

PosAm




Dôveryhodné úložisko Trusted Storage

Peter Smák

produktový manažér PosAm





**Pretvárame informačné technológie
na úžitok pre zákazníkov**

Agenda

- Trendy v oblasti neštruktúrovaných dát
- Regulácie a uchovávanie neštruktúrovaných dát
- Dôveryhodné úložisko a jeho vlastnosti
- Scenáre možného použitia

PosAm

The logo graphic for PosAm consists of two overlapping red ribbon-like shapes that form a stylized underline or swoosh beneath the text.

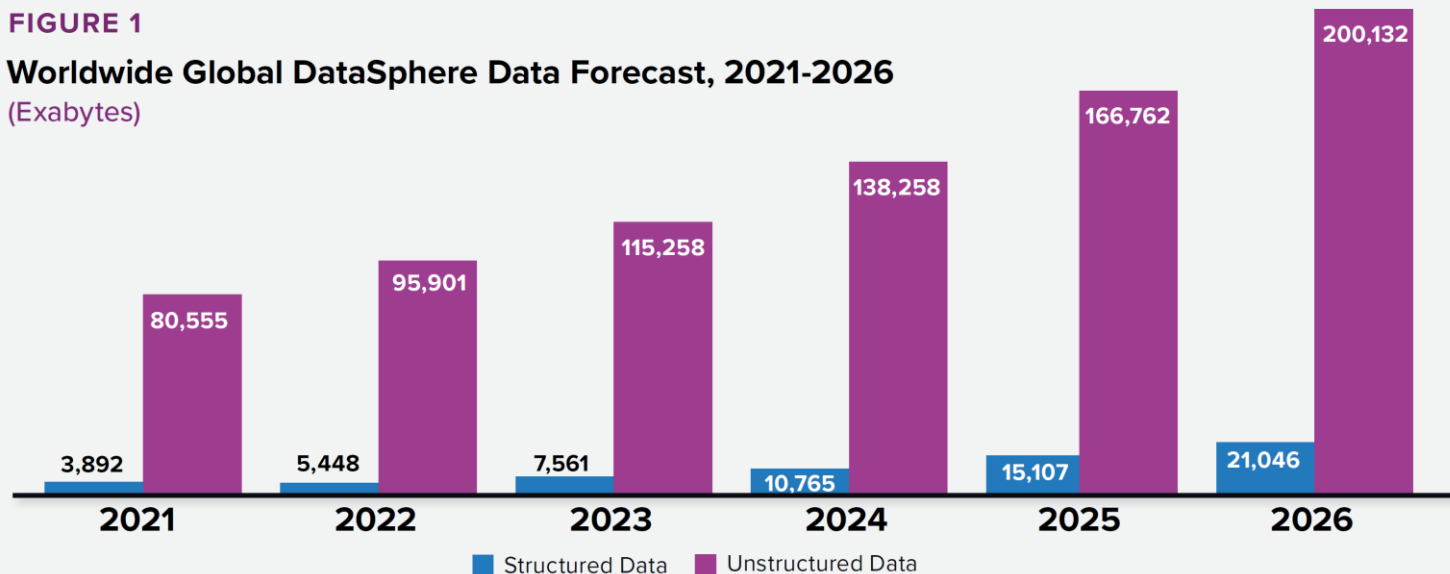
Čo spôsobuje rast neštruktúrovaných dát

- Rozmach internetu a konektivity
- Rast počtu užívateľov, zariadení a veľkosti dát
- Internet of Things (IoT), mobilné aplikácie
- Sociálne siete a marketing, okamžité posielanie správ
- Nové technológie (senzory, snímkovanie...)
- Digitálna transformácia
- Potreba rozhodovania založeného na údajoch (BI)
- Inovácie v oblasti AI

FIGURE 1

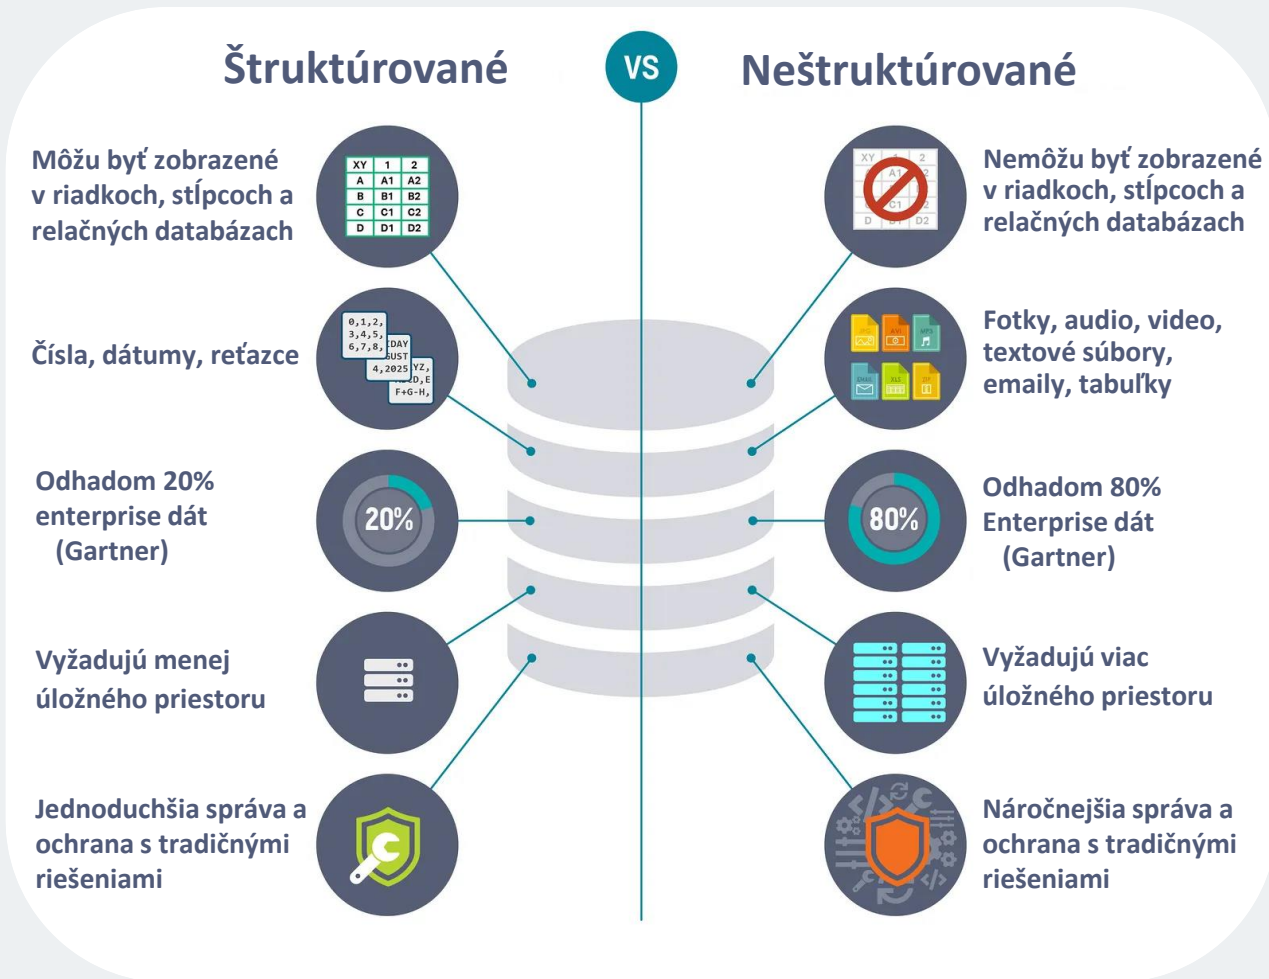
Worldwide Global DataSphere Data Forecast, 2021-2026

(Exabytes)



Source: IDC WW Global DataSphere and Global StorageSphere Structured and Unstructured Data Forecast, 2022-2026

Čo sú to neštruktúrované dáta



Vytvorené človekom

- Textové súbory a emaily
- Súbory kancelárskych aplikácií (pdf, doc, xls...)
- Mobilná komunikácia: SMS, IM, chat, audio a video správy
- Príspevky či tweety na sociálnych sieťach
- Médiá: digitálne fotografie, zvukové nahrávky, videosúbory a pod
- Obsah webových stránok

Strojovo generované

- IoT dáta - senzorické dáta, dáta aplikácii a logy
- Dohľadové systémy - napr. kamerové
- Snímkové údaje – meteo, geo, satelitné, medicínske
- Vedecké dáta (prieskum Zeme, seizmické, atómové...)

