsledky.**
- Proč? GT nesmí proniknout do kódu výlučného pro MT (UI, CoreData). Souběhy.
- Zásadu č. 1 lze porušit, pokud chápeme důsledky.

Zásada č. 2 — odlište v kódu

- Metody tříd:
  - Implicitně jsou pro běh v MT.
  - Metody pro GT jsou viditelně pojmenovány ”gtDoSomething”.
  - … něco jako @escaping, akorát nad metodami.
- gt* metody drží Zásadu č. 1, tj. ”hledí si svého kódu a svých interních dat”.
  - gt* metody volají pouze gt* metody.
  - Do okolního světa vstupují výhradně v MT režimu.

Najděte tam tu chybu

```
DispatchQueue.global().async {
    // aktivace kodu v GT rezimu
    let result1 = gtDoSomething()
    // synchronne vstupuji do MT rezimu
    // predat vysledek
    DispatchQueue.main.sync {
        //
        let response = communicateMT(result1)
    }
    // pokracuju dal
    let result2 = gtProcessResponse(result1, response)
    //
    DispatchQueue.main.async {
        //
        Conclusion(result2)
    }
}
```

...

```swift
DispatchQueue.global().async {
    // aktivace kodu v GT rezimu
    let result1 = gtDoSomething()
    // synchronne vstupuji do MT rezimu
    // predat vysledek
    DispatchQueue.main.async {
        //
        let response = communicateMT(result1)
        //
        DispatchQueue.global().async {
            // pokracuju dal
            let result2 = ProcessResponse(result1, response)
            //
            DispatchQueue.main.async {
                //
                Conclusion(result2)
            }
        }
    }
}
```

Notifikační centrum

- Singleton pro NCentrum.
- Registruji objekt A jako observer zprávy MSG.
- Objekt B ve vlákně X posílá sync přes NCentrum zprávu MSG.
  - NCentrum sync rozesílá (for-cyklus) MSG všem observerům.
  - … stále vykonává vlákno X.
  - Observer zpracovává přijetí MSG ve vlákně X.
  - Pokud X=GT, pak se do MT-kódu můžu dostat GT-vláknem.

Zásada č. 3: Notifikační centrum

- Notifikace je zpráva pro neznámý počet adresátů.
- Mám důvod ji posílat synchronně? Čekat na jejich obsluhu?
  - Typicke ne, pak posílat *.main.async { zprava(); }*
  - Odesílatel nezná podstatu obsluhu příjemce.
  - Příjemce nezná vlákno odesílatele (obecně…).
- Notifikace posílat MT async.

Komunikace objektů: properties

- Smí se objekt A hrabat v properties objektu B?
  - B.prop = "ahoj" — co se stane?
- Typicky je tam setter / getter. Spouští se nějaký kód.
  - setter, KVO — provolá se neznámá sada observerů. GT / MT?
  - setter, CoreData — B sync volá MOC, ten generuje Notification, na ni reaguje FRC, sync volá delegáta, tabulka.
  - getter, CoreData — B sync volá MOC, disková operace, Notifikace, …

KVO, @objc, @dynamic, CD obj

- Berme přístup na property vždy jako aktivaci nějakého kódu. Kaskádově dále.

```
@implementation TRIDAB
/* @synthesize numberb = _numberb; */

-(int) numberb {
     // willAccess, didAccess…
    return _numberb;
}

-(void) setNumberb:(int)v {
    [self willChangeValueForKey: @"numberb"];
    _numberb = v;
    [self didChangeValueForKey: @"numberb"];
}
@end
```

Zásada č. 4: properties

- Přístup na properties objektů pouze v MT.
  - Přirozená serializace činností. Bloky považujeme za atomické.
- GT nikdy nezapisuje properties mimo svůj kontext.
- Zámky. Zamykaná property: důsledně vždy každý přístup.
  - Stačí zamykat jenom getter/setter?
  - Instrukce procesoru Test&Set.

