PDV 09 2022/2023

Čas a kauzalita v DS

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

Distribuovaná kompilace

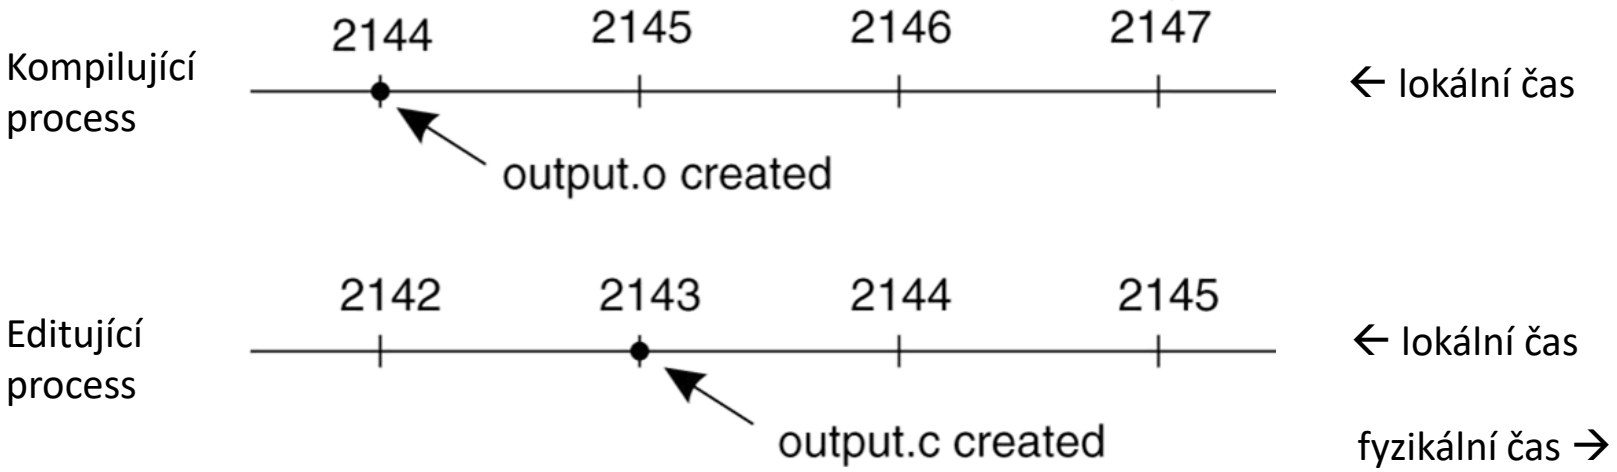

2143 < 2144 ➔ kompilace nebude spuštěna

Důsledek nesychronizovaného času – chybná verze binárního souboru

Synchronizace fyzických hodin

Mimoběžnost vs. Drift

Mimoběžnost hodin (clock skew)	**Drift** hodin (clock drift)
Rozdíl **v času** hodin dvou procesů. (jako vzdálenost dvou jedoucích automobilů) Mají-li dvoje hodiny nenulovou mimoběžnost, jsou **nesynchronizované**.	Rozdíl **v rychlosti** (frekvenci) hodin dvou procesů. (jako rozdíl v rychlosti jedoucích automobilů)

Mají-li dvoje hodiny **nenulový drift**, tak se jejich mimoběžnost v čase bude (nakonec) **zvyšovat**

- jsou-li popředu pomalejší hodiny, tak nejdříve dojde k vyrovnání času

Synchronizace

Uvažujeme skupinu procesů

Externí synchronizace	**Interní** synchronizace
▪ Čas C_i hodin každého procesu p_i je udržován v rozmezí δ od času S externích **referenčních hodin**, tj. v každém okamžiku $\lvert C_i - S \rvert \leq \delta$ ▪ Externí hodiny mohou být napojeny na UTC nebo na atomové hodiny ▪ Algoritmy: např. Cristianův, NTP	▪ Každý pár procesů (p_i, p_j) má hodnoty času svých hodin v rozmezí δ, v každém okamžiku tj. $\lvert C_i - C_j \rvert \leq \delta$ ▪ Algoritmy: např. Berkeley
Externí synchronizace s rozmezím δ **implikuje** interní synchronizaci s rozmezím $2 * \delta$.	Interní synchronizace **neimplikuje** externí synchronizaci.

Synchronizace fyzických hodin

Externí synchronizace: všechny procesy p_i se synchronizují s externím časovým serverem S.

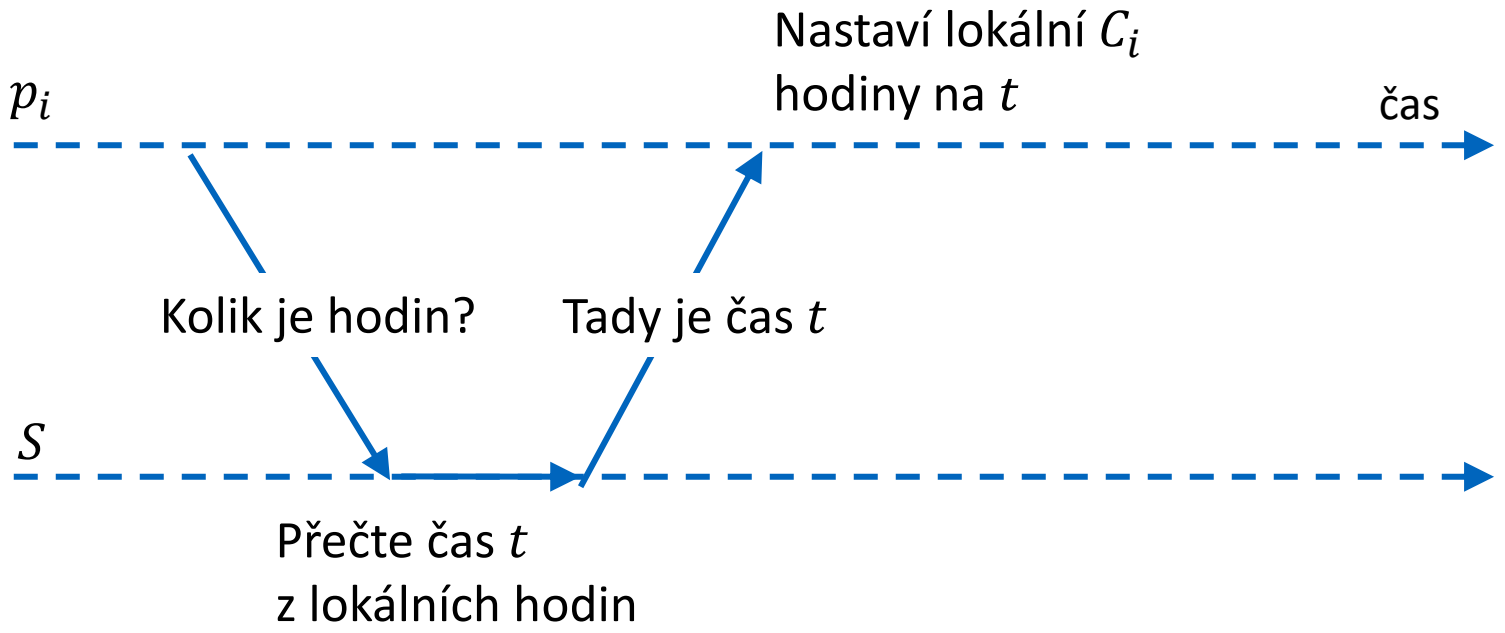

Co je špatně?