Trendy a výzvy v oblasti neštruktúrovaných dát (podľa analytikov)



Trend č. 1: Hromadenie neštruktúrovaných údajov núti mnohé organizácie zvážiť nové prístupy k riadeniu rastu údajov, životného cyklu údajov a súvisiacich nákladov



Trend č. 2: Umelá inteligencia a ML budú analyzovať trendy a vlastnosti údajov s cieľom zabezpečiť proaktívnu (a prípadne automatizovanú) správu neštruktúrovaných údajov



Trend č. 3: Dátové silo efekty a stále prevažujúce ukladanie neštruktúrovaných údajov v systémoch NAS



Trend č. 4: Zvýšená zraniteľnosť voči kybernetickým útokom



Trend č. 5: Právne obmedzenia si vyžadujú odlišné zaobchádzanie s rôznymi typmi údajov

Príklady údajov, u ktorých spôsob digitálneho uchovávania podlieha reguláciám

Verejný sektor

- Údaje vznikajúce pri poskytovaní elektronických služieb štátu
- Údaje vznikajúce v konaniach pred štátnymi, regionálnymi alebo miestnymi orgánmi
- Citlivé údaje obsahujúce kritické, osobné, súkromné, dôverné, utajované alebo inak privilegované skutočnosti
- Záznamy trvalých kultúrnych a historických aspektov – národné archívy a kultúrne dedičstvo
- Digitálne registre štátu
- Geografické dáta – mapy, letecké snímky...

Finančný sektor

- Elektronická kontraktácia (na diaľku), plnenie informačných povinností
- Záznamy z obchodných vzťahov a operácii
- Záznamy z finančných operácii, pri obchodovaní s cennými papiermi, z kolektívneho investovania

Zdravotnícky priemysel

- Medicínske informácie – zdravotné údaje, genetické, biometrické, diagnostické, údaje zo sekvenovania genómov, patologické, laboratórne údaje...

Ostatné sektory

- Preukazovanie integrity a pravosti údajov pred súdmi, regulačnými orgánmi alebo pri predkladaní podkladov príslušným orgánom, právna dokumentácia
- Na preukázanie vlastníckeho práva, duševného vlastníctva, zmluvných alebo iných právne vymožitelných práv a povinností
- Záznamy o platobných operáciách
- Účtovné a daňové informácie, podnikové výkazníctvo, záznamy o zamestnancoch, dávkach, sociálnom a dôchodkovom zabezpečení
- Záznamy, u ktorých spôsob uchovávania údajov podlieha lokálnej legislatíve a európskym smernicam ako GDPR

