ČVUT
ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE

PDV 08 2023/2024

Úvod do distribuovaných systémů

Michal Jakob
michal.jakob@fel.cvut.cz
Centrum umělé inteligence, katedra počítačů, FEL ČVUT

Paralelní výpočty

Distribuované výpočty

Plán

T	Přednáška
10.4.	Úvod do distribuovaných systémů (DS). Detekce selhání.
17.4.	Detekce selhání. Čas a uspořádání v DS.
24.4.	Globální stav a distribuovaný snapshot.
1.5.	--- Svátek ---
9.5.	Vyloučení procesů. Konsensus.
15.5.	Konsensus. Raft.
22.5.	Volba lídra. Shrnutí předmětu.

Studijní materiály

Slidy

Hlavní kniha: Maarten van Steen, Andrew S. Tanenbaum: **Distributed Systems (4.02 Edition),** 2023, k dispozici online: https://www.distributed-systems.net/index.php/books/ds4/

Sekundární kniha: George Coulouris, Jean Dollimore, Tim Kindberg, Gordon Blair: **Distributed Systems: Concepts and Design (5th Edition),** 2011

⚠️ Cvičení a semestrální práce jsou v **Javě** (nainstalovat a zprovoznit IntelliJ IDEA)

Úvod do Distribuovaných Systémů

Dva generálové

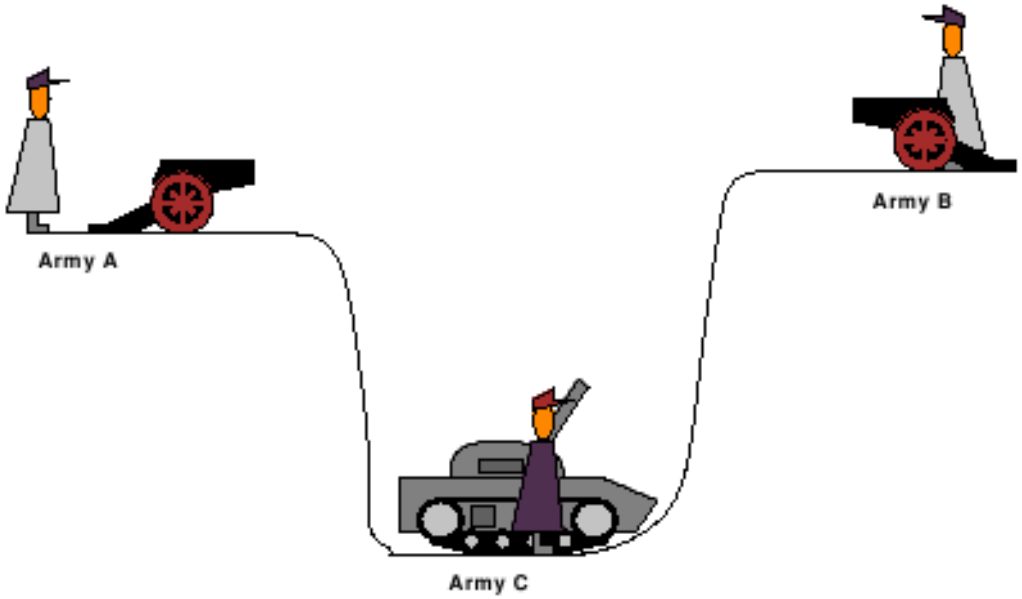

Pouze **synchronizovaný útok uspěje** → generálové se potřebují dopředu **shodnout na čase**, kdy oba zaútočí.

Komunikují skrze **posílání zpráv.** Poslané zprávy se mohou **ztratit**…

Jak **zaručit**, že zaútočí ve stejný čas?

Dva generálové

Možné řešení:

- Generál A: zaútočit za úsvitu!
- Generál B: potvrzuji, zaútočit za úsvitu!
- Generál A: potvrzuji, potvrzuji, zaútočit za úsvitu!
- Generál B:potvrzuji, potvrzuji, potvrzuji, zaútočit za úsvitu!
- …

Lze ukázat:

Řešení problému Dvou generálů za předpokladu nespolehlivého kanálu **neexistuje**!

Reality Check

Příklad: Výběr z bankomatu

- **vyberete** si z bankomatu v Praze 1000 Kč
- ze zůstatku vašeho účtu se v datovém centru **odečte** 1000 Kč

Problém **atomického commitu**: atomický commit je sada více operací, které jsou provedeny jako jedná operace.

- zúčastněné systémy musí zkoordinovat zda a kdy tyto operace budou provedeny

Pragmatické řešení problému Dvou Generálů

Musíme akceptovat nespolehlivost komunikačního kanálu a nesnažit se ji nejistotu eliminovat, ale snížit na přijatelnou mez

Předpokládejme, že pravděpodobnost chycení kurýra je p a že opakované zachycení kurýra jsou nezávislé jevy.

Možné řešení:

- Generál A pošle n **kurýrů** a **každopádně** zaútočí za úsvitu
- Generál B zaútočí za úsvitu pokud k němu dorazí **aspoň jeden** kurýr

Pravděpodobnost **nekoordinovaného útoku** je p^n.

- snížit pravděpodobnost nekoordinovaného útoku můžeme posláním více kurýru …

Jistoty koordinovaného útoku ale **dosáhnout nemůžeme** (pokud $p > 0$).