- V okamžiku, kdy p_i obdrží odpověď, se už **čas posunul**.
- Míra nepřesnosti C_i závisí na komunikační **latenci**.
- V asynchronním systému je latence **konečná**, ale **neomezená (**a **neznámá!)** ⇒ neomezená je i **nepřesnost** hodin.

Cristianův Algoritmus

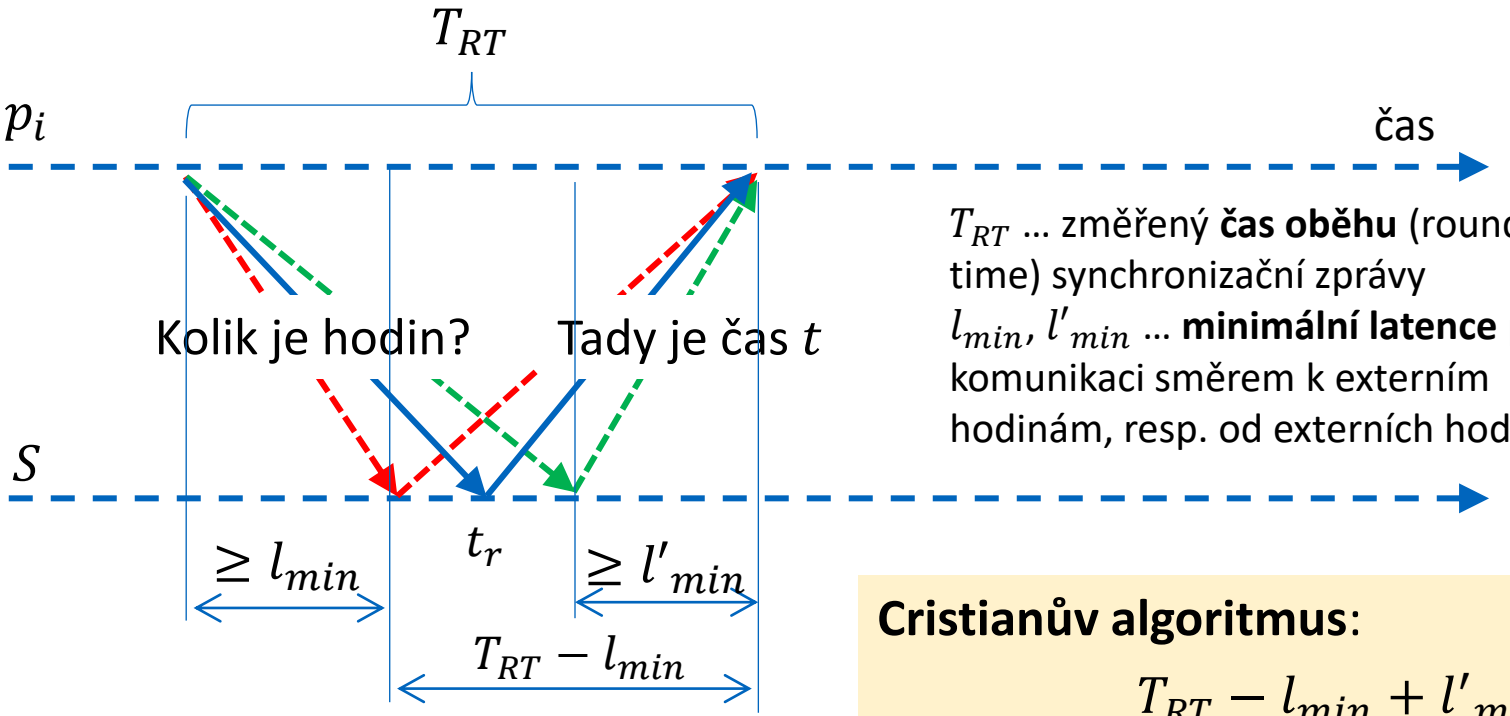

T_{RT} … změřený **čas oběhu** (round trip time) synchronizační zprávy

l_{min}, l'_{min} … **minimální latence** při komunikaci směrem k externím hodinám, resp. od externích hodin

Skutečný čas v okamžiku, kdy p_i přijme odpověď je

$[t_r + l'_{min}, t_r + T_{RT} - l_{min}]$

t_r … skutečný čas, kdy S odpověděl na dotaz

Cristianův algoritmus:

$$C_i := t + \frac{T_{RT} - l_{min} + l'_{min}}{2}$$

Chyba je **omezena**, tj. maximálně

$$(T_{RT} - l_{min} - l'_{min})/2$$

(t .. čas, který S hlásí v čase t_r)

Je-li chyba měření příliš vysoká, je možné poslat více zpráv a výsledek průměrovat.

Pozor

Lokální čas je možné posunout libovolně **dopředu**…

…ale **nikoliv dozadu**!

- posun dozadu by mohl narušit lokální uspořádání událostí v procesu

Je možné zvýšit nebo snížit **rychlost** hodin

Jak často synchronizovat?

Maximální rychlost driftu (maximum drift rate MDR) hodin

Absolutní $\boldsymbol{MDR}$ je definováno relativně vůči UTC (universal coordinated time). UTC je **správný (přesný)** čas v každém okamžiku.

Vzájemná maximální rychlost driftu mezi dvěma procesy se stejnou absolutní MDR je $2 * MDR$.

Je-li maximální **tolerovaná mimoběžnost** mezi jakýkoliv párem hodin je M, pak je třeba hodiny synchronizovat aspoň každých $\boldsymbol{M/(2 * MDR)}$ časových jednotek.

Network Time Protocol (NTP)

Využíván od roku 1985 pro synchronizaci času v počítačových sítích s proměnlivou latencí.