Dôveryhodné úložisko

Požiadavky na dodržiavanie predpisov

Garancia autenticity údajov

Garancia nemennosti údajov

Garancia nezmazateľnosti údajov

Garancia trvanlivosti integrity údajov

Politiky uchovávania na úrovni údajov

Vyhľadávanie údajov

Auditovateľnosť vykonaných operácií

Požiadavky na bezpečnosť a dostupnosť dát

Multitenantná architektúra

Ochrana dát viacerimi kópiami

Ochrana údajov a komunikácie šifrovaním

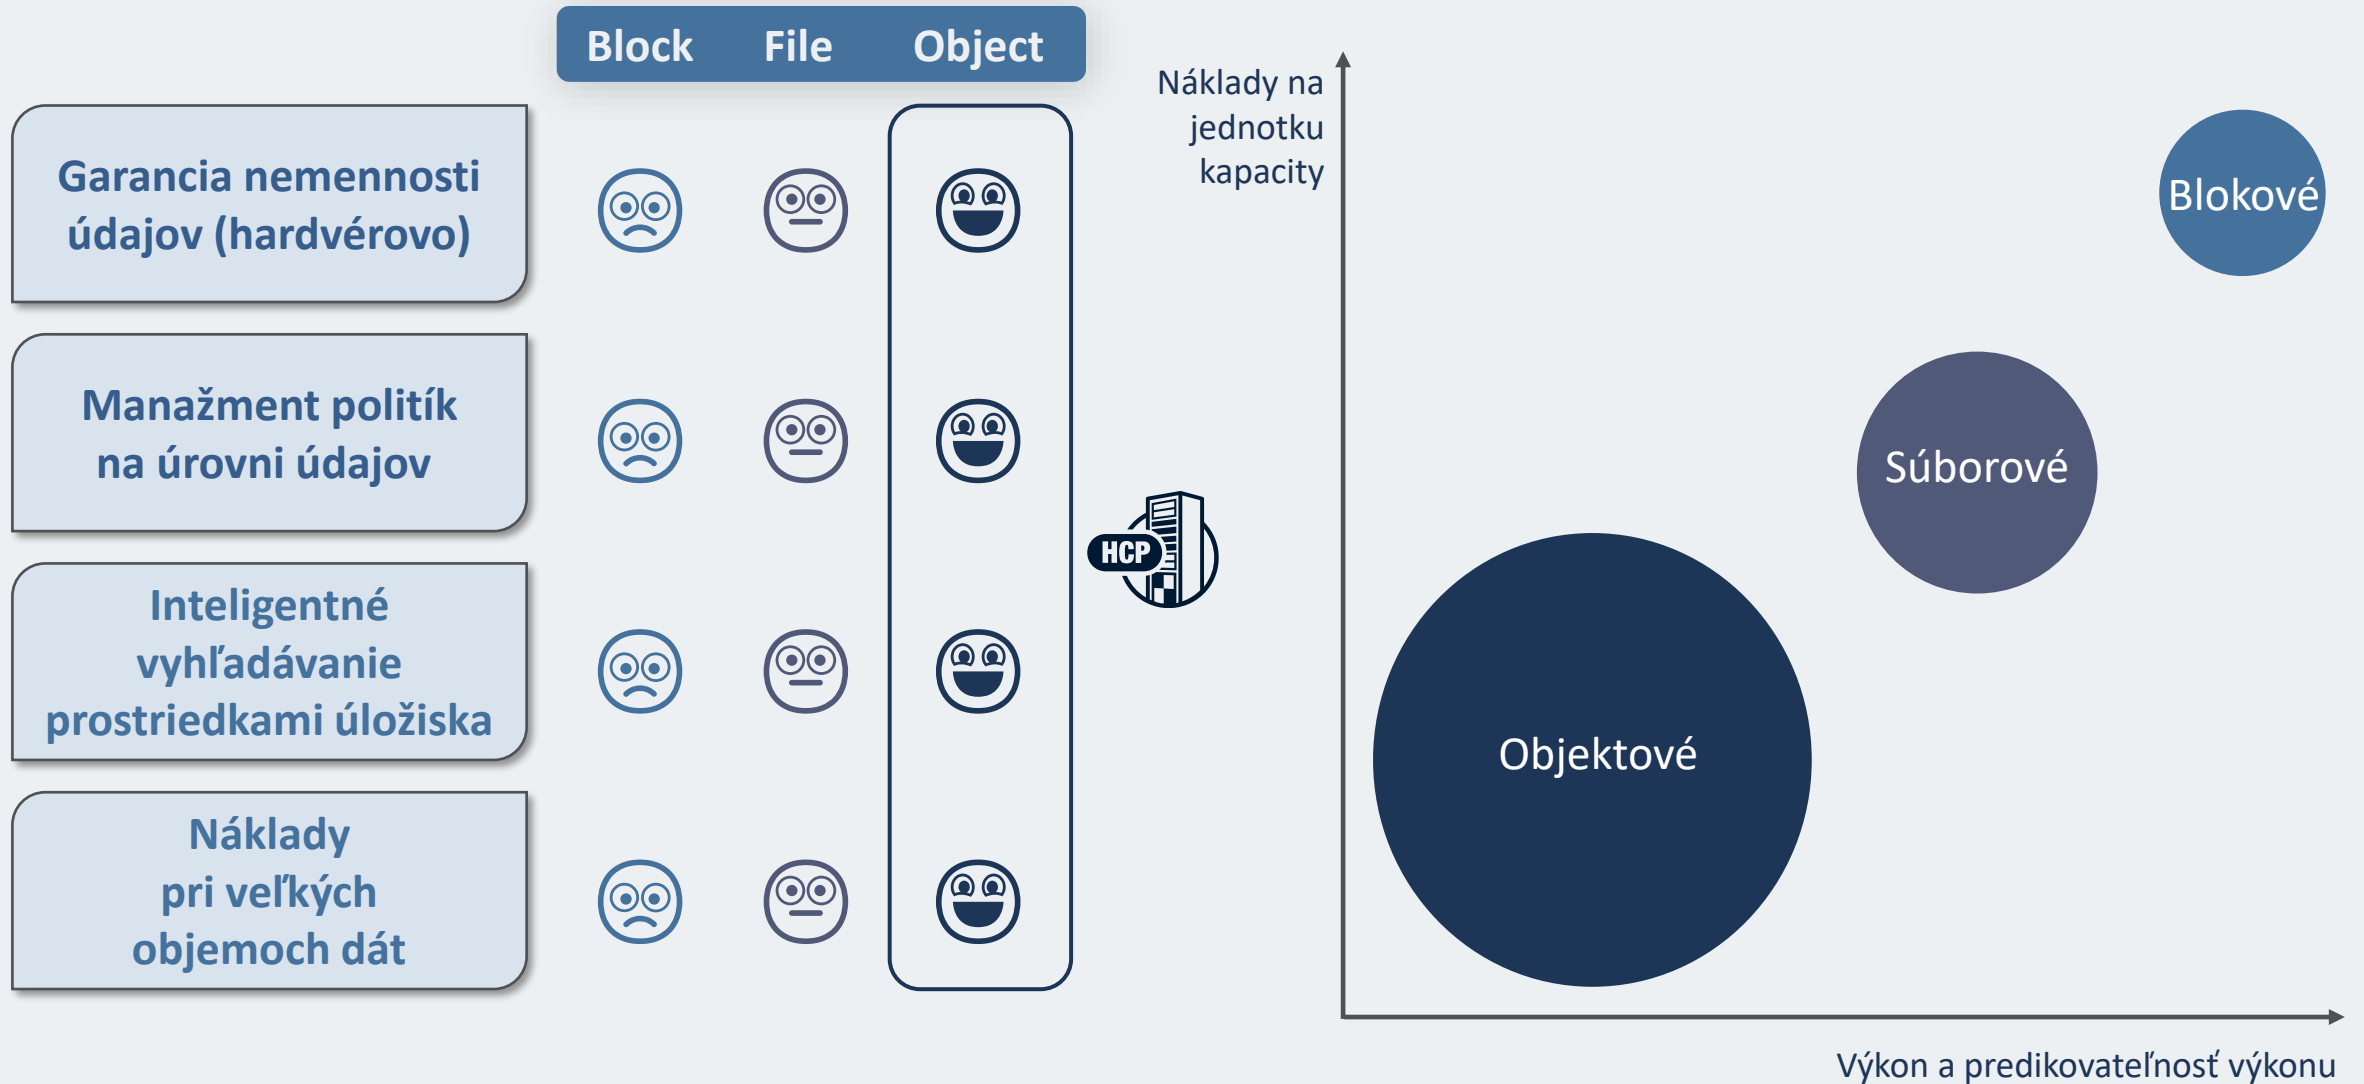
Neobmedzená škálovateľnosť

Maximálna odolnosť

Maximálna dostupnosť dát

Dôveryhodné úložisko je riešenie **aktívnej archivácie**, ktoré umožňuje organizáciám ukladať, chrániť, uchovávať a vyhľadávať **veľké objemy neštruktúrovaného obsahu** v rámci **jednotnej online platformy úložiska**. Je vhodné najmä na uchovávanie citlivého obsahu, ktorý podlieha **zabezpečeniu súladov s predpismi a bezpečnostnými požiadavkami**.

Voľba technológie pre Dôveryhodné úložisko




Čo je to Objekt



Súbor

+



Metadáta



Nastavenia politík k objektu + ACL Metadáta =



Objekt



Systémové Metadáta

- 28 systémových vlastností
- Nastavenia politík k objektu
- POSIX Metadáta

Vlastné Metadáta

- Pridanie relevantných informácií k objektu (anotácie) a vytvorenie asociácií so súvisiacimi objektmi
- Metadáta objektov (XML) sú indexované do škálovateľnej databázy, v ktorej možno vyhľadávať

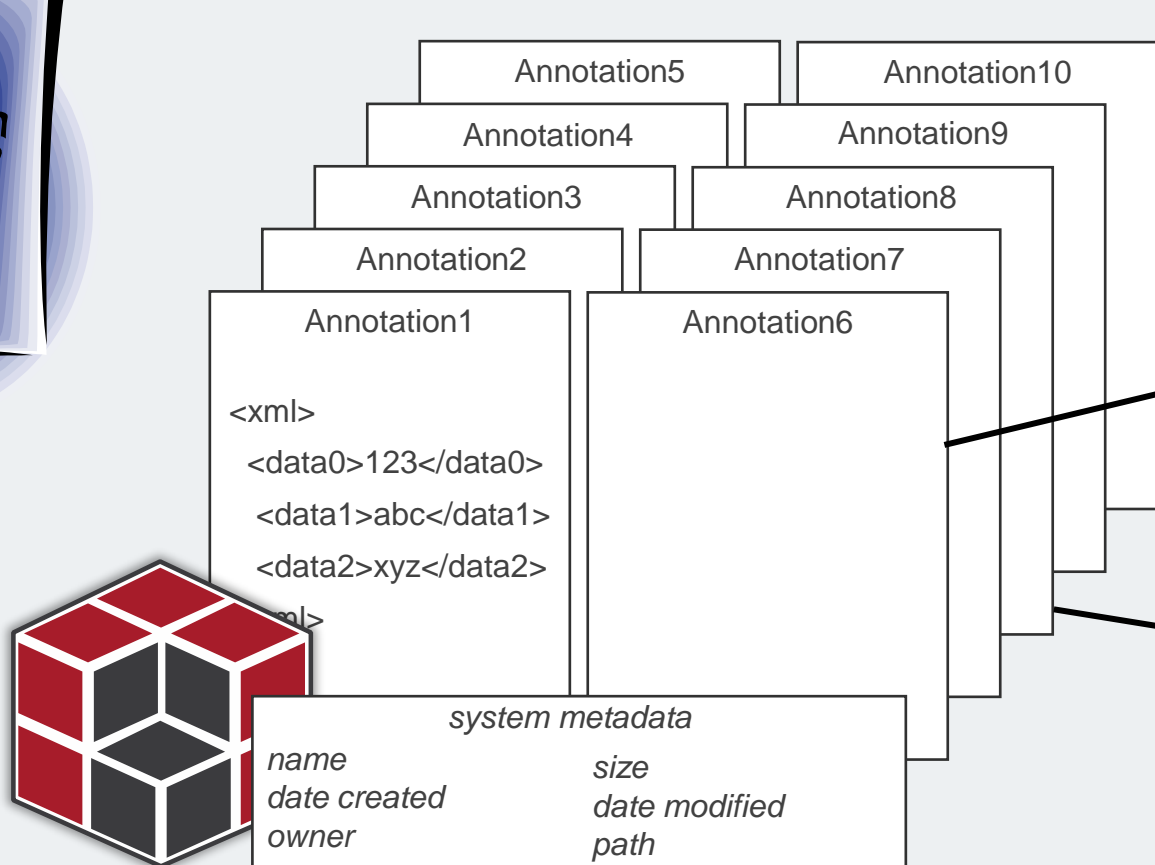
ACL Metadáta

- oprávnenia a prístupy k údajom na úrovni jednotlivých objektov pre používateľov alebo skupiny používateľov

