

Digitální svět: technologie, potenciál, rizika  
**Dlouhodobé uchování dat**

**Miroslav Bartošek**, bartosek@ics.muni.cz  
**David Antoš**, antos@ics.muni.cz

# Přednášející



## Miroslav Bartošek

- ÚVT MU, Knihovnicko-informační centrum MU
- Automatizace knihoven
- Digitální knihovny
- Open Science



## David Antoš

- ÚVT MU, CESNET, z.s.p.o.
- Oddělení datových úložišť
- Digital Preservation

# Obsah přednášky

## 1. Uchování informací v historii lidstva

Paměťové instituce • Nosiče informací a jejich životnost • Co se nám z minulosti dochovalo/nedochovalo a proč

## 2. Uchování informací v digitálním světě

Specifika a hrozby digitálních informací • Křehkost médií • Technologické zastarávání • Ochranné strategie • Aspekty digitální ochrany

## 3. Digitální archiv a osobní archivace

OAIS model – nahlédnutí za oponu • Důvěryhodnost • Tipy pro osobní archivaci • Chmurné perspektivy?

## 4. The Long Now

Podpora dlouhodobého uvažování • 10.000 Year Clock • Rosetta Disc

# 1. Uchování informací v historii lidstva

# 1.1 Uchování informací

– Uchovávání informací = důležitý úkol v historii lidstva

– Klasické „paměťové“ instituce

- muzea (fyzické artefakty)
- archivy (nepublikovaný materiál)
- knihovny (publikovaný materiál)

Alexandrijská knihovna  
(295 př.n.l. – 642 ??)

– Základní přístupy k uchování materiálu

- konzervace

uchovávání původního artefaktu

(metoda: obnovování – refreshing)

- uchování

uchování informačního obsahu původního artefaktu, i při zániku originálu

(metoda: migrace)

## 1.1 Uchování informací



Národní archiv  
Praha, Chodov



Moravský zemský archiv  
Brno, Bohunice

<https://www.asb-portal.cz/wp-content/uploads/images/fotogaleria/>

MUNI  
I C S

# 1.1 Uchování informací



**Národní knihovna ČR**  
Praha, Klementinum  
(Barokní sál)

**Moravská zemská knihovna**  
Brno, Kounicova ul.



Foto : varadikamen.cz

fotografie je vlastnictvím firmy Kámen Vítězslav Váraří, o.p.s.