NTP servery jsou uspořádány do **stromu**

- uzly synchronizují se svými rodiči a někdy i dalšími servery na stejné úrovni
- klienti tvoří listy stromu

Dosažitelná přesnost:

- internet: **desítky ms**
- LAN: **1 ms**

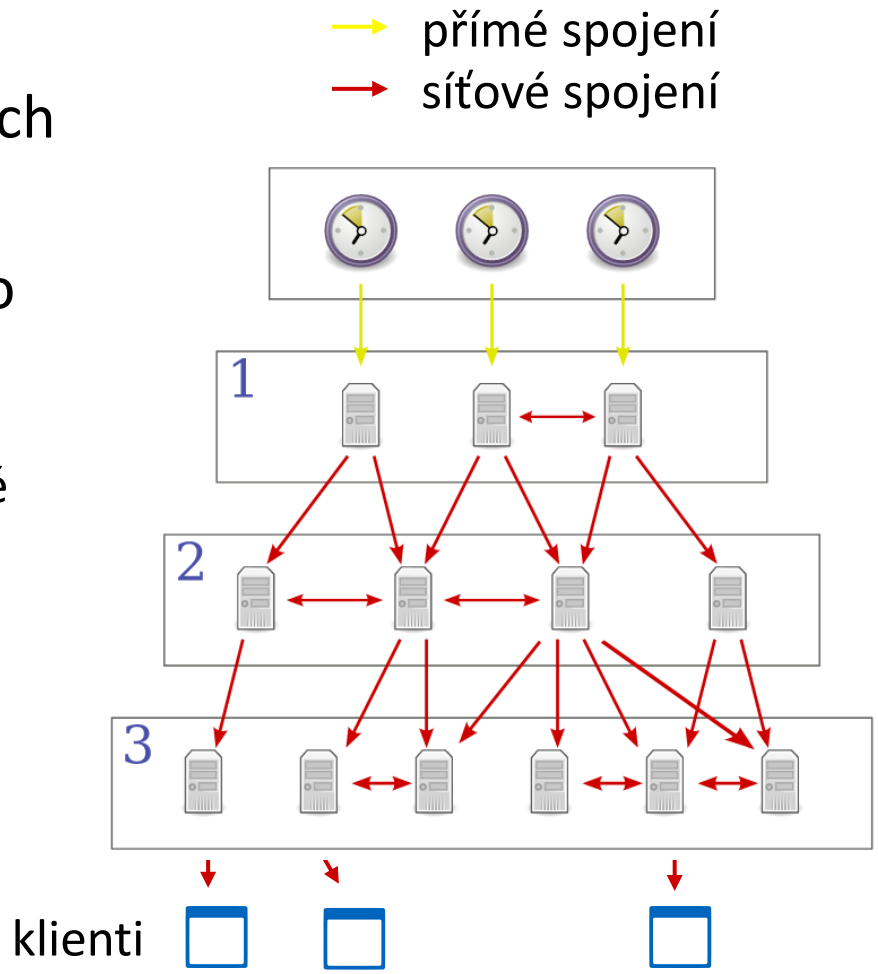

Základ protokolu

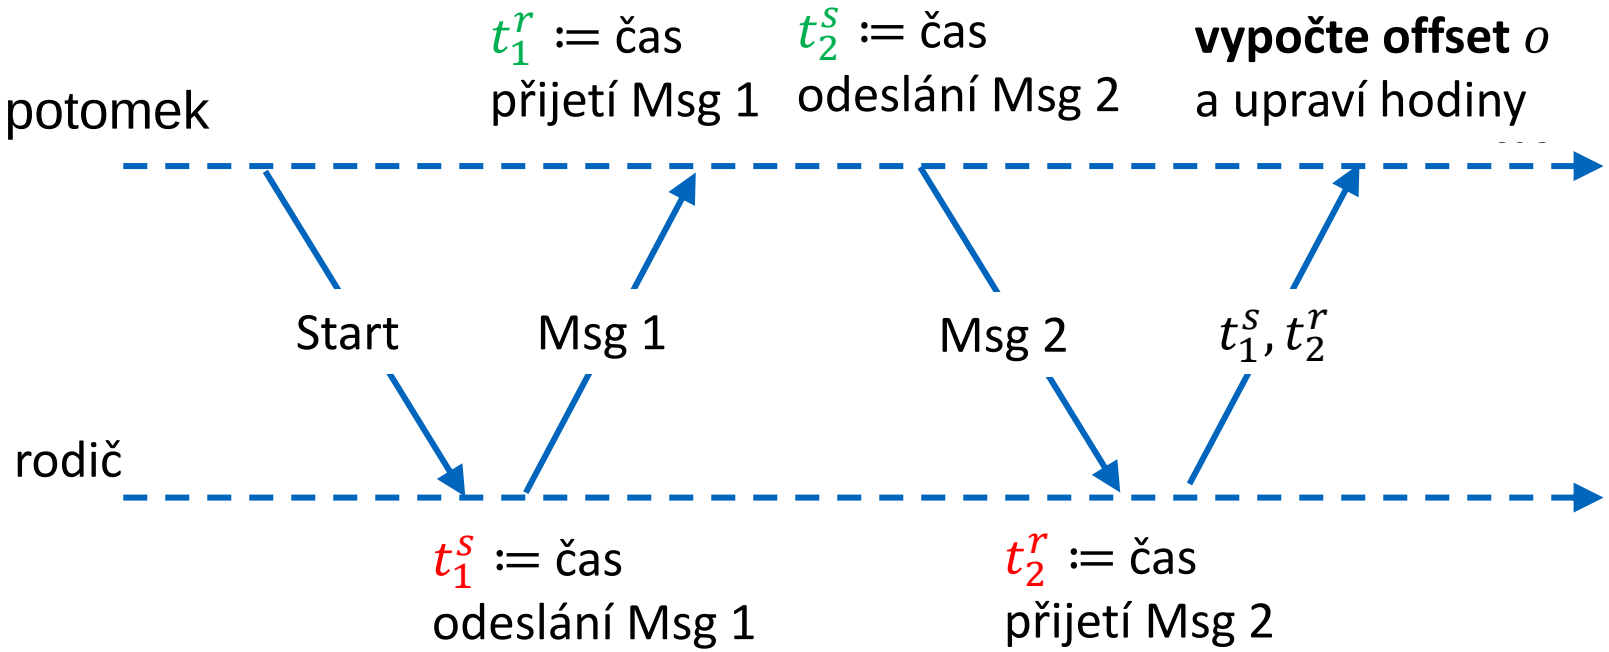

Potomek spočítá **offset** mezi svým časem a časem rodiče:

$$o = \frac{(t_1^r - t_2^r + t_2^s - t_1^s)}{2}$$

Odvození

Proč $o = \frac{(t_1^r - t_2^r + t_2^s - t_1^s)}{2}$?

Předpokládejme skutečný offset je o_{real}, tj. čas potomka je popředu o o_{real} a čas rodiče je pozadu o o_{real}.

Předpokládejme, že latence pro zprávu 1 je l_1 a pro zprávu 2 je l_2.