NSLock

```
//
class GTWorker {
    //
    func gtWork(on: GTUser) {
        //
        on.__lPropertyLock.lock()
        on.lProperty = 10
        on.__lPropertyLock.unlock()
    }
}
//
class GTUser {
    //
    var lProperty: Int = 0
    var __lPropertyLock = NSLock()
    //
    func someWork() {
        __lPropertyLock.lock()
        // vypocet 1 nad lProperty
        let op = lProperty
        // vypocet 2 nad lProperty
        let op2 = lProperty
        //
        __lPropertyLock.unlock()
    }
}
```

NSThread / Thread

- Zjistit, jakým vláknem je prováděn kód.
- Ovládat vlákno — sleep, lock, condition.
- Vytvořit vlákno.
  - odvodit z třídy Thread, pak metoda ”main”
  - předat referenci a selektor
- Uplatnění přímo Thread v aplikacích?

Třídní metody Thread

- Vrací hodnoty v kontextu provádějícího vlákna.
- Thread.sleep(:) — toto vlákno si dá N sekund pauzu (OS ho odloží).
- Thread.current — toto vlákno vrátí svůj ”self”,
- Thread.isMainThread — vykonávající vlákno odpoví, zda-li je tzv. hlavním vláknem.
- Thread.exit() — *toto vlákno* se ukončí.
  - Rozešle zprávu (Notif. center). Zřejmě neprovede korektní dealokaci/uzavření zdrojů.

Suspendování Thread — kvazi

```
class MThread: Thread {
    //
    weak var delegate: MThreadDelegate?

    //
    var myLock = NSLock()

    //
    func pauseMe() { myLock.lock() }
    func unpauseMe() { myLock.unlock() }

    //
    override func main() {
        //
        while true {
            //
            myLock.lock(); myLock.unlock()
            //
            print("jdu na nejakou praci")
        }
    }
}
```

NSCondition, ThreadPool

- NSCondition — bariéra, kde vlákna čekají na signál (pro jednoho, pro všechny)
  - wait — čekání, vlákno je odstaveno
  - signal — probuzení vláken.

Suspendování thread — cond

```
class MThread: Thread {
    //
    var myCond = NSCondition()

    // uvolni cekajici vlakno
    func unpauseMe() {
        myCond.signal()
    }

    //
    func main() {
        //
        while true {
            // cekam na pokyn
            myCond.wait()

            // prace
        }
    }
}
```

```
class MThreadPool {
    //
    typealias Hokna = ()->()
    var hokna : [Hokna] = []
    var myCond = NSCondition()
    var myLock = NSLock()
    //
    func addHokna(_ h: @escaping Hokna) {
        // zamykam data "hokna"
        myLock.lock()
        hokna.append(h)
        // uvolnuju zamek na "hokna" a spoustim vlakno
        myLock.unlock()
        myCond.signal()
    }
```

```
class MThreadPool {
    //
    func getHokna() -> Hokna? {
        //
        print("Do fronty na praci")
        // cekame tu vsichni na signal
        myCond.wait()
        // byl jsem probuzen
        print("Probuzen jeden?")
        // zichr pro "hokna"
        myLock.lock()
        // nejaka chyba, proc me budi?!
        if hokna.isEmpty == true {
            // !!! unlock()
            return nil
        }
        //
        let _f = hokna.removeFirst()
        //
        myLock.unlock()
        //
        return _f
    }
```

```swift
class MThread: Thread {
    //
    var tp : MThreadPool!

    //
    override func main() {
        //
        while true {
            //
            if let _hokna = tp.getHokna() {
                //
                print("jdu na nejakou praci")

                //
                _hokna()
            }
        }
    }
}
```

```
class VC: UIViewController {
    //
    @IBOutlet var lab : UILabel!
    //
    var thList : [MThread] = []
    var thPool = MThreadPool()
    //
    @IBAction func butt() {
        //
        thPool.addHokna {
            //
            print("Zazpivame si...")
        }
    }
    //
    override func viewDidLoad() {
        //
        super.viewDidLoad();
        //
        for _ in 0..<10 {
            //
            let _thr = MThread()
            //
            _thr.tp = thPool
            thList.append(_thr)
            _thr.start()
        }
    }
```

Příště

- David Procházka, PEF MENDELU: User Experience.
- Jinak:
  - Kódování dat.
  - Key-Value Coding.
  - Documents. iCloud Doc.