Pragmatické řešení

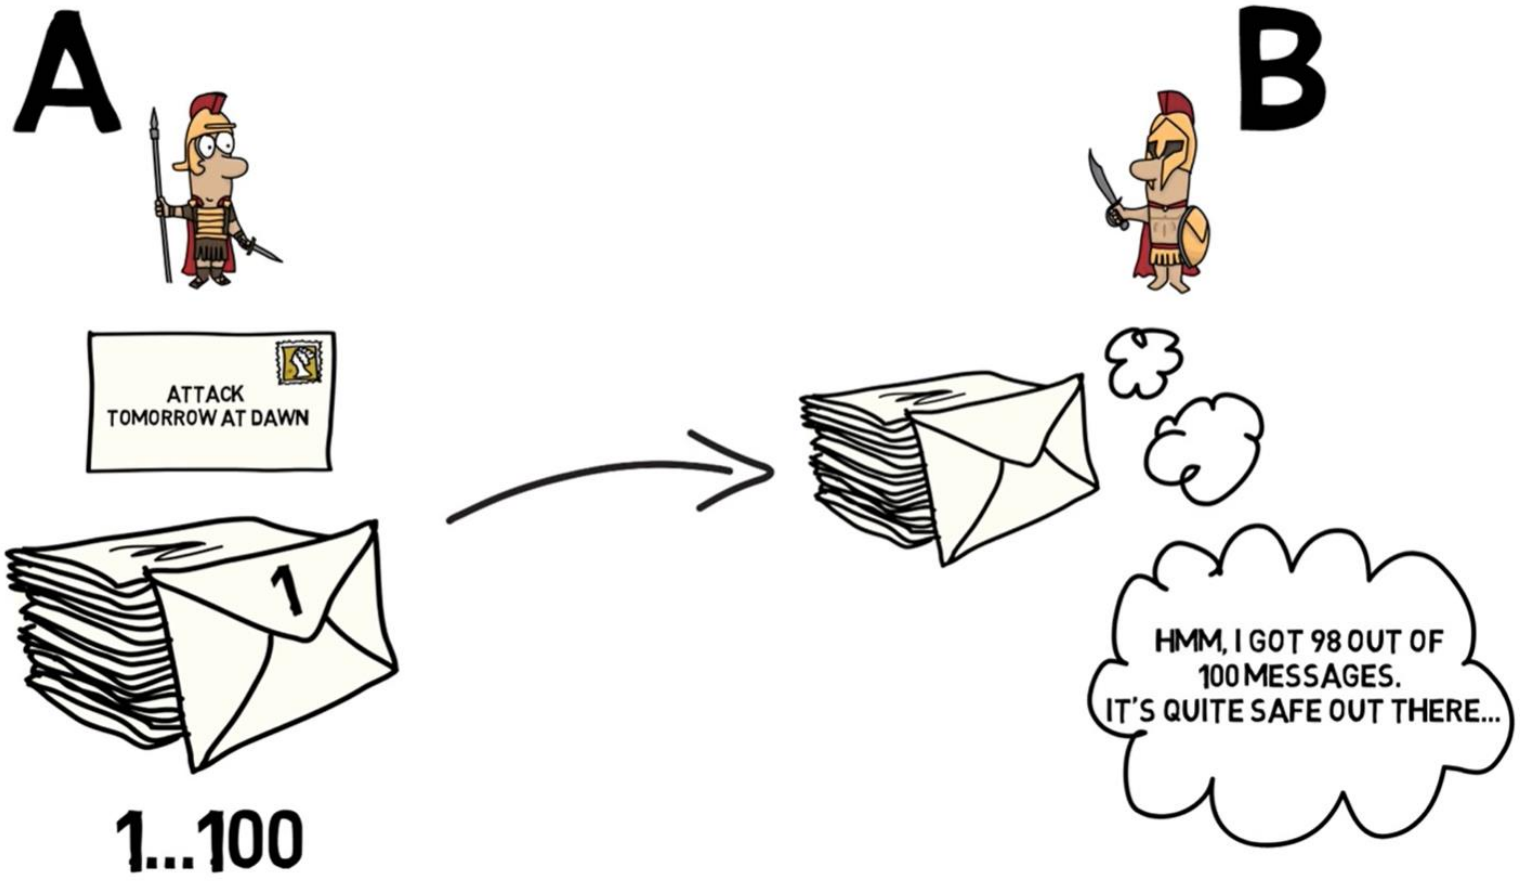

Drahé

Alternativní přístup

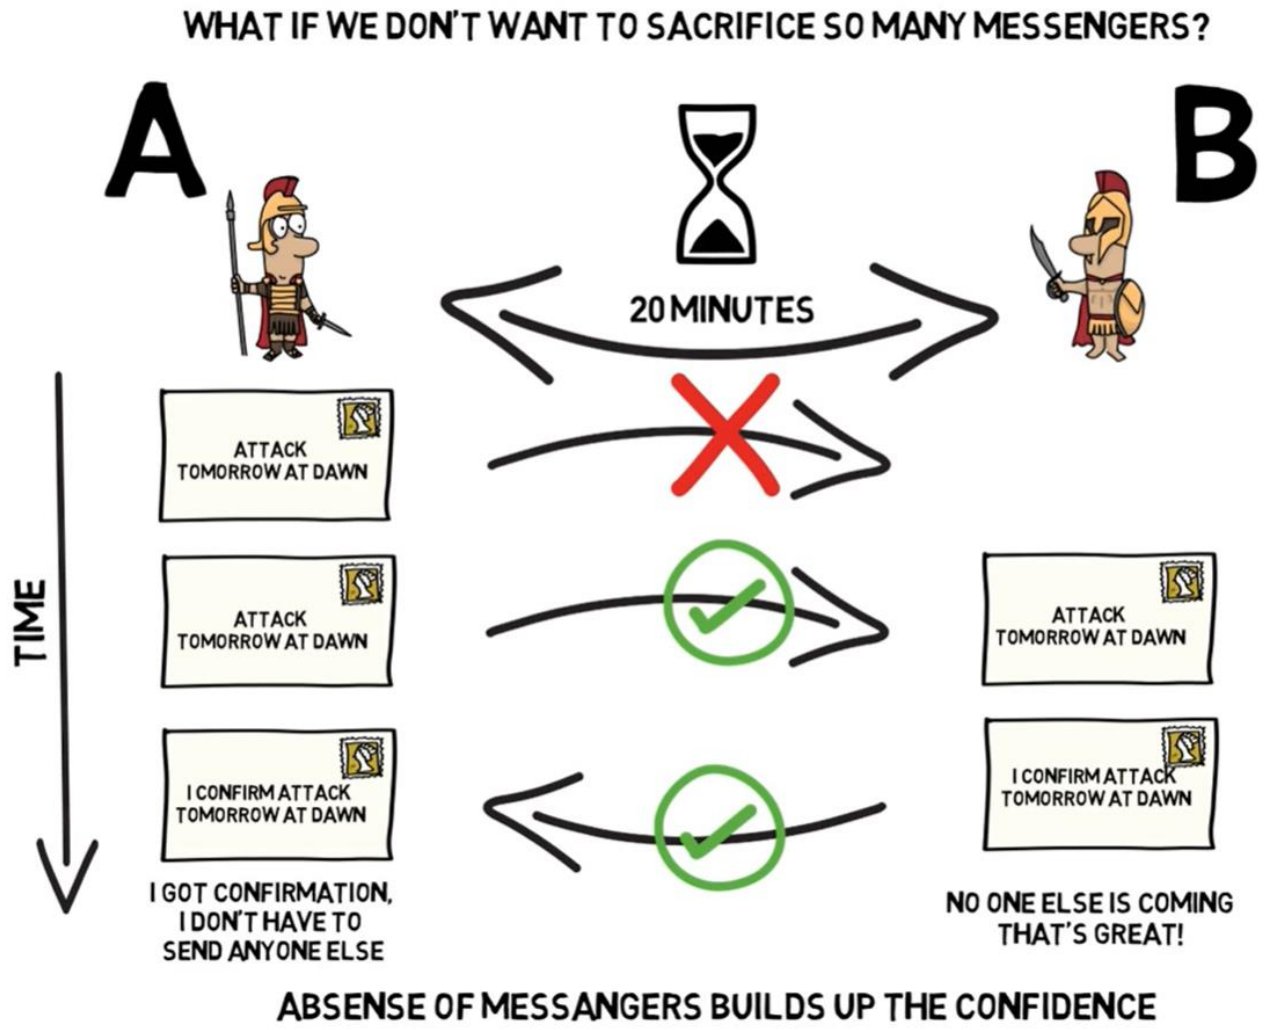

Dva přístupy

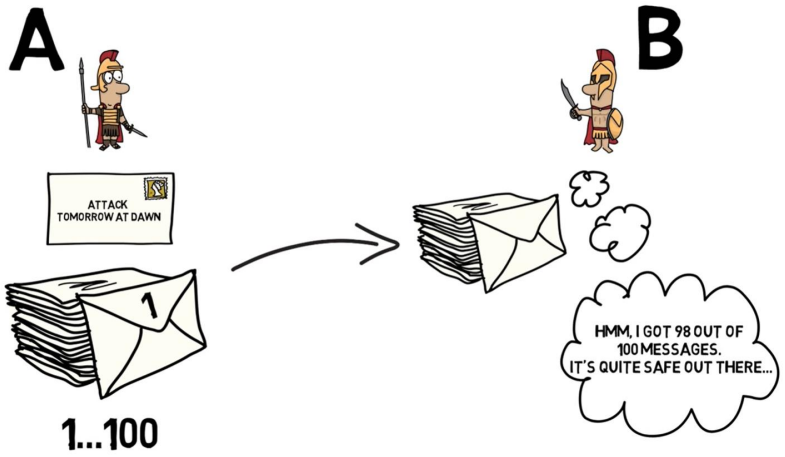

drahé

×

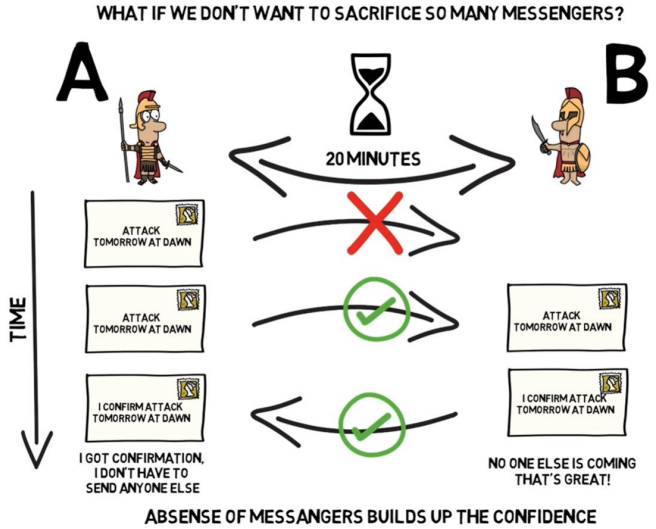

pomalé

Obecně

Řešitelnost problémů v distribuovaných systémech

- Řada zdánlivě jednoduchých problému nemá v distribuovaných systémech 100% řešení…
- …ale mají pragmatická řešení, často ale s různými trade-offs
- Některé problémy 100% řešení mají…
- … ale jen za určitých předpokladů.

Pochopit, které problém jsou které, a jak se dají řešit je cílem tohoto předmětu.

Co to je distribuovaný systém?

Distribuované systémy jsou všude

Od té doby, co existují počítačové sítě (natož Internet!) už prakticky **neexistují systémy**, které by **nebyly** aspoň částečně **distribuované**.

Co to je DS?

Definice (optimistická)

Soubor (*collection*) **autonomních výpočetních jednotek**, které se uživateli jeví jako **jeden koherentní systém.** [Andrew Tanenbaum]

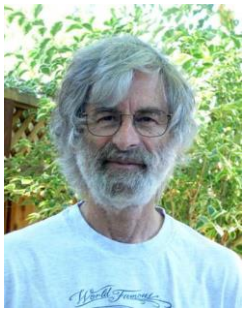

Definice (pesimistická)

Systém, ve kterém selhání počítače, o které jste vůbec nevěděli tušení, že existuje, učiní váš vlastní počítač nepoužitelný. [Leslie Lamport]

Definice (pragmatická)

Soubor (*collection*) nezávislých, **autonomních výpočetních jednotk** propojených **komunikační sítí.** Výpočetní elementy komunikují formou **posílání zpráv** za účelem určité formy **spolupráce**.

Příklady distribuovaných systémů

Mezibankovní platby	MMOG	Uber/Lyft/ Liftago
Sensorové sítě	P2P sítě	Blockchain
Řízení výrobní linky	Datové centrum	Internet

Je počítač distribuovaný systém
(z pohledu programátora aplikací)?