**MUNI**  
**I C S**

# 1.2 Nosiče informací a jejich životnost

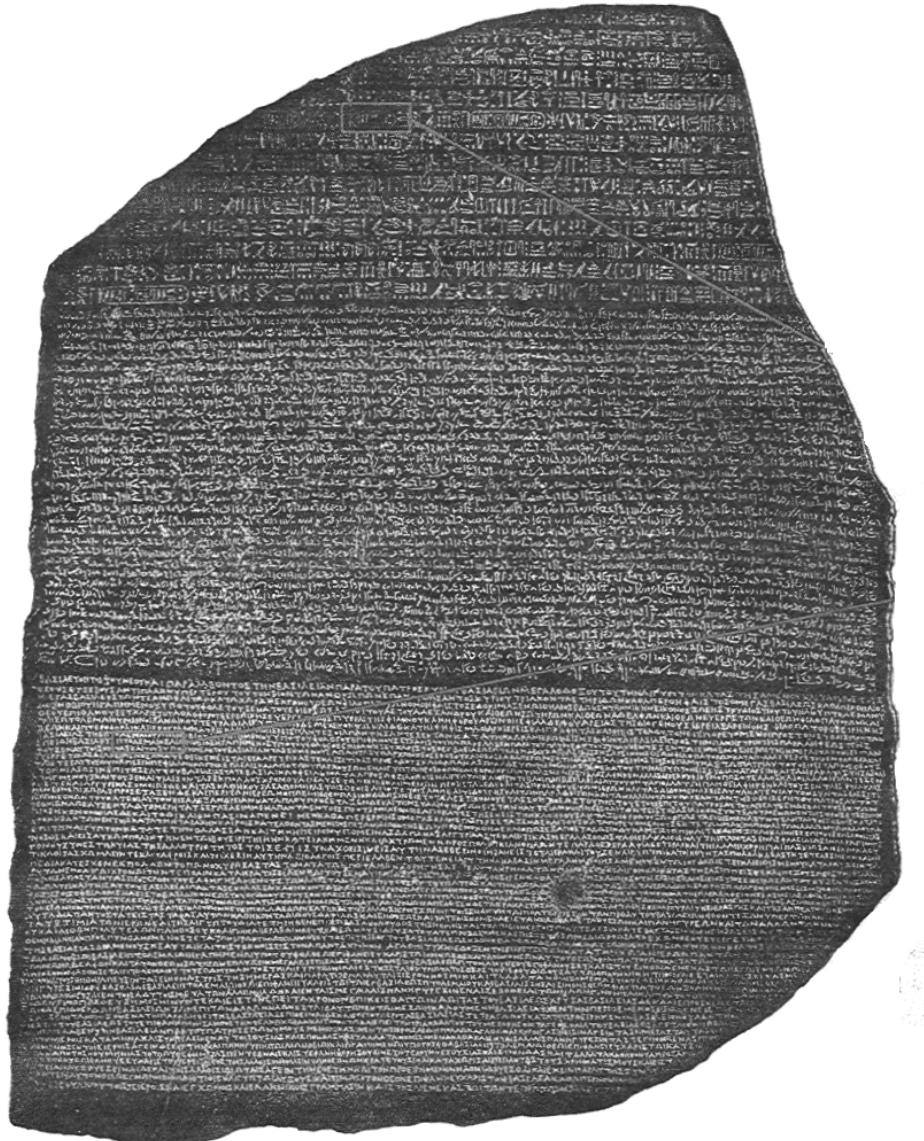
## Rozdílné zkušenosti

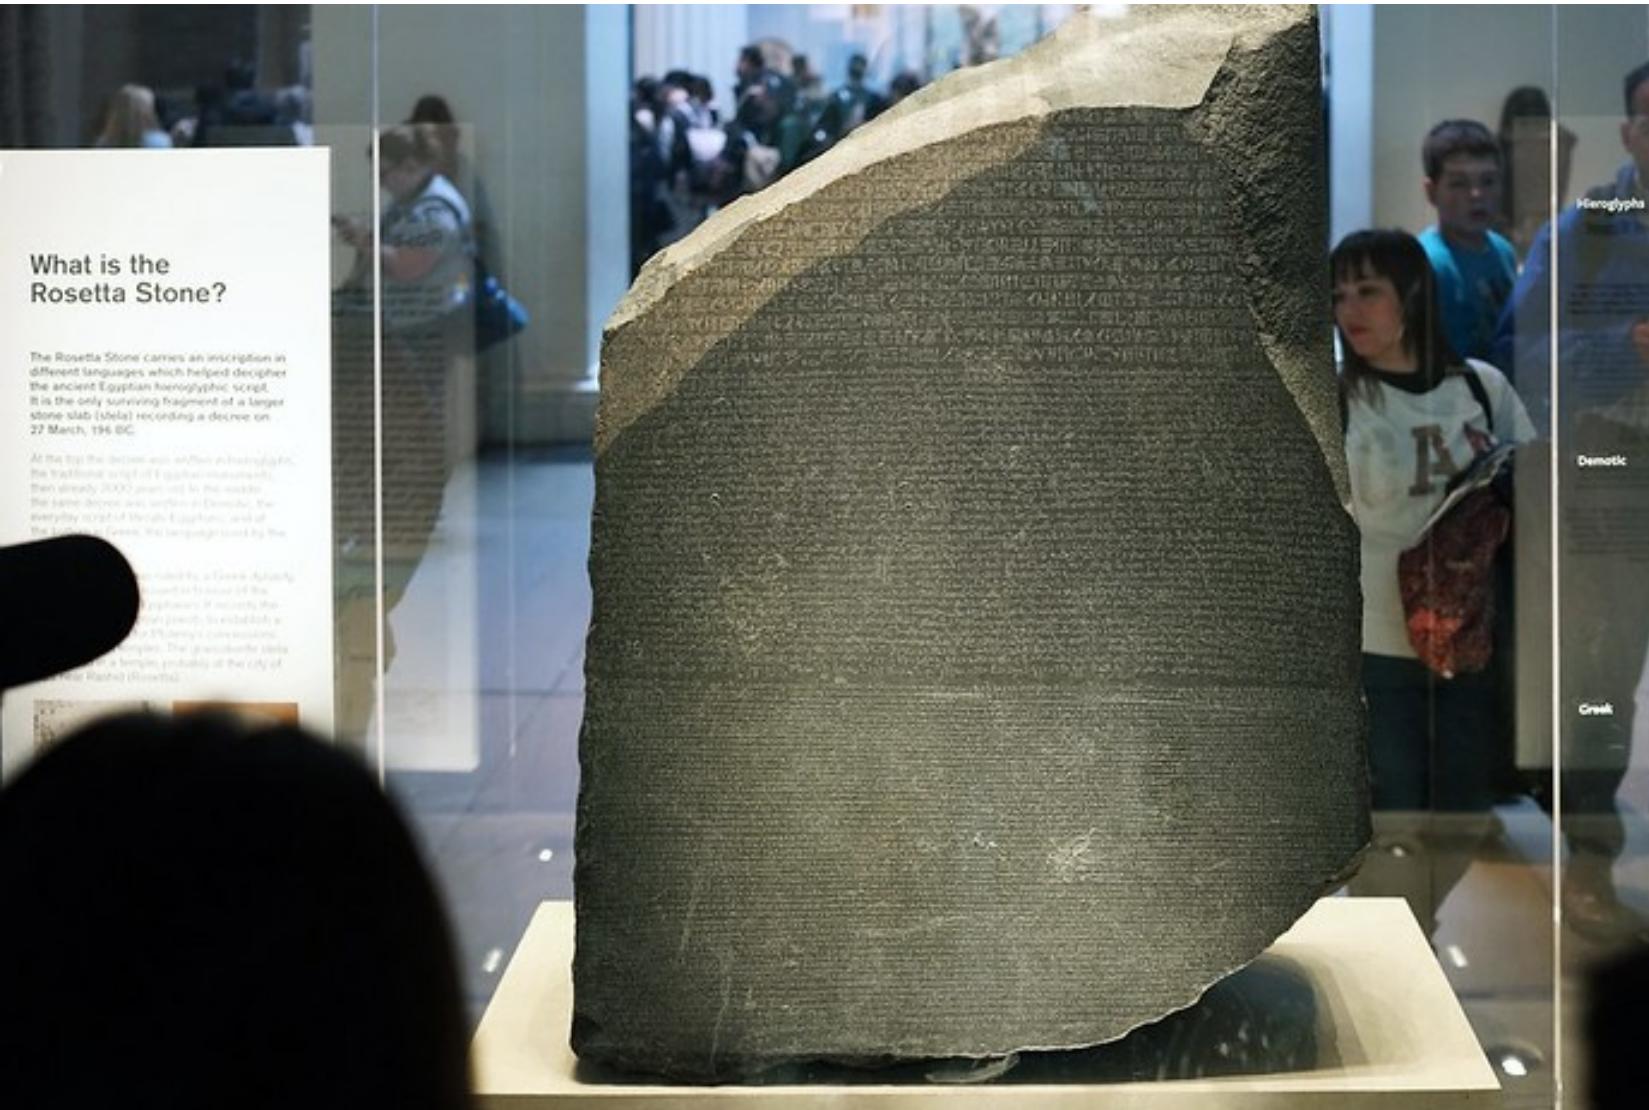
- starověké záznamy  
(kosti, kámen, hliněné tabulky, papyrus, pergamen, papír) ~ 4000 let
- fotografické dokumenty  
(fotografické desky, film, fotopapír) ~ 200 let (od 1839)
- audiovizuální záznamy  
(voskové a celuloidové válečky, šelakové desky, LP-desky, magnetické pásky) ~ 100 let
- elektronické dokumenty  
(magnetický záznam, optický záznam, SSD) ~ desítky let