- hodnoty l_1 a l_2 **nejsou známé**

Pak platí

- $t_1^r = t_1^s + l_1 + o_{real}$
- $t_2^r = t_2^s + l_2 - o_{real}$

$$o_{real} = \frac{(t_1^r - t_2^r + t_2^s - t_1^s)}{2} + \frac{l_2 - l_1}{2}$$

$$o_{real} = o + \frac{(l_2 - l_1)}{2}$$

l_1 a l_2 jsou **nezáporné**

$$|o - o_{real}| \leq \frac{l_2 + l_1}{2}$$

tj. chyba je omezená **časem oběhu zprávy**

Nicméně

Stále **nenulová** chyba synchronizace.

Dokud bude **latence nenulová a neznámá**, chyby se nezbavíme!

Pomocí fyzických hodin lze uspořádávat jen události v **„pomalých“** distribuovaných výpočtech

- tj. když intervaly mezi kroky výpočtu trvají výrazně déle než je mimoběžnost hodin
- pro standardně rychlé výpočty bychom potřebovali synchronizaci hodin řádově v nanosekundách

V praxi jsou ale výpočty řádově rychlejší ➔ lze problém uspořádání události vyřešit **bez potřeby synchronizovat** fyzické hodiny?

Logické hodiny

Uspořádání událostí v DS

Synchronizace fyzických hodin je jeden z přístupů k uspořádání událostí v DS. Vzhledem k omezené přesnosti synchronizace lze ale použít jen uspořádání událostí, mezi kterými uplyne **dostatečné množství času**.

Alternativní přístup: Co kdybychom místo absolutního/fyzického času přiřazovali událostem **logické časové značky**?

- Pokud by přiřazení logických značek respektovalo **kauzální vztah** mezi událostmi, tak by fungovalo.

Kauzální vztah mezi událostmi: první událost může ovlivnit druhou.

Model

Uvažujeme **asynchronní** DS sestávající z **procesů**.

Každý proces má **stav** (hodnoty **proměnných**).

Každý proces vykonává **akce**, aby změnil svůj stav. Akce může být **instrukce** nebo **poslání zprávy** (**send**, **receive**).

Událost je výskyt akce. Poslání zprávy generuje dvě události: **odeslání** a **přijetí**.

Každý proces má **lokální hodiny.**

Události v rámci procesu mohou mít přiřazeny **časové značky** (timestamps), a mohou tak být linerárně **seřazeny**.

- Ale my potřebujeme řadit globálně v celém DS.

Relace „stalo se před“

Potenciální kauzalitu zachycujeme pomocí relace „stalo se před“

Definice (Relace $\rightarrow$ *stalo se před*)

- Jsou-li A a B události ve stejném procesu p a pokud A předchází B, pak $A \rightarrow B$.
- Je-li A odeslání zprávy a B je přijetí této zprávy, pak $A \rightarrow B$.
- Pokud $A \rightarrow B$ a $B \rightarrow C$, pak $A \rightarrow C$

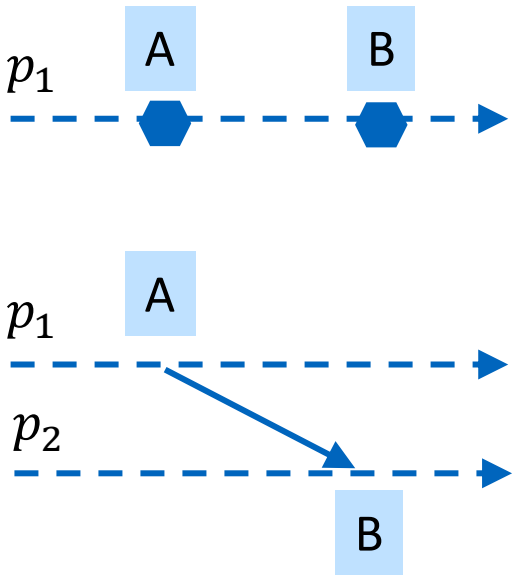

Kauzální závislost/nezávisost

Relace *stalo se před* zavádí **částečné uspořádání událostí** → potenciální **kauzální závislost**

$e_1 \rightarrow e_2$: potenciálně **kauzálně závislé** události
(*může* být kauzální vztah, tj. e_1 *mohla* ovlivnit e_2 – ale *nemusela*)

$e_1 \parallel e_2$: **současné** události
(kauzální vztah *určitě* není, tj. e_1 *nemohla* ovlivnit e_2 a e_2 *nemohla* ovlivnit e_1)