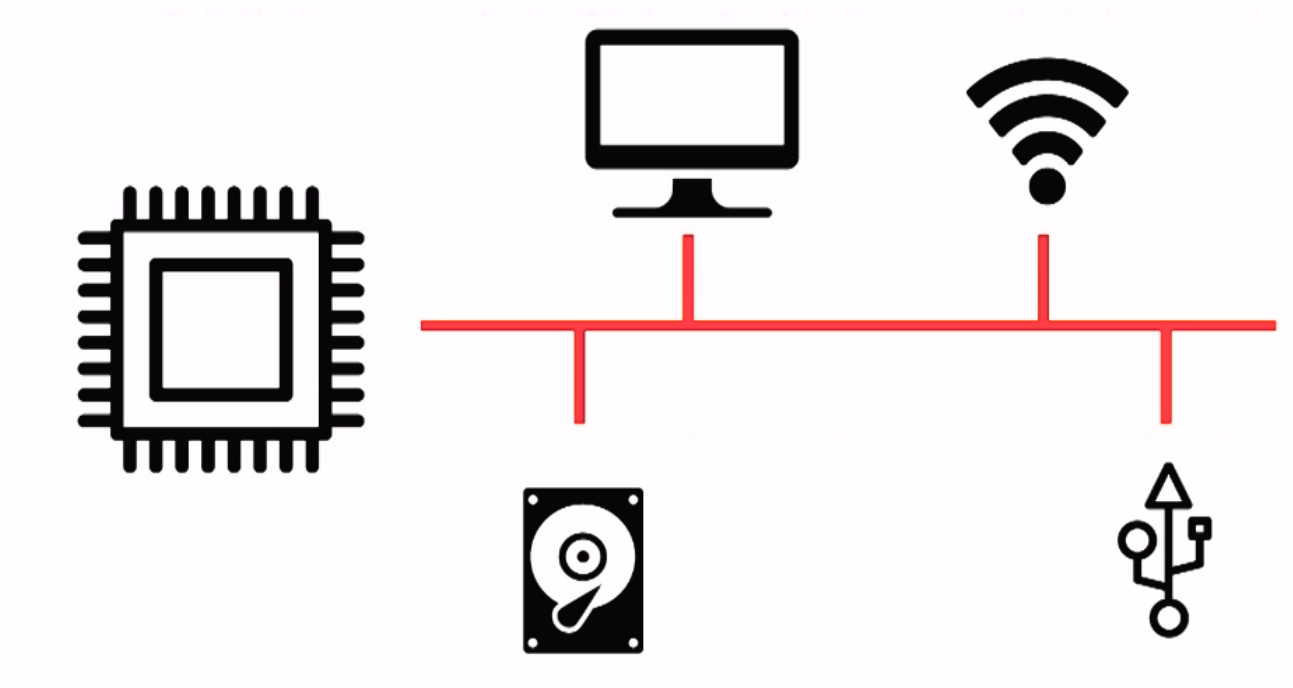

Není* → Proč?

(*záleží na úrovni, na které se počítačem pracujeme)

Charakteristiky DS

V **distribuovaném systému**:

1. Výpočetní jednotky nemají **sdílenou paměť**
2. Výpočetní jednotky **nesdílejí** globální **hodiny**
3. Výpočetní jednotky **selhávají nezávisle**

Naopak:

Paralelní systémy sdílejí

1. **Paměť**: předávání stavu používá sdílenou paměť a synchronizační mechanismy
2. **Hodiny**: přístup ke společným hodinám
3. **Osud**: selže buď nic nebo vše

Cíle při vývoji DS

Výkon/Škálovatelnost

Schopnost řešit více úloh nebo větší instance úloh, než je možné s jedním počítačem

Podobné jako u paralelních výpočtů, ale řeší i případy, když už jeden počítač nestačí.

Spolehlivost/Dostupnost

Schopnost zajistit (téměř) trvalou dostupnost požadovaných služeb

U paralelních výpočtů tento cíl typicky nemáme

zaměření distribuované části PDV

Další cíle: otevřenost, bezpečnost, …

Nezávislá (a částečná) selhání

Nezávislá selhání **komplikují život vývojářům**	×	Nezávislá selhání **usnadňují život uživatelům**
Algoritmy je třeba navrhnout tak, aby s možnosti selhání počítaly a byly **robustní vůči selhání**. n závislých procesů, pravděpodobnost selhání p → **dostupnost** $(\mathbf{1}-\boldsymbol{p})^{\boldsymbol{n}}$		**Replikace** pomocí více nezávislých počítačů **zvyšuje odolnost** vůči selhání n nezávislých procesů, pravděpodobnost selhání p → **dostupnost** $\mathbf{1}-\boldsymbol{p}^{\boldsymbol{n}}$

199x: Distribuované operační systémy

Operační systém vyvinutý speciálně pro potřeby DS

- "zlatý věk": Amoeba, Sprite, V, Chorus, Mosix ... T4
- **součástí jádra** OS podpora distribuovanosti, komunikace, synchronizace
- aplikace: **transparentní** využití distribuovaných služeb