**! Novější nosiče: větší kapacita, ale obvykle kratší životnost!**

## 1.3 Rosettská deska

- Objevena 1799 během Napoleonova tažení do Egypta
- Žulová stéla 114 x 71 cm
- **Text z r. 196 př. n. l.**  
ve třech různých zápisech:
  - egyptské hieroglyfy
  - egyptské démotické písmo
  - starořečtina
- Champollion:  
rozluštění hieroglyfů
- Londýn, British Museum





## What is the Rosetta Stone?

The Rosetta Stone carries an inscription in different languages which helped decipher the ancient Egyptian hieroglyphic script. It is the only surviving fragment of a larger stone slab (stele) recording a decree on 27 March, 196 BC.

At the top the decree was written in hieroglyphs, the traditional script of Egyptian monuments, then already 2000 years old. In the middle the same decree was written in Demotic, the everyday script of ancient Egypt, and at the bottom in Greek. What happened was this:

A new king, Ptolemy V, had been installed by a Greek dynasty that had come to power because of the decline of the Egyptian Empire. He needed the support of the Egyptian priests, so he included a clause in his decree in their language, Egyptian. The place where the stele was found is a temple probably at the city of Persepolis (Rosetta).

Hieroglyph

Demotic

Greek

## The key to Egyptian hieroglyphs

As soon as the Rosetta Stone was discovered, scholars realized that it might help decipher the mysterious Egyptian hieroglyphic script. The three inscriptions, which could be read, showed that each script on the Stone recorded the same decree.