Příklad: Stalo se před →

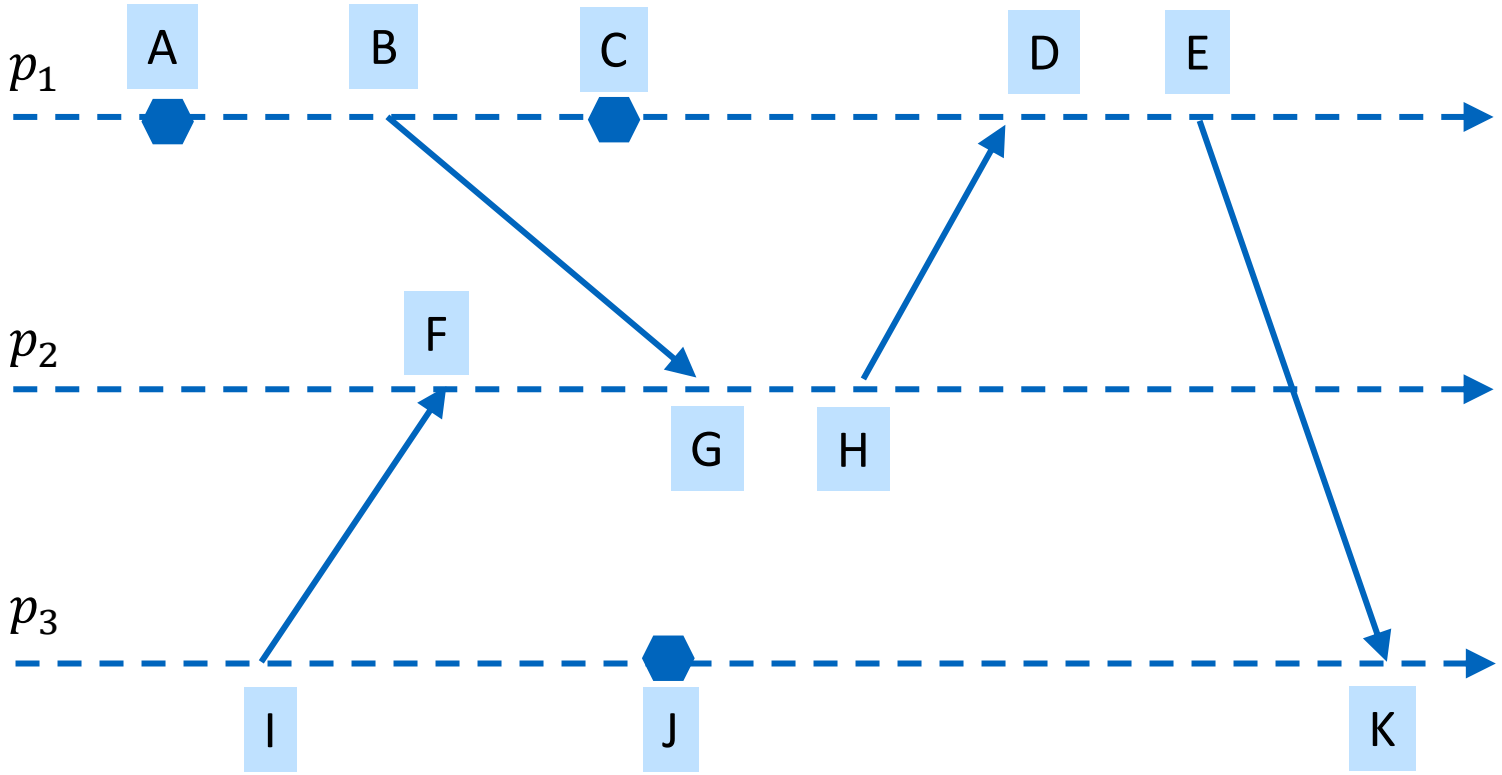

instrukce

zpráva

A → B
B → G
A → G

I → F
F → K
A → K
C → K

C ‖ G
A ‖ J
C ‖ H

Lamportovy logické hodiny

Jak přiřadit události e časovou značku $C(e)$ tak, aby **respektovaly kauzalitu**, tj. jestliže $e_1 \rightarrow e_2$, pak $C(e_1) < C(e_2)$?

→ **Lamportovy logické hodiny:** Každý proces má své logické hodiny, které se **synchronizují podle přijímaní zpráv**.

- navržené Leslie Lamportem v 70. letech
- používané prakticky ve všech distribuovaných systémech (a všech cloudových platformách)

Příklad: Lamportovy hodiny

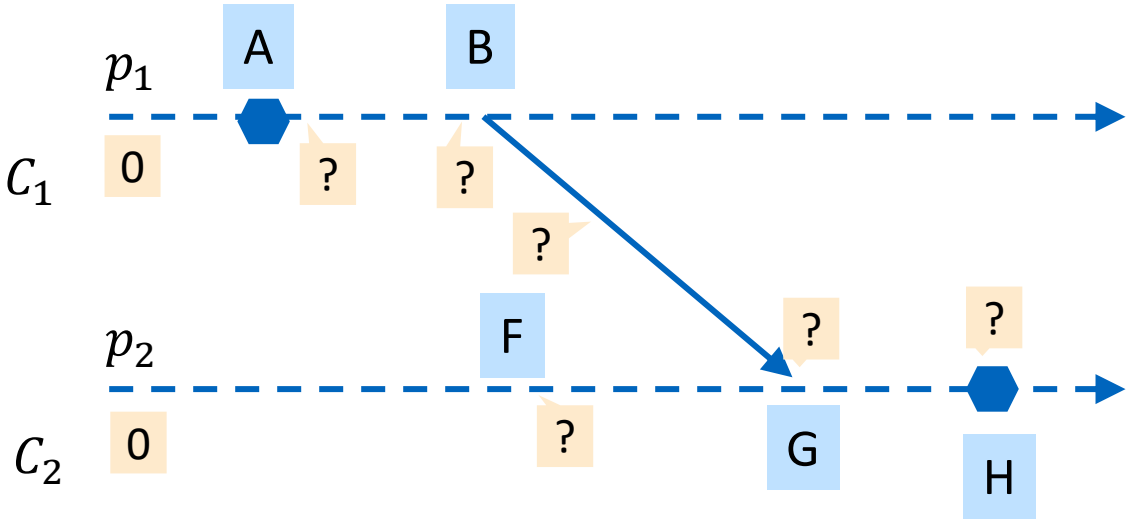

Synchronizace logických hodin

Synchronizace logických hodin

Každý proces p_i si udržuje lokální logické hodiny C_i a nastavuje

1. Po každé události, která se odehraje v p_i, se C_i **inkrementuje** o 1.
2. Každé zprávě m **odeslané** procesem p_i je přiřazena časová značka $ts(m) = C_i$.
3. Kdykoliv proces p_j přijme zprávu m, tak
   I. upraví své lokální hodiny C_j na $\max\{C_j, ts(m)\}$; a poté
   II. provede krok 1 předtím, než předá m aplikaci (⇐ přijetí zprávy je událost)