Neexistuje rozdíl mezi lokální a distribuovanou aplikací

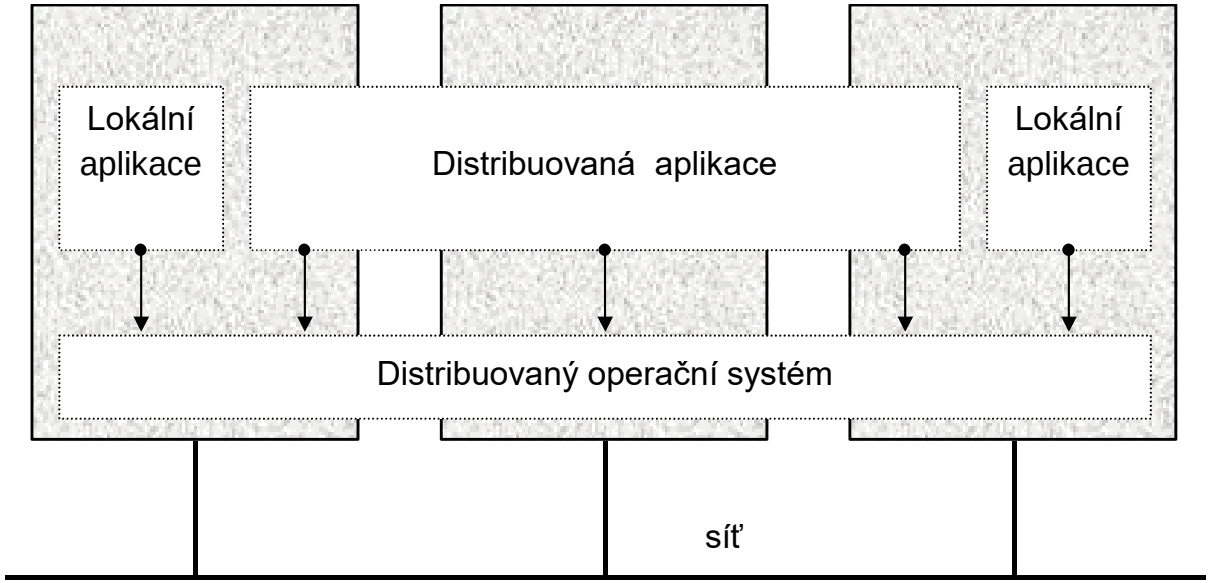

Nesplněná očekávání: žádný systém nedotažen do masově použitelného stavu

200x - Distribuované frameworky a aplikace

Lokální OS (Win/Ux) + rozšiřující vrstva pro distribuované aplikace

Prostředí pro distribuované aplikace → **middleware** (OSF DCE, CORBA, DCOM, Globe, ..)

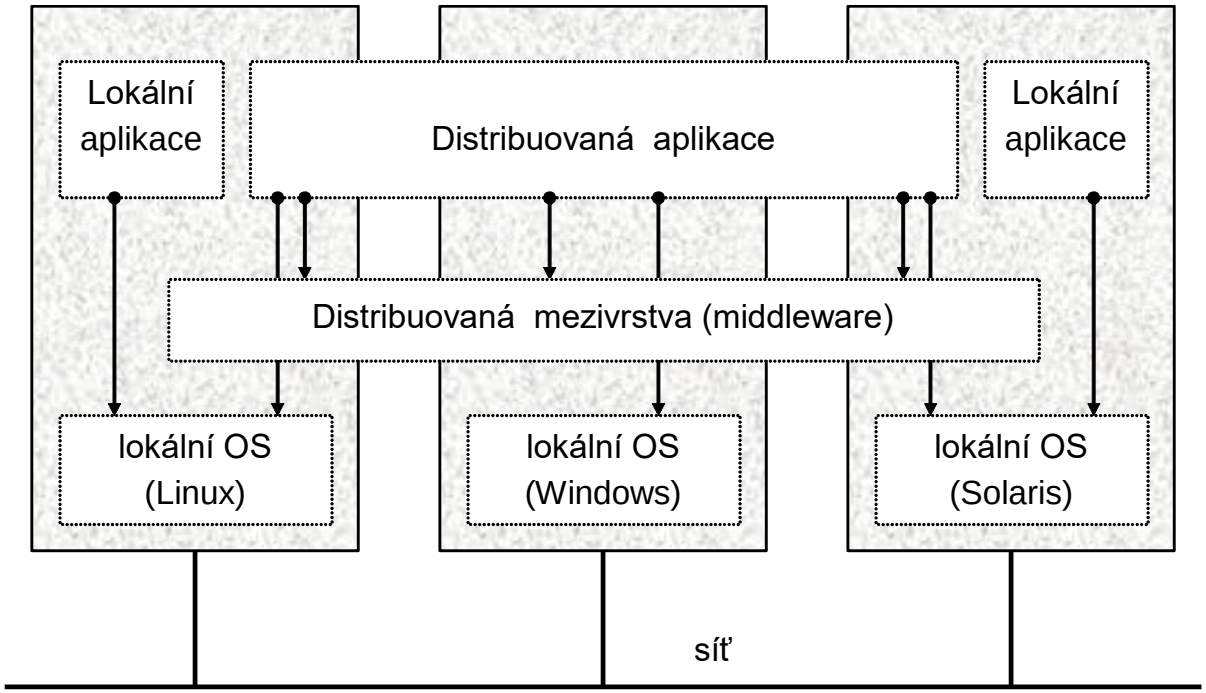

(Relativně) úspěšné využití pro cluster / grid computing

201x - Cloud computing, XaaS

Service-oriented computing: SaaS, PaaS, IaaS

- nutná podpora **virtualizace**
- kompletní infrastruktura připravená k použití:
  Windows Azure, Google App Engine, Amazon ECC, OpenStack, ...