Vlastné metadáta



Source Object



Medical (DICOM)

```
<record>  
<doctor>  
<name>John Smith</name>  
</doctor>  
<patient>  
<name>John Smith</name>  
<age>48</age>  
</patient>  
</record>
```

Image (EXIF)

```
<taken>11/17/12</taken>  
<aperture>5</aperture>  
<ISO>400</ISO>
```

Billing

```
<cost>$1,500</cost>  
<insurance>yes</insurance>
```

Súbor + Metadáta = Objekt

Podpora aplikačných protokolov na HCP

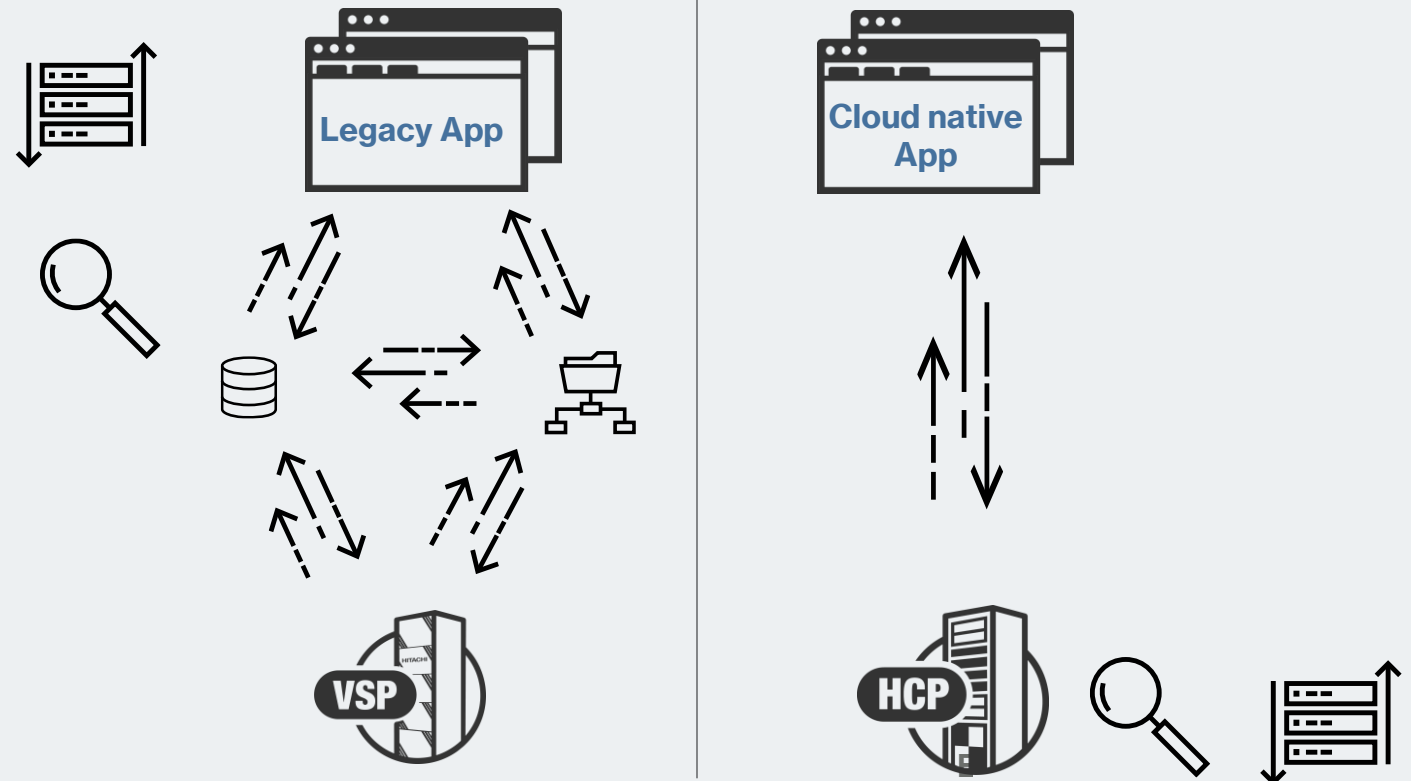
Prístup na dáta

- RESTful API (resp. REST API for HCP)
- Amazon S3 API
- NFS/CIFS/SMB/WebDAV*
- OpenStack SWIFT API
- Kubernetes (CSI)

REST API for HCP – až 10 anotácií / objekt, rozšírený náhľad do fyzickej infraštruktúry HCP, do politik uchovávania, multitenancie, vyhľadávania a metadát.

Pre **S3 API** ponúka HCP vlastné hlavičky, aby S3 aplikácie mohli využívať compliance funkcie HCP, ktoré nie sú súčasťou špecifikácie S3 API.

Prístup na dáta



Vlastnosti Dôveryhodného úložiska – Splnenie regulačných požiadaviek

Autenticita údajov

- Zapisované dáta sú presnou digitálnou kópiou zapísaného súboru (digitálny odtlačok na báze hash algoritmu)
- Digitálny odtlačok je trvalo spojený s objektom – HCP ho počas životného cyklu pravidelne porovnáva s pôvodnou hodnotou

Nemennosť údajov

- Funkcionalita WORM (Write-Once-Read-Many)
- Zmenám alebo zmazaniu zabraňuje aj ochrana verzii objektov

Nezmazateľnosť údajov

- Režim **Compliance** – objekty nie je možné odstrániť žiadnym mechanizmom a nie je možné zmazať parametre uchovávania alebo skrátiť dobu uchovávania.
- Režim **Enterprise** - objekty môže odstrániť len oprávnený používateľ, pričom môže tiež zmazať parametre uchovávania alebo skrátiť dobu uchovávania.