Příklad: Lamportovy hodiny

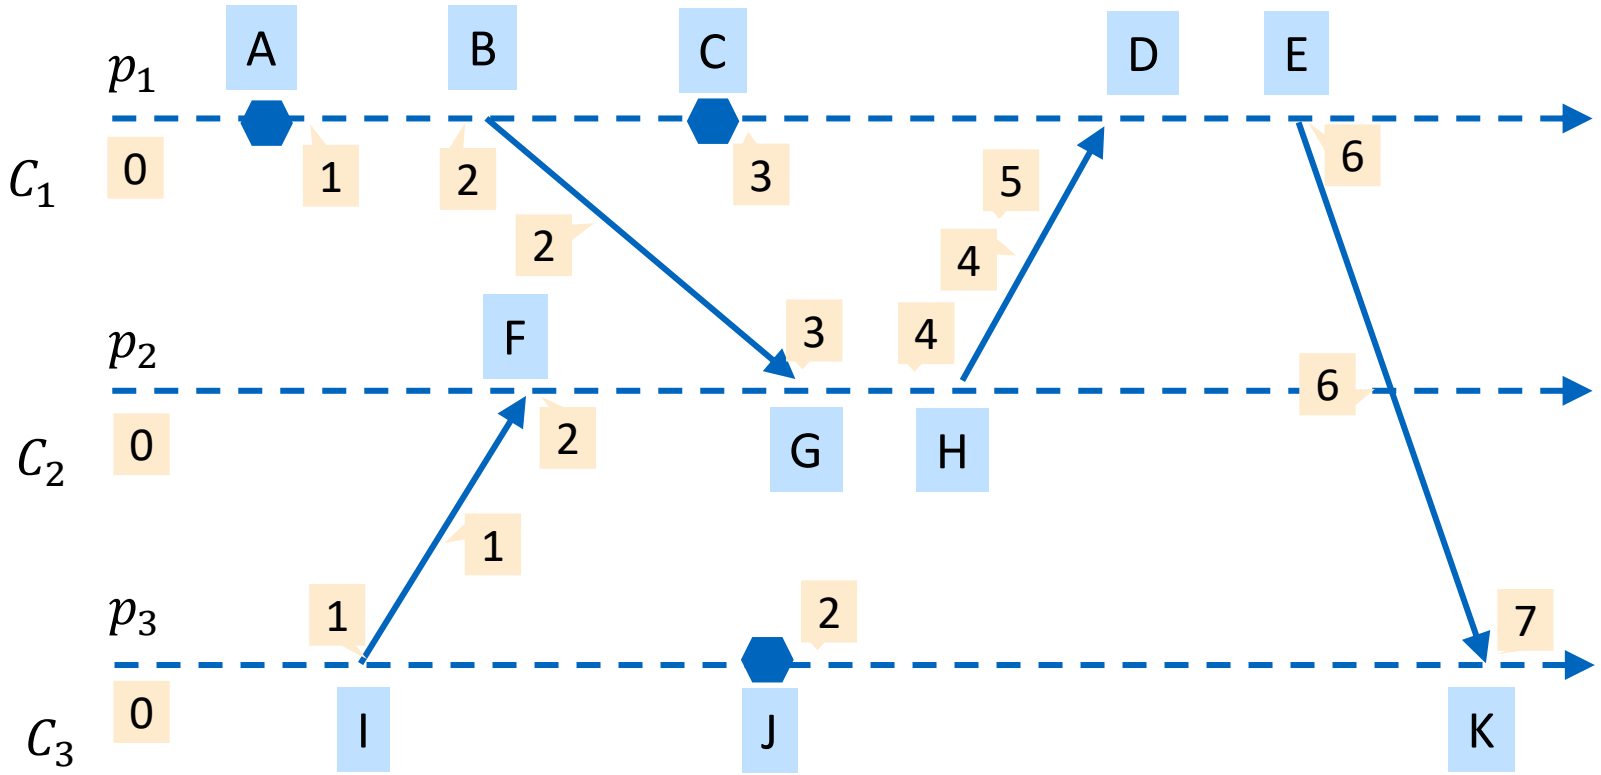

A → B	1 < 2	G → H	3 < 4	C ∥ G?	3 = 3
B → G	2 < 3	F → K	2 < 7	A ∥ J?	1 < 2
A → G	1 < 3	H → K	4 < 7	C ∥ H?	3 < 4
		C → K	3 < 7		

Lamportovy hodiny **neimplikují kauzalitu**!

Logické hodiny a kauzalita

Pár **současných** událostí **nemá kauzální cestu** od jedné události ke druhé (ani jedním směrem).

Lamportovy časové značky pro současné události mohou, ale **nemusí** mít stejnou hodnotu!

- **Platí**: jestliže $e_1 \rightarrow e_2$, pak $C(e_1) < C(e_2)$
- **Neplatí**: jestliže $C(e_1) < C(e_2)$, pak $e_1 \rightarrow e_2$

tj. $e_1 \rightarrow e_2 \Rightarrow C(e_1) < C(e_2)$

Jak zajistit, že **z uspořádání** časových značek jednoznačně poznáme potenciální **kauzalitu**?

Vektorové hodiny

Vektorové hodiny

Předpokládejme skupinu procesů $\{p_1, \dots p_N\}$

Každý proces si udržuje **vektor** celočíselných hodin $V_i[1 \dots N]$

- j-tý element vektorových hodin procesu $V_i[j]$ je znalost procesu i o událostech v procesu j

Synchronizace vektorových hodin

Synchronizace vektorových hodin

Každý proces p_i si udržuje **lokální vektorové hodiny** V_i a nastavuje

1. Před **provedením akce** v procesu p_i se V_i **inkrementuje** o 1, tj. $V_i[i] := V_i[i] + 1$
2. **Pošle-li** proces p_i zprávu m procesu p_j, **nastaví** *vektorovou* časovou značku $ts(m)$ zprávy m na V_i (poté, co provedl krok 1)
3. Proces p_j po **přijetí** zprávy m
   - nastaví své hodiny $V_j[k] := \max\big(V_j[k], ts(m)[k]\big)$ pro všechna $k = 1, \dots, N$ (tzv. **sloučení**)
   - poté **inkrementuje** $V_j[j]$ a předá zprávu m aplikaci.