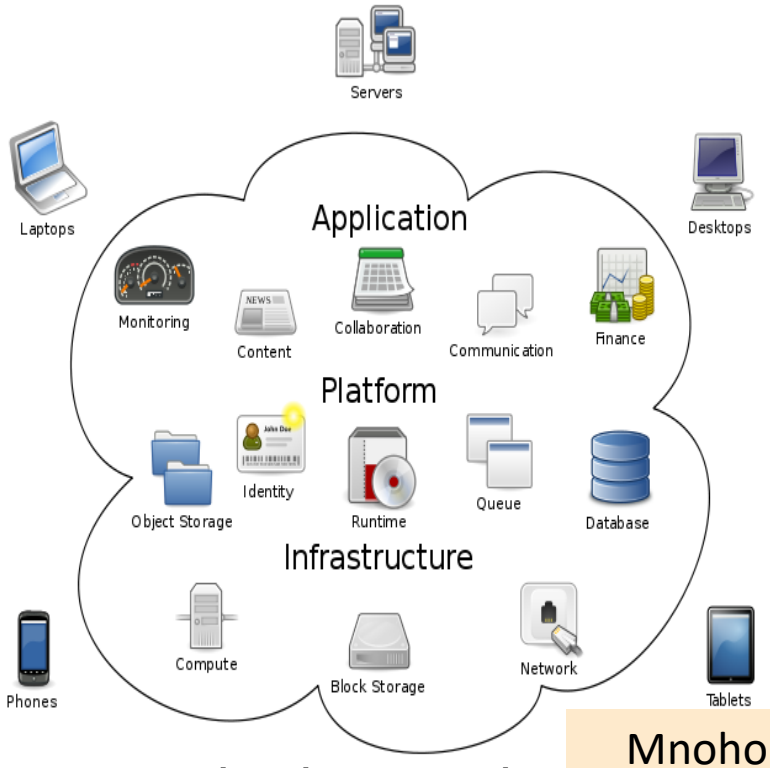

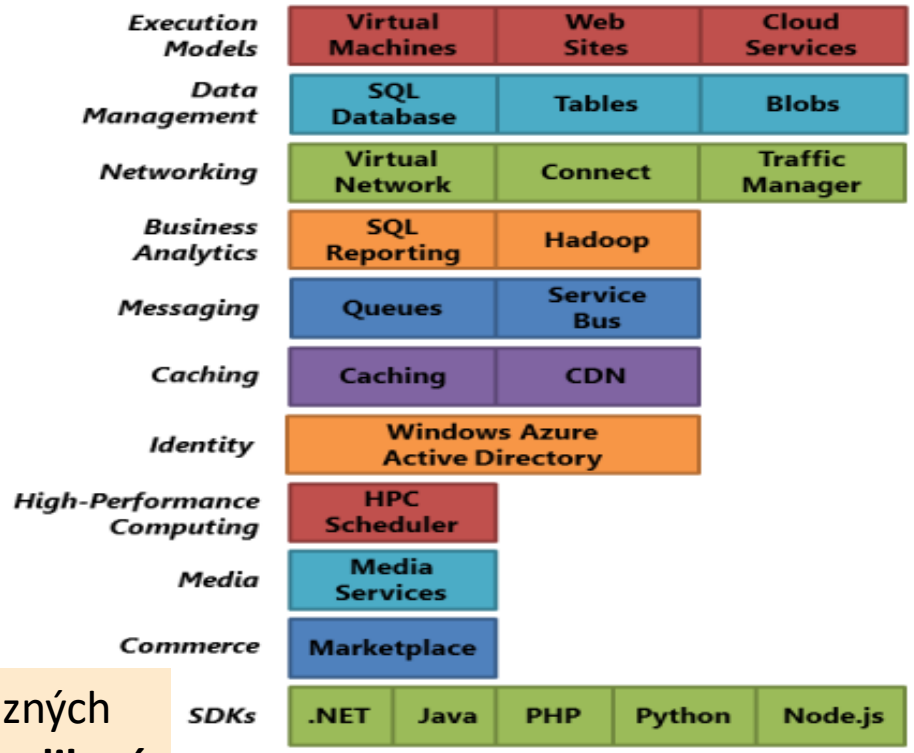

Mnoho různých
úspěšných aplikací

Hlavní typy DS

DS pro vysoko výkonnostní výpočty (high-performance computing)

Distribuované informační systémy

DS pro pervazivní výpočty/IoT

DS pro spolehlivé a rozsáhlé (high-performance) výpočty

DS jako nástroj pro zvýšení výkonů, spolehlivosti a ekonomické efektivity.

Model sdílené paměti se na multi-počítačové architektury **nepodařilo rozšířit** → Další škálování možné jen v paradigmatu distribuovaných výpočtů založených na posílání zpráv.

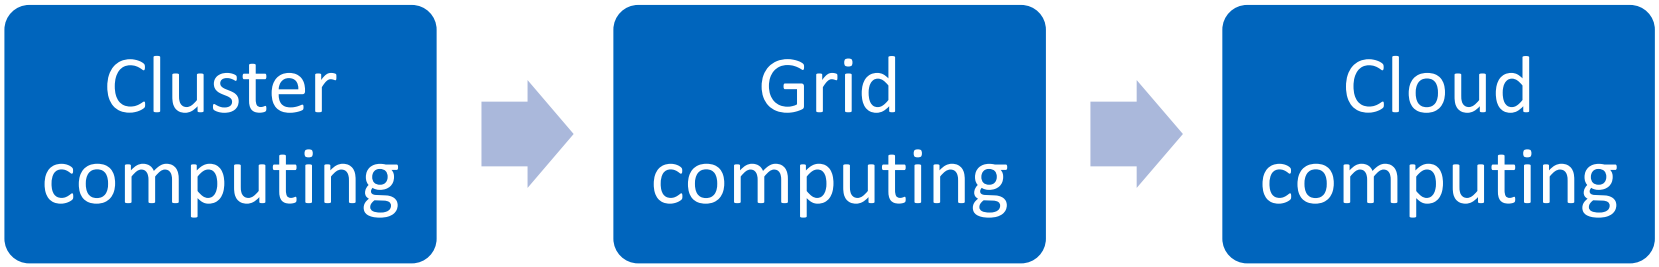

Distribuované informační systémy

Distribuce vynucena příslušností jednotlivých výpočetních uzlů do **různých organizací.**