Trvanlivosť integrity údajov

- Mechanizmy samo-opravy dát počas životného cyklu – zabránenie degradácii
- Digitálne odtlačky sa porovnávajú s replikami údajov
- Ak je objekt prečítaný aplikáciou a aplikácia ho odošle znovu na uloženie, jeho hash HCP znovu prepočíta a porovná

Politiky uchovávania na úrovni objektov

- Doba uchovávania
- Privilegované vymazanie (GDPR)
- Legal Hold (právne podržanie)
- Verzionovanie
- Indexovanie
- Skartovanie (v súlade so špecifikáciou DoD 5220.22-M)

Vyhľadávanie údajov

- Ako súčasť dátového manažmentu
- Ako súčasť právneho alebo auditného procesu
- Podpora pre 370 súborových formátov a 77 jazykov
- Vstavaný Metadata Query Engine (konzola alebo API)

Auditovateľnosť

- Úplné a komplexné monitorovanie a audit všetkých udalostí počas životného cyklu informácií
- Sledovanie objektov (object tracking) a zaznamenávanie udalostí (event logging) vrátane všetkých akcií zmazania objektov
- HCP vie generovať auditné prehľady

Vlastnosti Dôveryhodného úložiska – Bezpečnosť Dát

DPL/MDPL – Data & Metadata Protection Level

- Redundancia pre kritické alebo vysoko hodnotné údaje
- Všetky kópie údajov pre objekty sú uložené vo všetkých uzloch v „ochranných setoch“
- Každý HCP klaster umožňuje ukladať až 4 repliky pôvodného dátového objektu (2 default) a až 2 repliky metadát
- V prípade poškodenia je ich možno ich obnoviť pomocou druhej kópie

Šifrovanie komunikácie

- IP filtrovanie a SSL pre HTTP prístupy (REST, S3)
- Manažment prístupov k IP adresám
- Každá prístupová brána HCP má svoje bezpečnostné mechanizmy
- Vstavaný firewall pre nepoužité porty
- Vzdialená správa cez SSH
- Administrácia cez samostatné porty alebo VLAN

Šifrovanie

- Viac-úrovňové šifrovanie (DEK / KEK)
- Integrácia s externými KMS riešeniami (KMIP API 1.4 alebo novším)
- Šifrovací kľúč sa generuje v čase inštalácie systému a je distribuovaný medzi uzly HCP (nutné kvórum)
- HCP šifruje automaticky in-line – bez potreby meniť prístupy alebo procesy
- Všetky metódy šifrovania sú podľa AES-256 (súlad s FIPS 140)
- Kľúče nie sú nikdy uložené v HCP a nie sú prístupné správcovi HCP

Overovanie používateľov (RBAC) a Access Control List (ACL)

- Lokálne používateľské účty
- Integrácia s MS Active Directory a RADIUS
- ACL metadáta - riadenie prístupu k údajom na úrovni jednotlivých objektov

Vlastnosti Dôveryhodného úložiska – Multitenantná architektúra

Logické oddelenie správy, údajov a politik

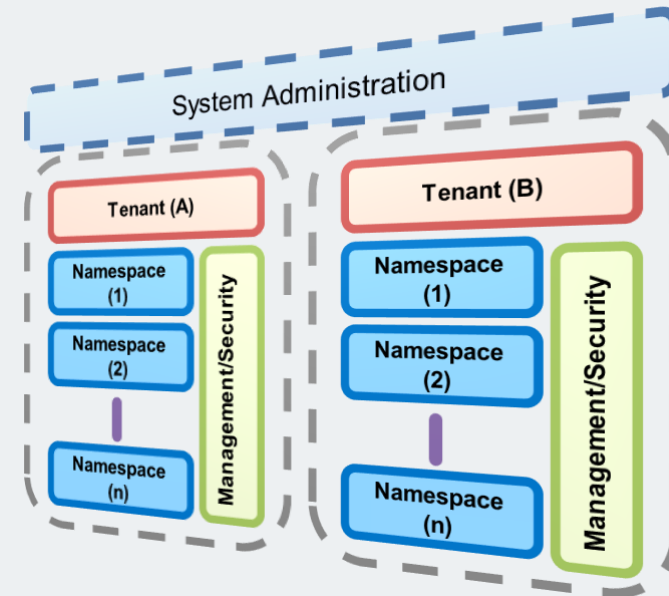
Tenant

- Oddelenie na úrovni správy
- Typicky organizačná jednotka alebo workload – virtuálne HCP
- Až 1000 tenantov / HCP

Namespace

- Oddelenie priestorov pre údaje – až 10 000 namespace / HCP
- Oddelenie údajov uložených - aplikáciami, obchodnými jednotkami, používateľmi alebo zákazníkmi.
- Objekty uložené v jednom namespace nie sú viditeľné v žiadnom inom namespace

Chargeback – HCP vie generovať prehľady za spotrebovanú kapacitu - užitočné napr. pri využívaní prostriedkov úložiska rôznymi organizačnými jednotkami



Example of Namespace adress

<https://t1n1.t1.hcp.company.sk>

<https://t1n2.t1.hcp.company.sk>

<https://t2n3.t2.hcp.company.sk>

Example of object representation

<https://t5n1.t5.hcp.company.sk/rest/images/image1.jpg>

<https://t5n1.t5.hcp.company.sk/hs3/images/image1.jpg>

Vlastnosti Dôveryhodného úložiska – Škálovateľnosť

Kľúčové atribúty

- Výkonnosť architektúra HCP je schopná adresovať požiadavky malých aj veľkých objektov
- Multilokalitné riešenie - až 80 uzlov, 160 rackov, >1EB na lokalitu, >6EB (Geo-EC), >100B objektov na systém
- Nezávislé škálovanie všetkých vrstiev a bezvýpadkové rozširovanie

Prístupové G-uzly

- Klaster (min. 4 uzly)
- Spracovanie I/O od klientov, služby pre protokoly, ukladanie metadát, indexov, beží tu vstavaný search engine a OS
- Automatické rozkladanie záťaže na všetky prístupové uzly
- Môže slúžiť aj na ukladanie objektov (interná kapacita s RAID6)

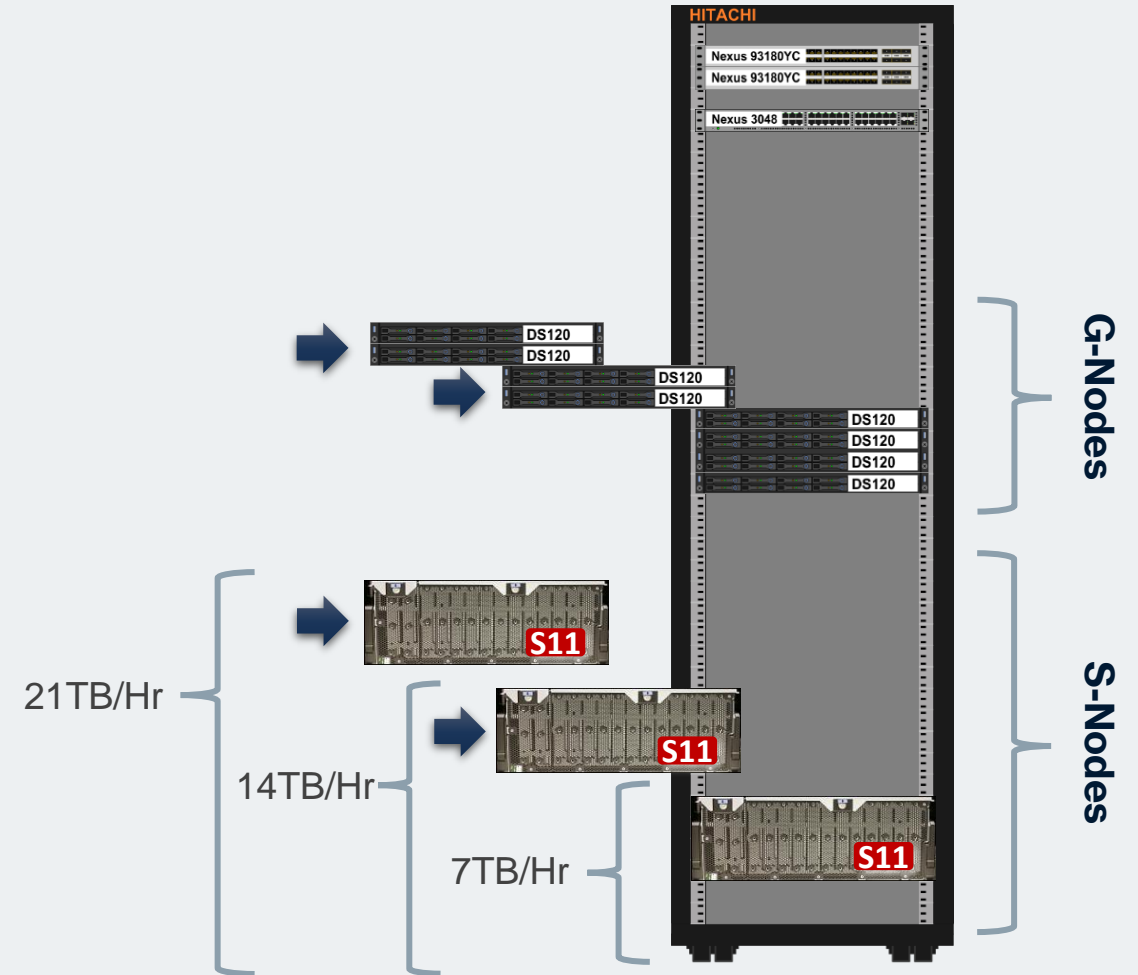
Úložné S-uzly

- Úložná kapacita pre objekty a metadáta
- S11: max 3.2PB per node
- S31: max 15.1PB per node