Vektorové hodiny: příklad

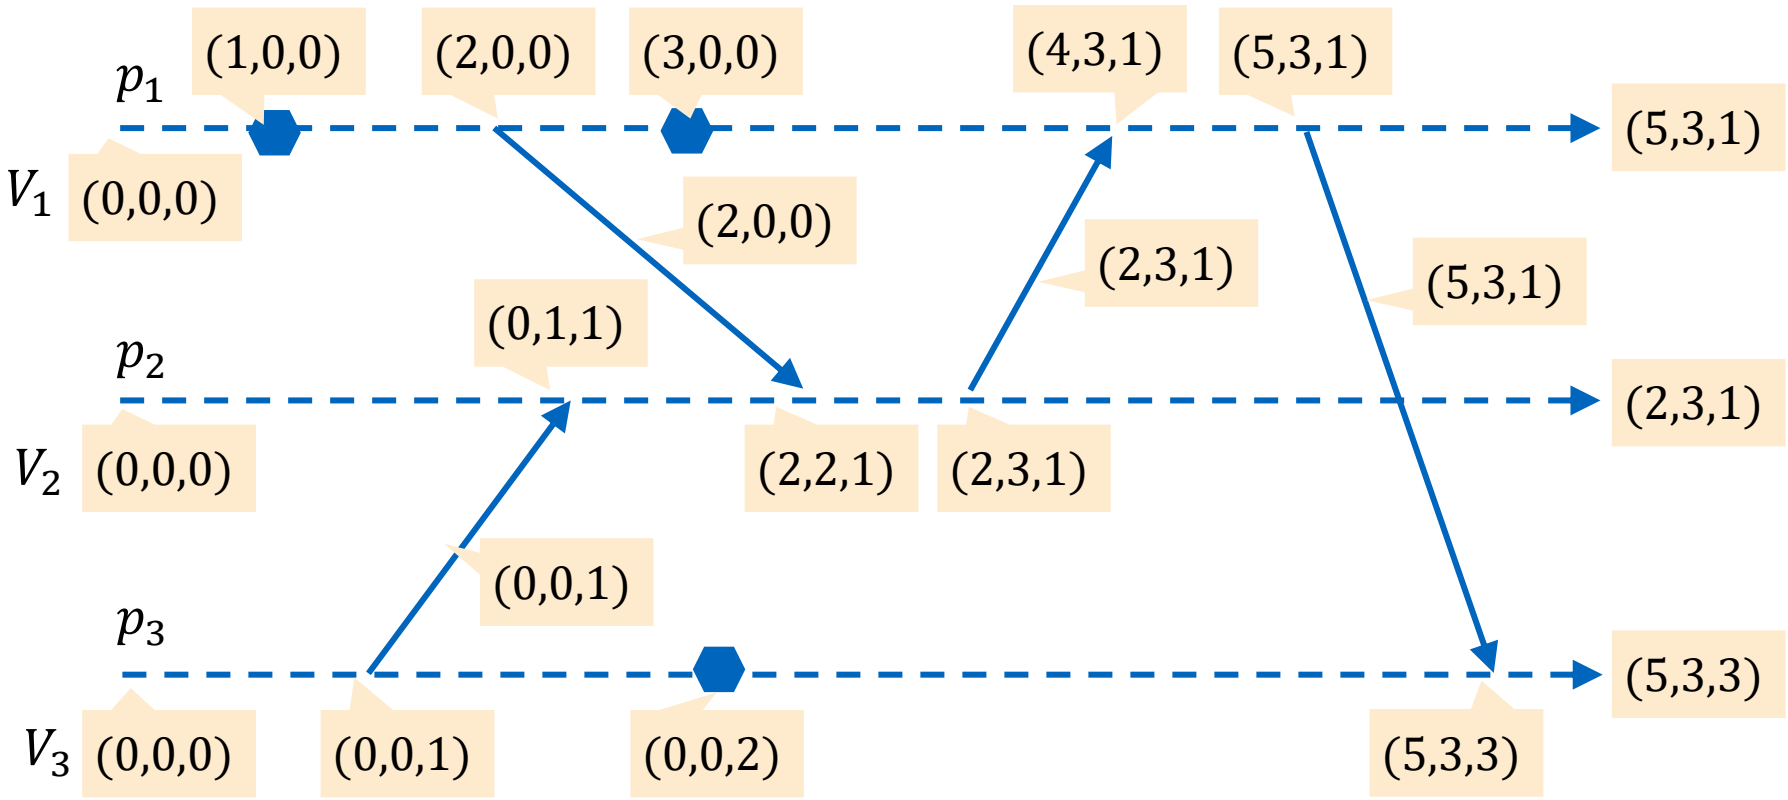

Vektorové hodiny a kauzalita

Upořádání vektorových časových značek:

- $V_1 = V_2$ iff $V_1[i] = V_2[i]$ pro všechna $i = 1, \dots, N$
- $V_1 < V_2$ iff $V_1[i] \leq V_2[i]$ pro všechna $i = 1, \dots, N$ a existuje j, že $V_1[j] < V_2[j]$
- Pokud: $\neg(V_1 < V_2) \wedge \neg(V_2 < V_1)$, pak píšeme $V_1 \parallel V_2$

Pro vektorové hodiny platí:

$e_1 \rightarrow e_2$ **právě tehdy když** pro časové událostí platí $V_{e_1} < V_{e_2}$