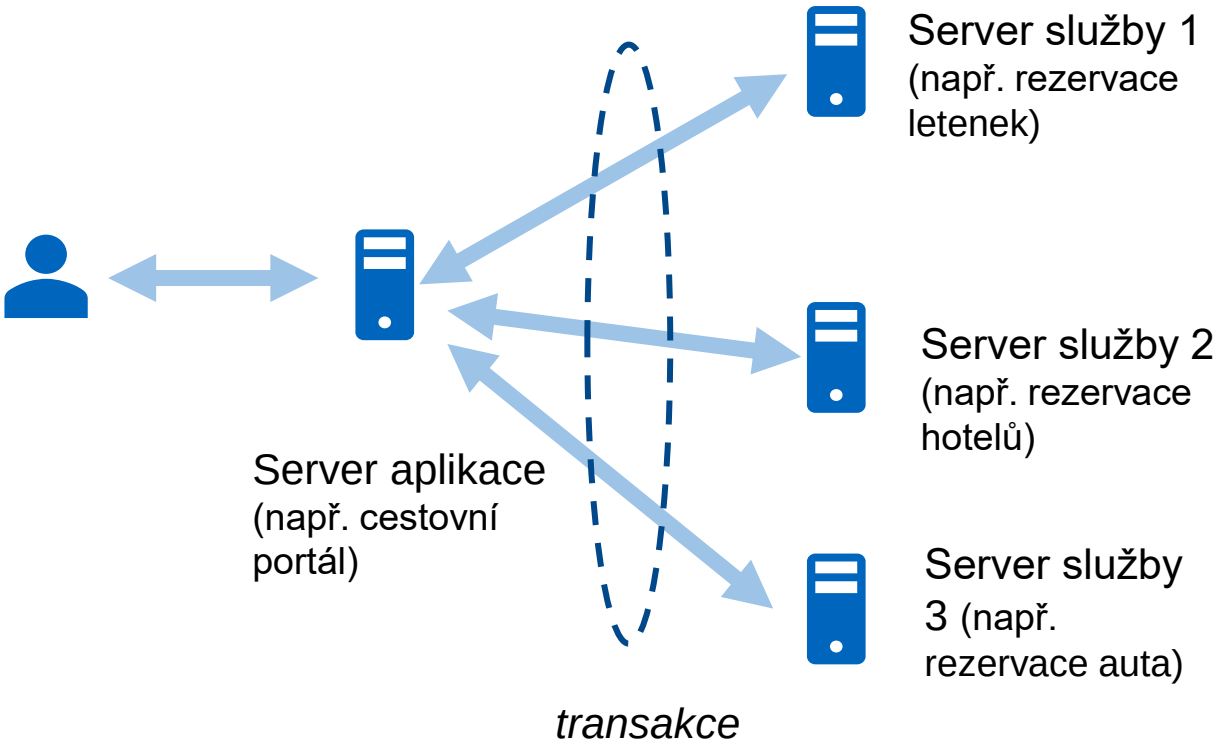

Hlavní výzva: **spolehlivost** a **konzistence.**

Pervazivní DS/IoT

Malé, mobilní výpočetní uzly, často **vtělené do fyzického prostředí**. Omezení na dosah a rychlost komunikace, a na spotřebu energie.

Distribuce vynucena nutností **fyzické blízkosti** uzlu k uživateli nebo prostředí.

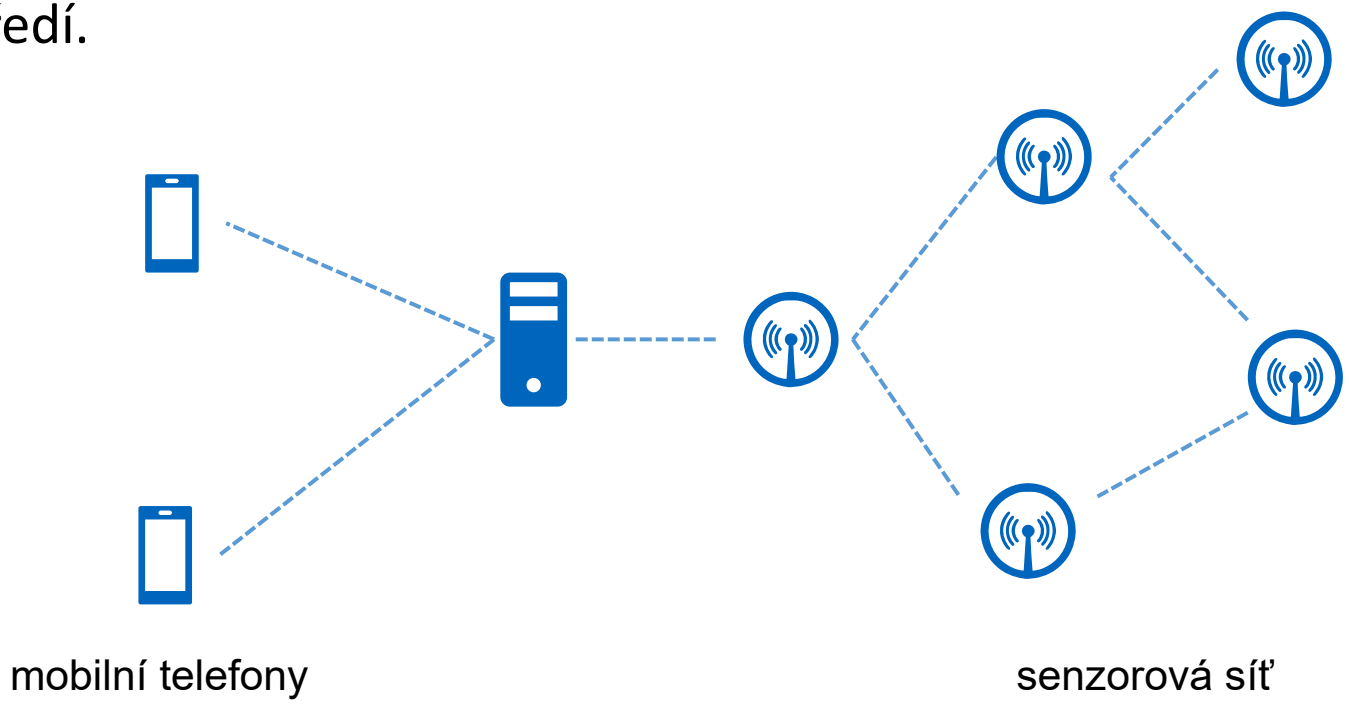

Hlavní výzva: **efektivita, dostupnost, ….**

Proč existují DS?

Distribuce jako **nástroj**

Distribuce může být cílenou **volbou** v **softwarovém návrhu** směřující k splnění specifických **požadavků**: odolnost vůči selhání, zvýšený výkon nebo poměr cena / výkon, nebo minimální QoS.