Ďalšie vrstvy na:

Vyrovňovanie záťaže – Load Balancers

Dedikované Search uzly na vyhľadávanie – Hitachi Content Intelligence



Vlastnosti Dôveryhodného úložiska – Odolnosť

1. Na úrovni údajov

- Redundantné kópie údajov a metadát (DPL / MDPL)
- Overovanie obsahu pomocou hashov a automatická oprava objektov
- Ochrana dát pred zmazaním – WORM a verzionovanie

2. Na úrovni komponentov

- Redundantná HW architektúra, RAID6 na G-uzloch, EC (20+6) na S-uzloch
- HCP dáta zostávajú na S-uzloch dostupné aj pri výpadku 6 diskov naraz
- HCP dáta sú dostupné pri výpadku celého G-uzla


3. Na úrovni celej lokality (viac-lokalitné riešenie)

- Automatická oprava údajov pomocou replík zo záložných lokality
- Topológia globálneho prístupu - obojsmerná async repl active, pri ktorej sú systémy HCP synchronizované spôsobom používateľom a aplikáciám prístup k údajom z najbližšej lokality

Geodistribovaný Erasure Coding

- Ochranný mechanizmus kódovania dát
- Minimálne 3 lokality, maximálne 6
- Jeho benefitom je zvýšenie efektívnej kapacity až o 40%

Bezvýpadková (online) migrácia dát na novú generáciu úložiska bez vplyvu na existujúce aplikácie a so zachovaním pôvodných metadát objektov



Výsledkom je mimoriadna ochrana údajov:

Prístupnosť HCP je 99.99999999% (10 deviatok) = nedostupnosť 3ms ročne

Trvanlivosť dát na HCP je 99.99999999999999% (15 deviatok) = milión x lepšia ako AWS S3

HCP nie je nutné zálohovať

*Dostupnosť = prístupnosť (môžete sa dostať k svojej aplikácii a k svojim údajom)
+ trvanlivosť (či sú údaje neporušené a konzistentné)*

Capacity Savings	0%	25%	33%	37%	40%
------------------	----	-----	-----	-----	-----

Vlastnosti Dôveryhodného úložiska – Sumarizácia

Hitachi Content Platform spĺňa všetky atribúty dôveryhodného úložiska:

- ✓ Garancia autenticity, nemennosti, nezmazateľnosti a trvalej integrity uchovávaných informácií
- ✓ Schopnosť nastavovať politiky ako doby uchovávanania, právneho podržania, verzionovania a skartovania na úrovni objektov
- ✓ Rýchle vyhľadávanie údajov v rámci právnych alebo auditných procesov vďaka metadátam
- ✓ Ochrana citlivých dokumentov pomocou pokročilých techník šifrovania, vstavané schémy šifrovania dát s integráciou na externé KMS
- ✓ Každá činnosť je v systéme je plne kontrolovateľná – auditovateľná
- ✓ Multitenantná architektúra - pobočky, užívatelia, aplikácie a dáta majú vlastné „virtuálne“ HCP
- ✓ Takmer neobmedzená škálovateľnosť, nezávislé a bezvýpadkové rozširovanie a údržba všetkých HW vrstiev
- ✓ Bezvýpadková migrácia na novú generáciu úložiska bez vplyvu na aplikácie / používateľov a so zachovaním pôvodných metadát
- ✓ Mimoriadna ochrana údajov a odolnosť, ktorá eliminuje potrebu zálohovania



Hitachi Content Platform – ďalšie možnosti HCP ekosystému

HCP Anywhere Enterprise

- Smart Cache riešenie Edge úložísk pre SMB/NFS pobočky s protokolovým mostíkom do centrálnych S3 HCP
- Globálne dostupný súborový systém s End-to-End bezpečnosťou
- Privátne zdieľanie a synchronizácia citlivých dokumentov medzi pobočkami