t.j. $e_1 \rightarrow e_2 \Leftrightarrow V(e_1) < V(e_2)$

Vektorové hodiny: kauzalita

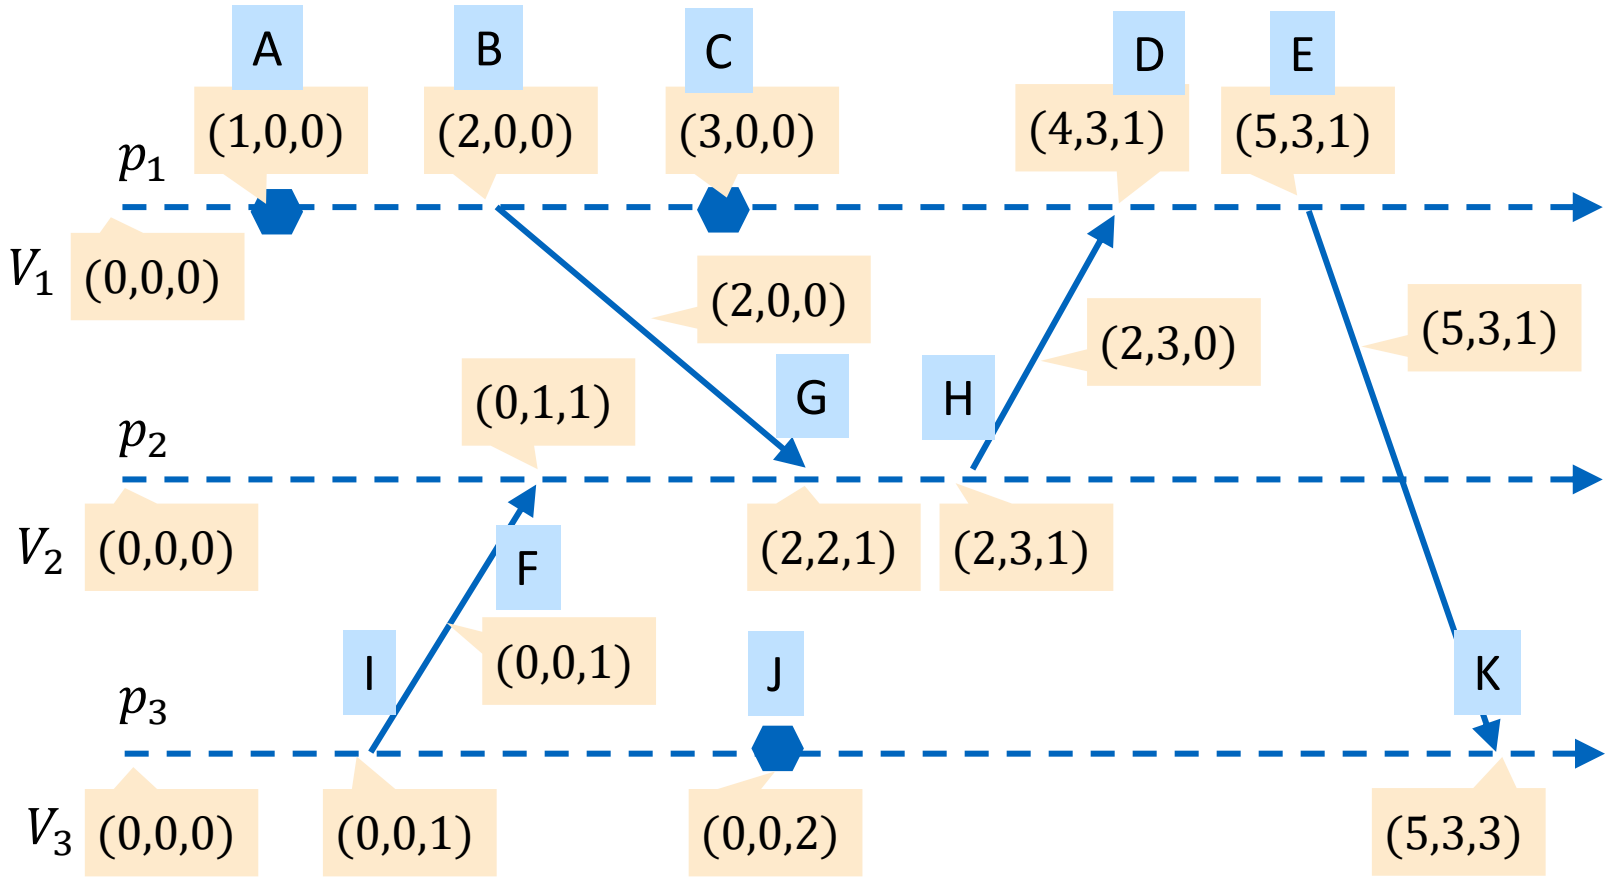

A → B $(1,0,0) < (2,0,0)$
B → G $(2,0,0) < (2,2,1)$
A → G $(1,0,0) < (2,2,1)$

I → H $(0,0,1) < (2,3,1)$
F → K $(0,1,1) < (5,3,3)$
I → K $(0,0,1) < (5,3,3)$
C → K $(3,0,0) < (5,3,3)$

Souběžné události

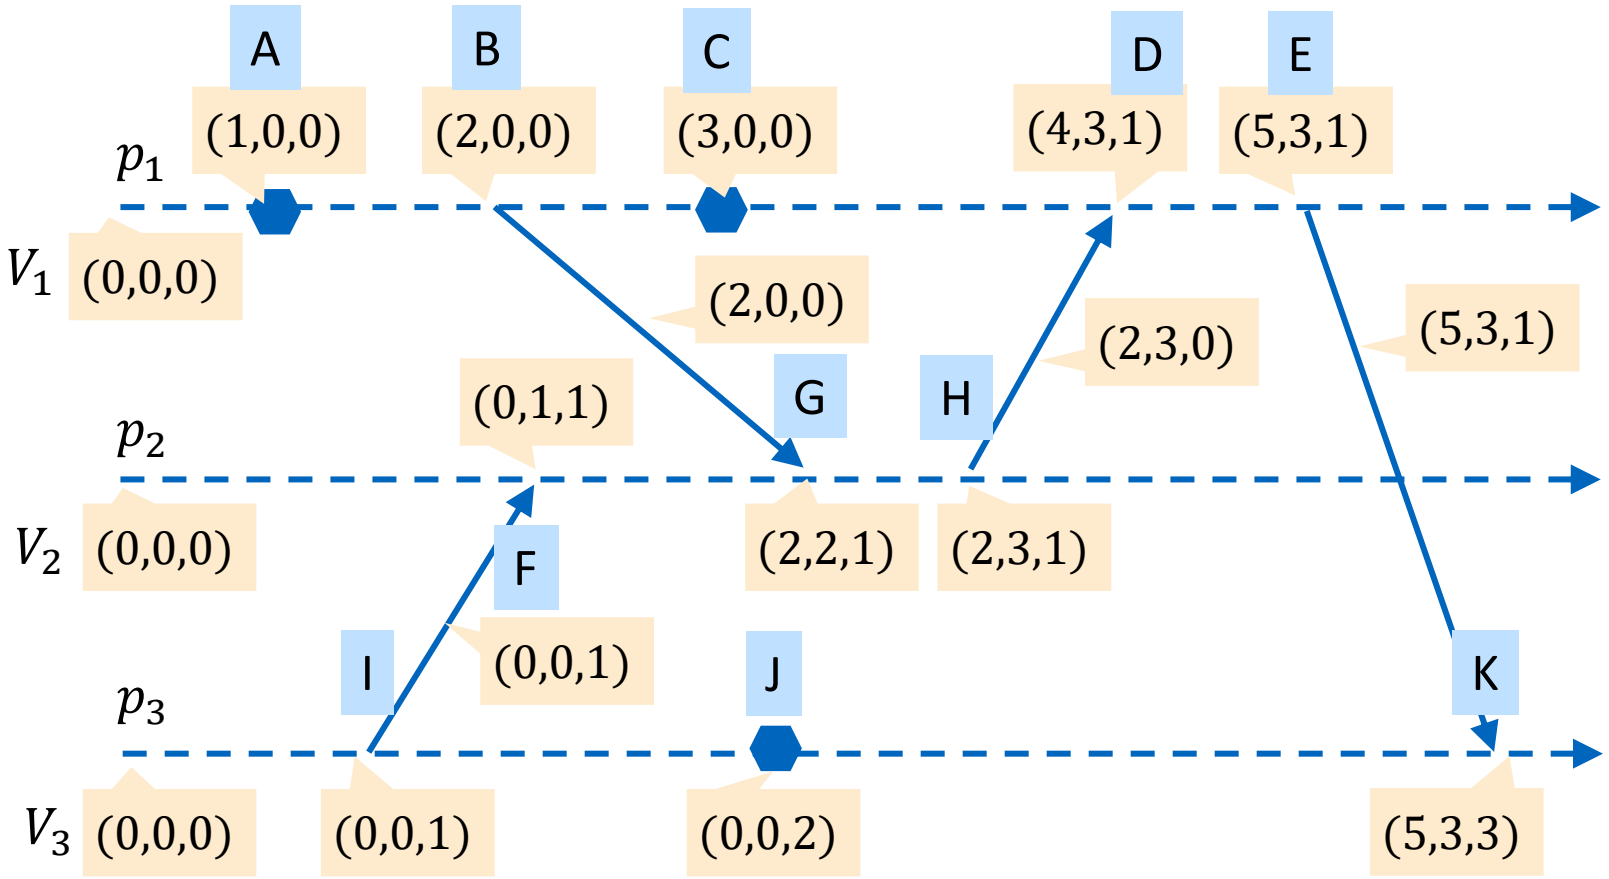

$C \parallel G \quad (3,0,0) \parallel (2,2,1)$
$A \parallel J \quad (1,0,0) \parallel (0,0,2)$
$C \parallel H \quad (3,0,0) \parallel (2,3,1)$

vektorové hodiny rozliší **souběžné události**

Logické hodiny: Souhrn

Lamportovy (skálární) logické hodiny

- respektují **kauzalitu**
- ale nerozliší současné události

Vektorové hodiny

- implikují kauzalitu
- potřebují více místa, ale rozliší **současné události**

Lze dokázat, že pro zachycení kauzality ve skupině N procesů je potřeba **vektorové hodiny délky N** pro každý proces

- Existují algoritmy, které redukují množství dat potřebných pro udržbu vektorových hodin (např. Raynal a Singhal, 1996)

Čas v DS: Shrnutí

Přesně **synchronizované globální** hodiny v DS (s nenulovou latencí přenosu zpráv) **neexistují**.

Lze synchronizovat s určitou přesností:

- Cristianův algoritmus
- NTP
- Berkely algoritmus

… ale chyba je **nenulová** a je funkci **doby oběhu zprávy** (RTT)

Nutností synchronizovat hodiny se můžeme vyhnout využitím **logických hodin**.