Např. replikované servery, cloud, …

×

Inherentní distribuce

Aplikace vyžadující sdílení zdrojů nebo šíření informace mezi geograficky nebo organizačně **vzdálenými** entitami jsou **„přirozené“** distribuované systémy.

Např. banka se několika pobočkami, senzorová síť, …

Modelování DS

Klíčové elementy DS

Výpočet

Interakce

Čas

Selhání

Výpočet

Proces: jednotka výpočtu v distribuovaném systému (někdy nazýván uzel, hostitel, element, …)

Množina (skupina) procesů: označována Π – je složena ze souboru N jednoznačně identifikovaných procesů $p_1, p_2, \dots, p_N$.

Klasické **předpoklady DS**:

- množina procesů je **konstantní** (N je dobře definováno)
- procesy se navzájem **znají**
- BÚNO: všechny procesy provádějí kopii stejného **algoritmu** (souhrn těchto kopií vytváří distribuovaný algoritmus)

V **reálných rozsáhlých** (někdy tzv. **extrémních)** distribuovaných systémech tyto předpoklady nemusí být splněny.

Interakce

Procesy komunikují **zasíláním zpráv**

- $send(m, p)$ pošle zprávu m procesu p
- $receive(m)$ přijme zprávu m

Zprávy mohou být v některých případech jednoznačně **identifikovány**

- odesílatelem zprávy
- sekvenčním číslem, které je lokální odesílateli

Klasickým předpoklad: každý pár procesů je propojen **obousměrným** komunikačním **kanálem** (point-point messaging)

- plně propojená topologie může být realizována pomocí směrování (routingu)

Čas

Přesné globální hodiny by umožnily globální uspořádání výpočetních kroků v DS. Bohužel **neexistují**.

Každý proces má své **lokální hodiny.**

Lokální hodiny **nemusí** ukazovat **přesný čas.**

Synchronizce lokálních hodin je možná **jen** s určitou **přesností.**

DS a Čas

V distribuovaných systémech je obtížné uvažovat o čase nejen kvůli absenci globálních hodin, ale také proto, že obecně nelze dát časové **limity** na **komunikaci** a **délku výpočtů**.

Různé možné modely:

- **Asychronní** DS
- **Synchronní** DS
- **Částečně synchronní** DS

Synchronní vs. Asynchronní

Asynchronní systém

- Žádné časové limity na **relativní rychlost** vykonávání procesů.
- Žádné časové limity na **trvání přenosu** zpráv.
- Žádné časové limity na **časový drift** lokálních hodin.

×

Synchronní systém

- **Synchronní výpočty:** známe horní limit na relativní rychlost vykonávání procesů.
- **Synchronní komunikace:** známé horní limit na dobu přenosu zpráv.
- **Synchronní hodiny**: procesy mají lokální hodiny a je znám horní limit na rychlosti driftu lokálních hodin vzhledem k globálním hodinám.

Částečně synchronní DS

Částečná sychronicita: pro většinu systému je relativně snadné definovat časové limity, které platí ***většinu* času**. Občas se ale mohou vyskytnout období, během kterých tyto časové limity neplatí.

- zpoždění procesů: např. swappování, garbage collection
- zpoždění komunikace: přetížení sítě, ztráta zpráv (vyžadující jejich opakovaný přenos)

Prakticky užitečné systémy **jsou částečně synchronní**

→ Umožňuje **v praxi vyřešit** problémy, které jsou za předpokladu plně asynchronních DS **neřešitelné**.

- některé z časových úseků synchronního běhu DS jsou dostatečně dlouhá na to, aby distribuovaný výpočet skončil

Selhání

Jak procesy, tak komunikační kanály mohou v DS selhat.

Selhání procesu

- **havárie (crash/fail-stop)**: proces přestane vykonávat algoritmus (a reagovat na zprávy)
- **libovolné (byzantské) selhání**: proces může pracovat dále (a reagovat na zprávy), ale vykonává chybný algoritmus (z důvodu softwarový chyby nebo úmyslu)

Selhání kanálu

- **ztráta zprávy (message drop)**: zpráva není doručena cílovému procesu (např. kvůli přetížení sítě nebo přetečení zásobníku v OS u přijímacího procesu)
- **rozdělení (partitioning):** procesy jsou rozdělené do disjunktních množin (oddílů - partitions) tak, že v rámci oddílu je komunikace možná, ale mezi oddíly nikoliv

V případě synchronních DS definujeme ještě **selhání časování**, pokud doba odezvy procesu nebo přenosu zprávy po síti vybočila z dohodnutého **časového rozmezí**.

Předpoklad na komunikační kanál

Dokonalý (perfect) kanál

- **Spolehlivé doručování**: Pokud proces p pošle zprávu procesu q ani p a ani q nehavaruje, pak q nakonec zprávu obdrží.
- Žádná **duplikace**: Žádná zpráva není doručena vícekrát než jednou.
- Žádné **vytváření**: Je-li zpráva m doručena procesu p, tak zpráva m byla dříve poslána nějakým procesem q procesu p.
- **Garantované pořadí doručování:** Odešle-li proces p procesu q zprávy m_1 a m_2, tak pokud byla m_1 odeslána dříve než m_2, tak m_2 nemůže být doručena aniž by předtím byla doručena m_1.

Spolehlivý kanál

FIFO kanál

Chybné předpoklady při vývoji DS

Řada DS je **zbytečně komplexních**. Komplexita je způsobena chybami, které je třeba později záplatovat. Chyby vycházejí z **mylných předpokladů**.

Typické mylné předpoklady

- Síť je spolehlivá
- Síť má nulovou/nízkou latenci
- Síť má konzistentní latenci
- Procesy odpovídají v časovém limitu
- Síť má neomezenou kapacitu
- …

Shrnutí

Distribuované systémy jsou všude kolem nás a jejich **význam a složitost** dále **roste**.

Základním rozdílem mezi paralelními a distribuovanými výpočty jsou: absence **sdílené paměti**, absence **globálních hodin** a nezávislá **selhání**.