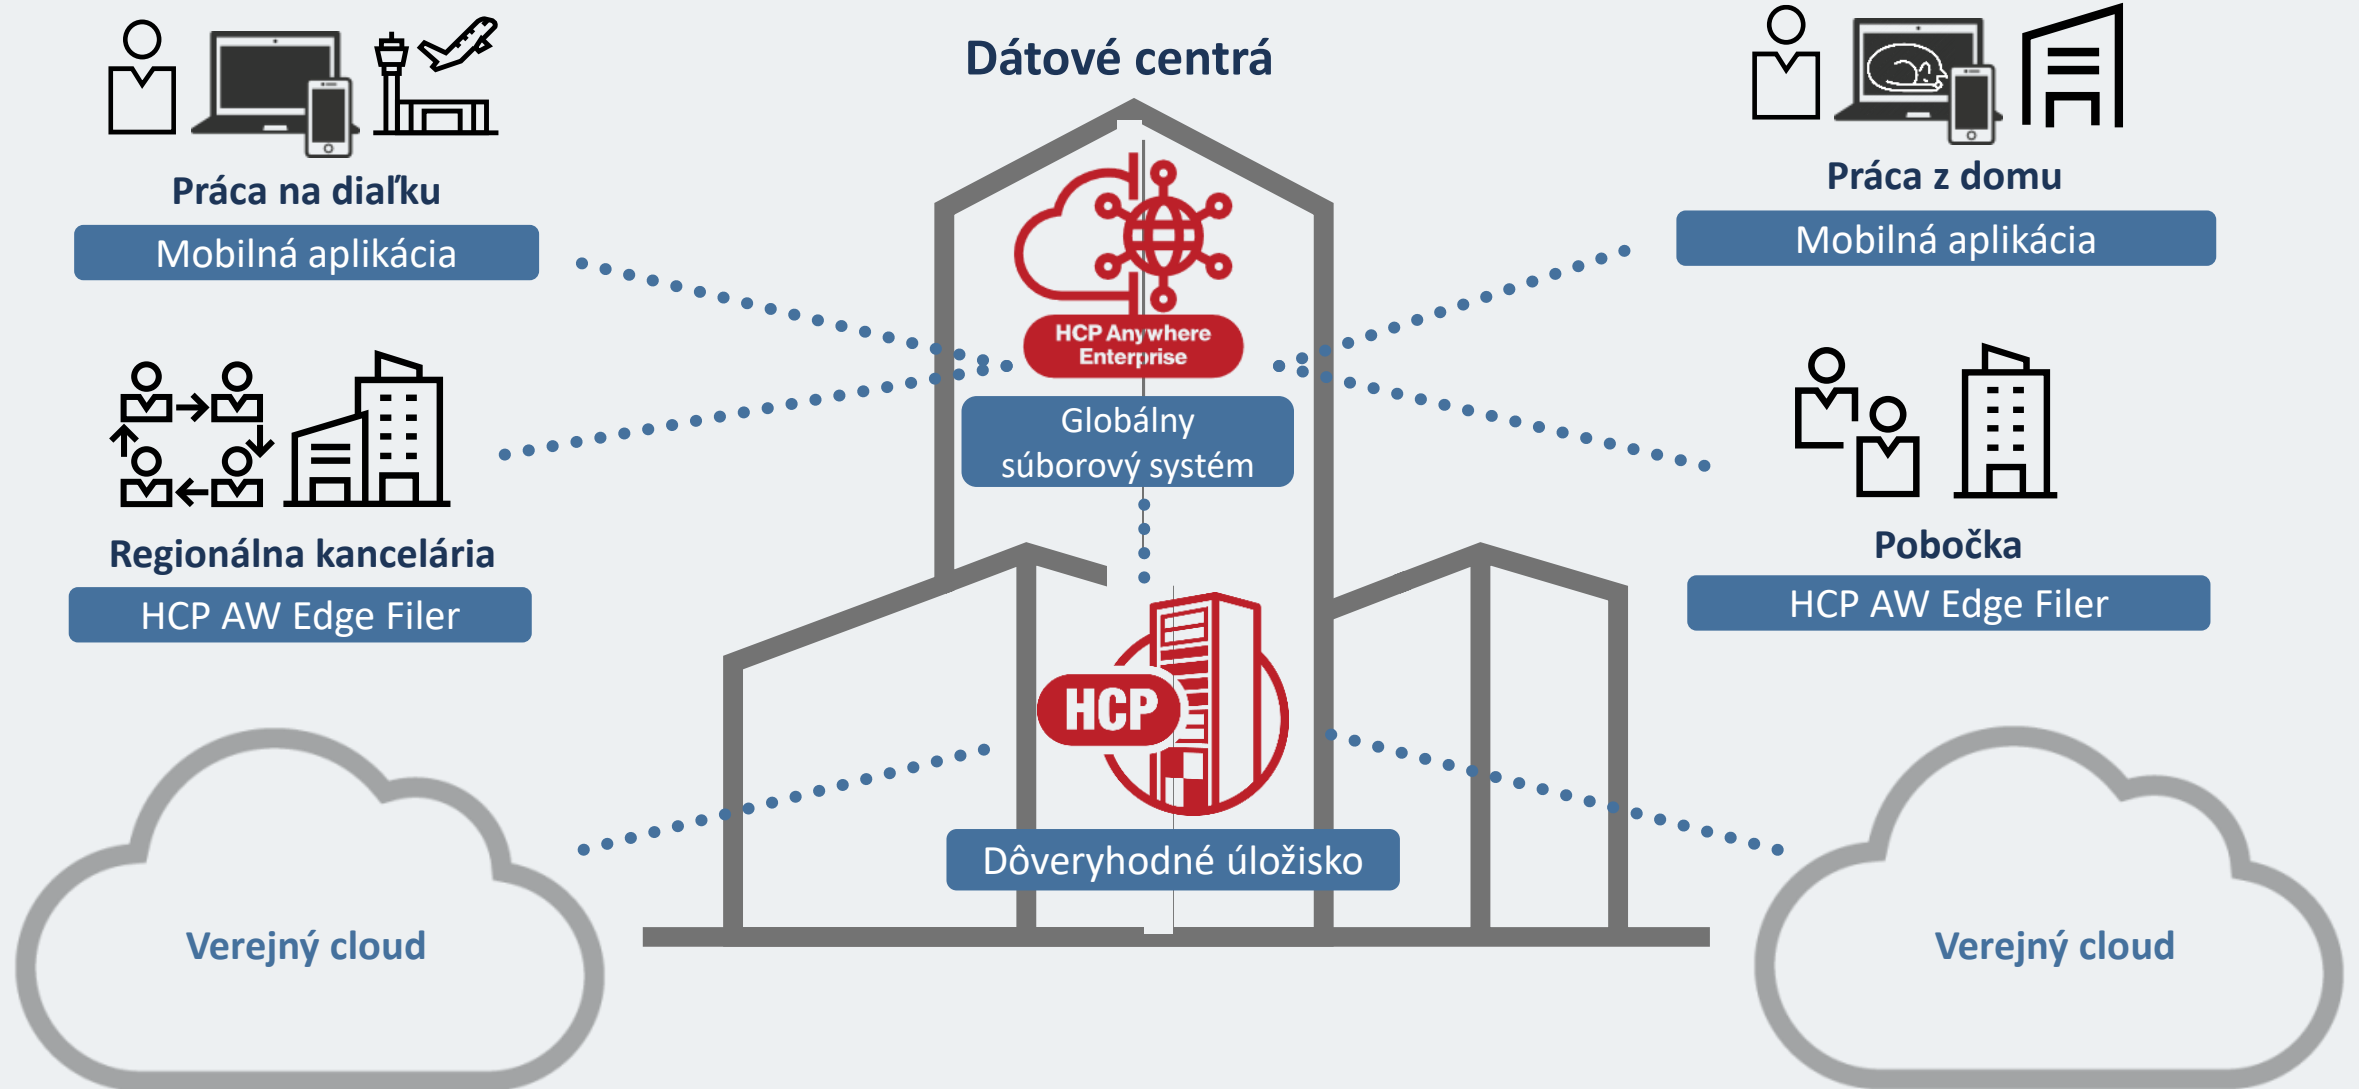
HCP Content Monitor

- Rozširujúce riešenie na monitorovanie HCP úložísk
- Analýza trendov v podobe grafických vizualizácií s cieľom zlepšiť plánovanie výkonu a kapacity
- Prispôsobenie monitorovania metrík, aby boli relevantné pre potreby organizácie