In England and France an exceptional man used writing on hieroglyphic stelae to decipher Egyptian writing. Champollion died in 1832, but in 1850, Jean-François Champollion's son, Jean-Jacques Champollion, had already guessed that signs, or pictographs, in hieroglyphic inscriptions probably described true names. Champollion had also shown that the three scripts were written in the same language. This was the breakthrough moment that gave him the idea that some hieroglyphs were symbolic signs.

Curiously, Champollion's first guess was that the signs represented numbers.

Champollion's work was published in 1822, but Champollion died in 1832. Champollion was not the first to decipher the script and Champollion did not decipher all of the signs. Another French scholar, Jean-François Champollion, did this using the source of a German language book, the Rosetta Stone, and the knowledge of ancient Egyptian he had gained through his own work.

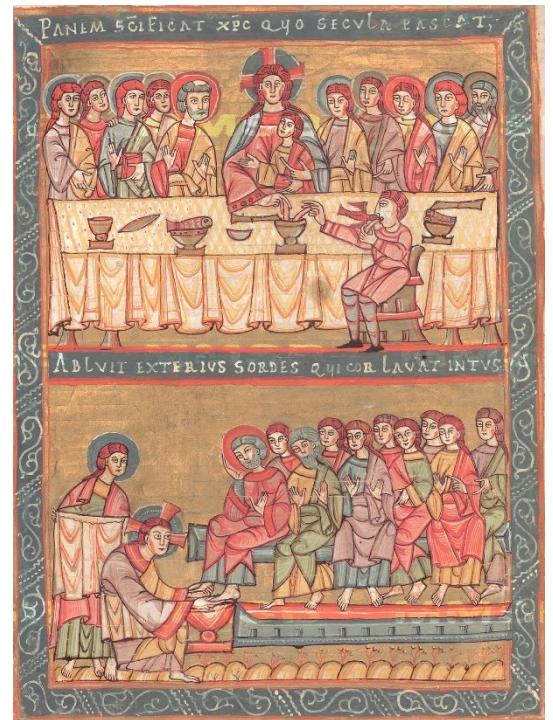
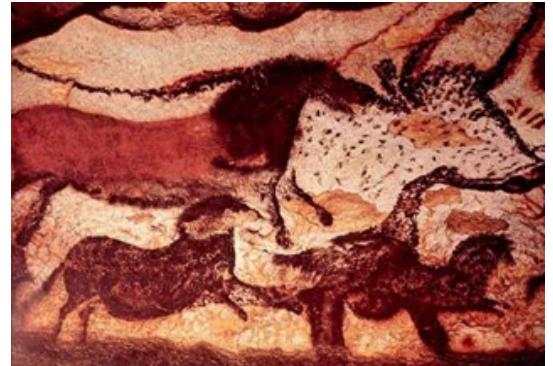
MUNI  
TCS

# 1.4 Hodně se dochovalo...

- Jeskynní kresby (Lascaux, Francie, 16 000 let)
- Babylónské hliněné destičky (4 000 let)
- Svitky od Mrtvého moře (cca 2 000 let)
- Starověké rukopisy a staré tisky (inkunábule)
- Antické písemnosti, ...
  - Ne vždy se dochoval originál (médium vs informace)  
(přepisy řeckých děl v klášterech – běh proti času)
  - „Archimedes codex“, Reviel Netz & William Noel, 2007

V ČR:

- **Vyšehradský kodex** (cca 1085, korunovace Vratislava II.)  
(nejstarší psaná památka, součást „korunovačních klenotů“)



# 1.5 Hodně se (nenávratně) ztratilo...

- Originální rukopisy řeckých učenců, různý starobylý materiál...

Ale i novodobé dokumenty:

- Značná část novin na kyselém papíru (konec 19. a poč. 20.st.)
- 50 % filmů ze 40. let
- Marvin Minsky (AI, 60. léta) versus Galileo Galilei (16 st.)
- Originální videozáznam z přistání Apollo 11 na Měsíci (19.7.1969)
- 20 % NASA Viking (první průzkum Marsu, 1976)
- První email (1971), obsah první webové stránky (1990)
- ...a mnohé, mnohé další...

**! Křehkost nosiče, chyby/opomenutí, vandalství, přírodní katastrofy, závislost na technologických, chybějících systém/infrastruktura**

## 2. Uchování informací v digitálním světě

## 2.1 Optimismus – a vystřízlivění

- **Digital information is forever. It doesn't deteriorate and requires little in the way of material media.**

Andy Grove, Intel Corp.