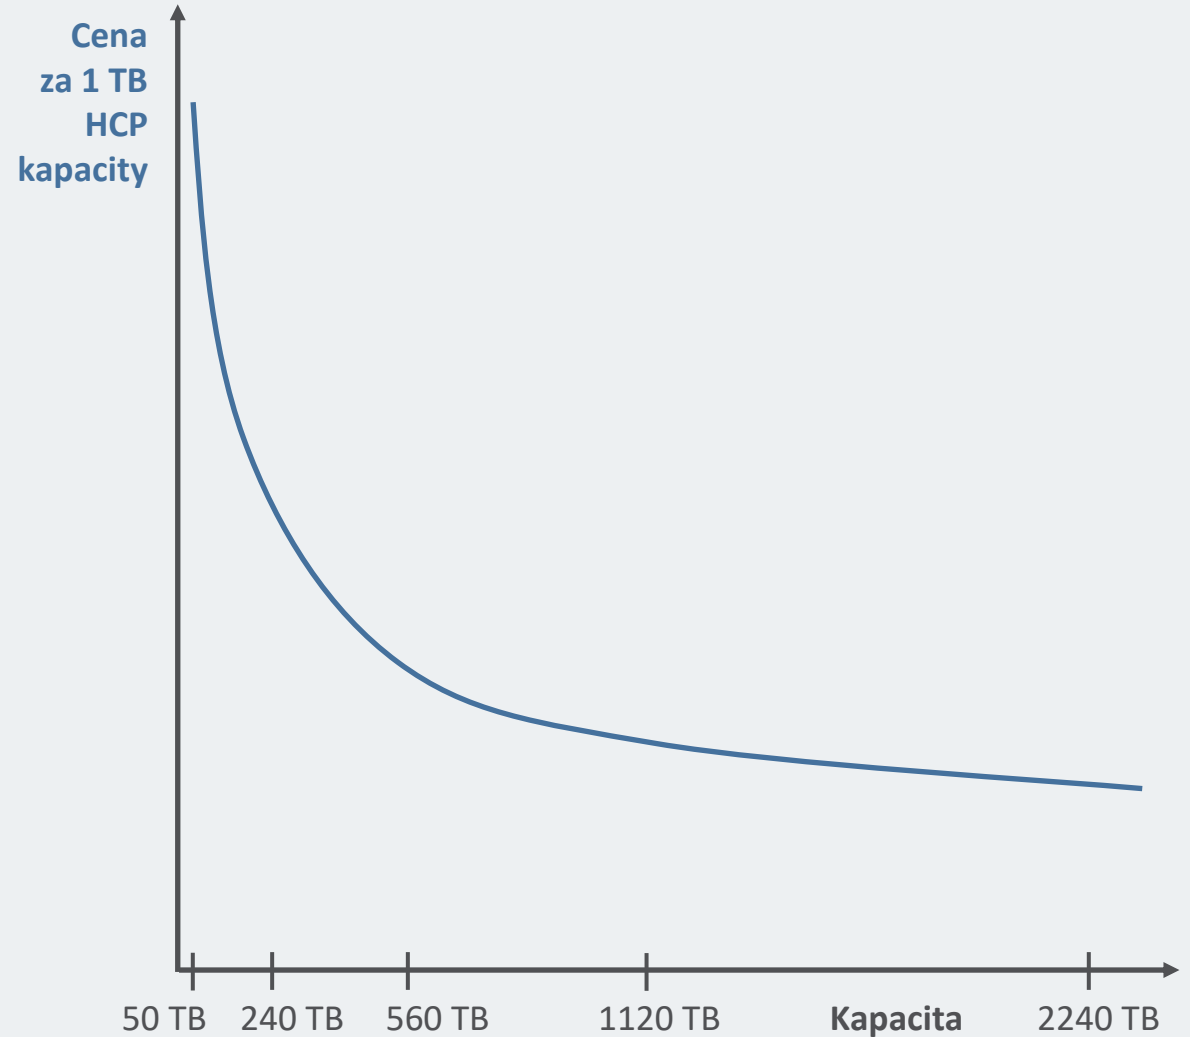
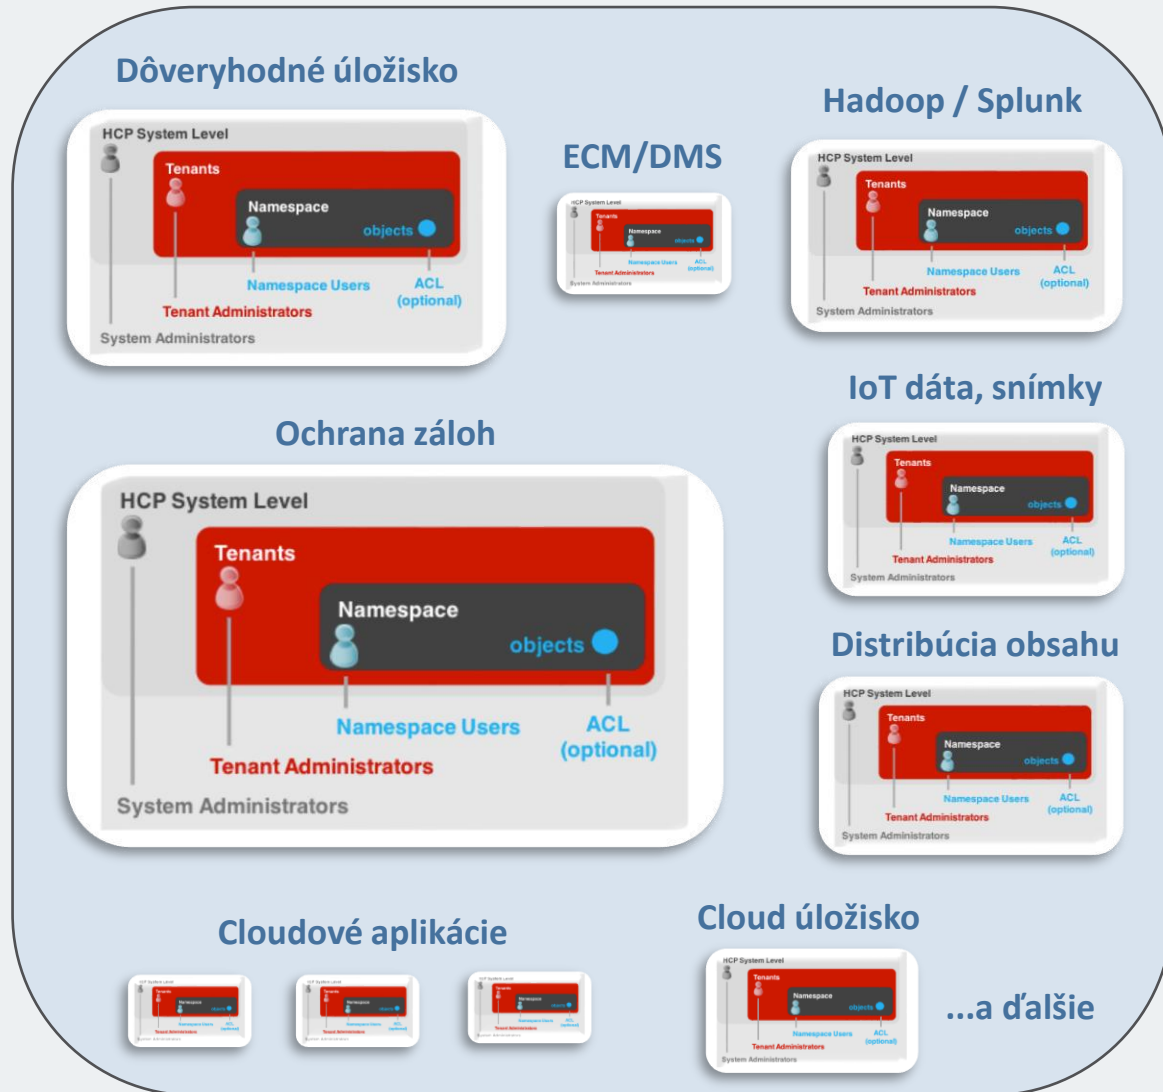
HCP Content Intelligence

- Automatizuje extrakciu, klasifikáciu, obohacovanie a kategorizáciu štruktúrovaných alebo neštruktúrovaných údajov.
- Workflow Designer (wizard driven, drag & drop)
- Možnosť integrácie s treťostrannými aplikáciami

HCP Anywhere Enterprise



HCP – scenáre použitia a ekonomika škálovania



Dalšie verejné zdroje:

K splneniu právnych požiadaviek:

- [Hitachi Content Platform and Compliance Obligations in the European Union, BEP SYSTEMS, 2019](#)
- [Hitachi Content Platform \(HCP\): SEC 17a-4\(f\), FINRA 4511\(c\), and MiFID II Compliance Assessment, Cohasset Associates, 2019](#)

Technická architektúra:

- [Hitachi Content Platform Architecture Fundamentals, Hitachi Vantara, 2020](#)
- [HCP Security Hardening Whitepaper, Hitachi Vantara, 2020](#)
- [The Path to 10 Nines Availability with Hitachi Content Platform \(HCP\), Hitachi Vantara, 2017](#)
- [Secure File Services for Government and Defense, HCP Anywhere Enterprise, Hitachi Vantara, 2023](#)

Posúdenie od tretích strán:

- [2022-23 DCIG TOP 5 On-Premises SDS Object Storage Solutions, Hitachi Content Platform, DCIG, 2023](#)
- [GigaOm Radar for Unstructured Data Management \(UDM\), GigaOm, 2023](#)
- [Object storage for digital-age challenges, MIT Technology Review Insights, 2020](#)

PosAm



Ďakujem za pozornosť

Peter Smák

produktový manažér PosAm

peter.smak@posam.sk