- **Digital information lasts forever – or five years, whichever comes first.**

Jeff Rothenberg, RAND, 1995

## 2.2 Dlouhodobé uchování

– **Knihovny:** dlouhodobě = staletí

– **Digitální technologie:** inovační cyklus cca 5 let

(v průměru po 5 letech je daná technologie zastaralá ☹)

- *The trouble with technological progress is that it seems to come at the expense of preservation.* (Ian H.Witten, How to Build a DL)
- *Computer technology is made for information processing, not for long term storage.* (M.Wettengel, NSR)

! Digitální technologie dlouhodobé uchování neusnadní, naopak spíše je komplikují!



DP Handbook

## 2.3 V čem je problém s digitální informací?

- Přístup a zobrazení digitální informace jsou závislé na technologiích (nestačí k tomu lidské smysly)
- Hrozby pro digitální informaci
  1. **Křehkost záznamového média**  
(krátká životnost, nízká odolnost vůči změnám)
  2. **Technologické zastarávání**  
(platformní závislost – nosič, formát, software, hardware)
- Další
  - Velký (trvale rostoucí) objem digitálních dat
  - Finanční nákladnost
  - Nezbytné expertní znalosti

## 2.4 Křehkost digitálního média



### – Krátká životnost

- Pevné disky – roky
- Zapisovatelná optická CD/DVD – roky
- Archivní magnetické pásky – desítky let
  - Čím vyšší hustota zápisu, tím hůře

### – Nízká odolnost proti změnám obsahu

- Snadnost provádění (ne)úmyslných změn
- Samovolné změny (bit rot)

Narušení integrity  
a autenticity

### – Rychlá obměna technologií

- Typy médií
- Čtecí zařízení
- Komunikační rozhraní, ovladače

! Běžná digitální média nejsou vhodná pro dlouhodobé uchování



Color photo by Jeff Rothenberg

## HOW TO SAVE YOUR DIGITAL WORK FOR THE POSTERITY?



## 2.5 Technologické zastarávání



DP Handbook

### – Formát dat

- způsob zakódování informace do binárního zápisu (doc, docx, xls, jpg, tif, mp3, ...)
- tisíce formátů, nově vznikající, otevřené/proprietary formáty, obsolete
- software nezbytný pro dekódování/zobrazení informace

### – Software

- Nástroje (textový procesor, tabulkový kalkulátor, videosoftware, DB-systém, poštovní klient)
- Aplikační software (IS MU, ekonomický systém, ... – interpretace dat v souborech)
- Operační systém (MS Windows, Apple OS, Linux, ...)

### – Hardware

- Počítač (IBM PC, Apple, superpočítač Cray, herní konzola, mobil)
- Periferní zařízení (vstupní, výstupní, ...)
- Síť

! Závislost dat na „správných“ technologiích je velký problém

## 2.6 Co je „Digital Preservation“



DP Handbook

### – Digital Preservation

The goal of digital preservation is the accurate rendering of authenticated content over time.

Digitální uchování kombinuje postupy, strategie a akce zajišťující přesnou reprodukci ověřeného obsahu v průběhu času, a to s ohledem na případná selhání záznamových médií a na probíhající technologické změny.

### – Dvě úrovně

- **Bit-level preservation** (dostupnost digitálních dat)
- **Logical preservation** (technologické změny + porozumění obsahu)

Terminologie: Digital Preservation (DP), LongTerm Preservation (LTP)

## 2.7 Ochranné strategie

- a) **Nosič** (uchování digitálních dat – bitová ochrana)
  - oživování a replikace
  - nový formát
- b) **Informace** (digitální obsah a jeho význam – logická ochrana)
  - uchování technologického prostředí
    - technologické muzeum
    - emulace
  - překonání technologické zastaralosti
    - migrace
    - encapsulation

! V praxi: kombinace přístupů (+ digitální archeologie, když vše selže)

## 2.8 Aspekty digitální ochrany



- Digitální ochrana zdaleka není jen problém technologický
- Ne izolovaný proces, součást širšího digitálního inf. prostředí
- Integrální součást celého životního cyklu digitální informace  
(nutná podpora od CMS – content management systémů)
- Součást běžného každodenního fungování organizace  
(ne kampaňovitost jako u analogových inf. zdrojů)
- Nejfektivnější když je pre-emptivní  
(problematická ex-post záchrana až při vzniku potíží)
- Nutná spolupráce různých subjektů  
(nakladatelé, paměťové instituce, komerční specializované firmy, instituce, jednotlivci)
- Je dražší než u analogových zdrojů  
(ale zatím neumíme cenu dlouhodobé archivace vyčíslit)

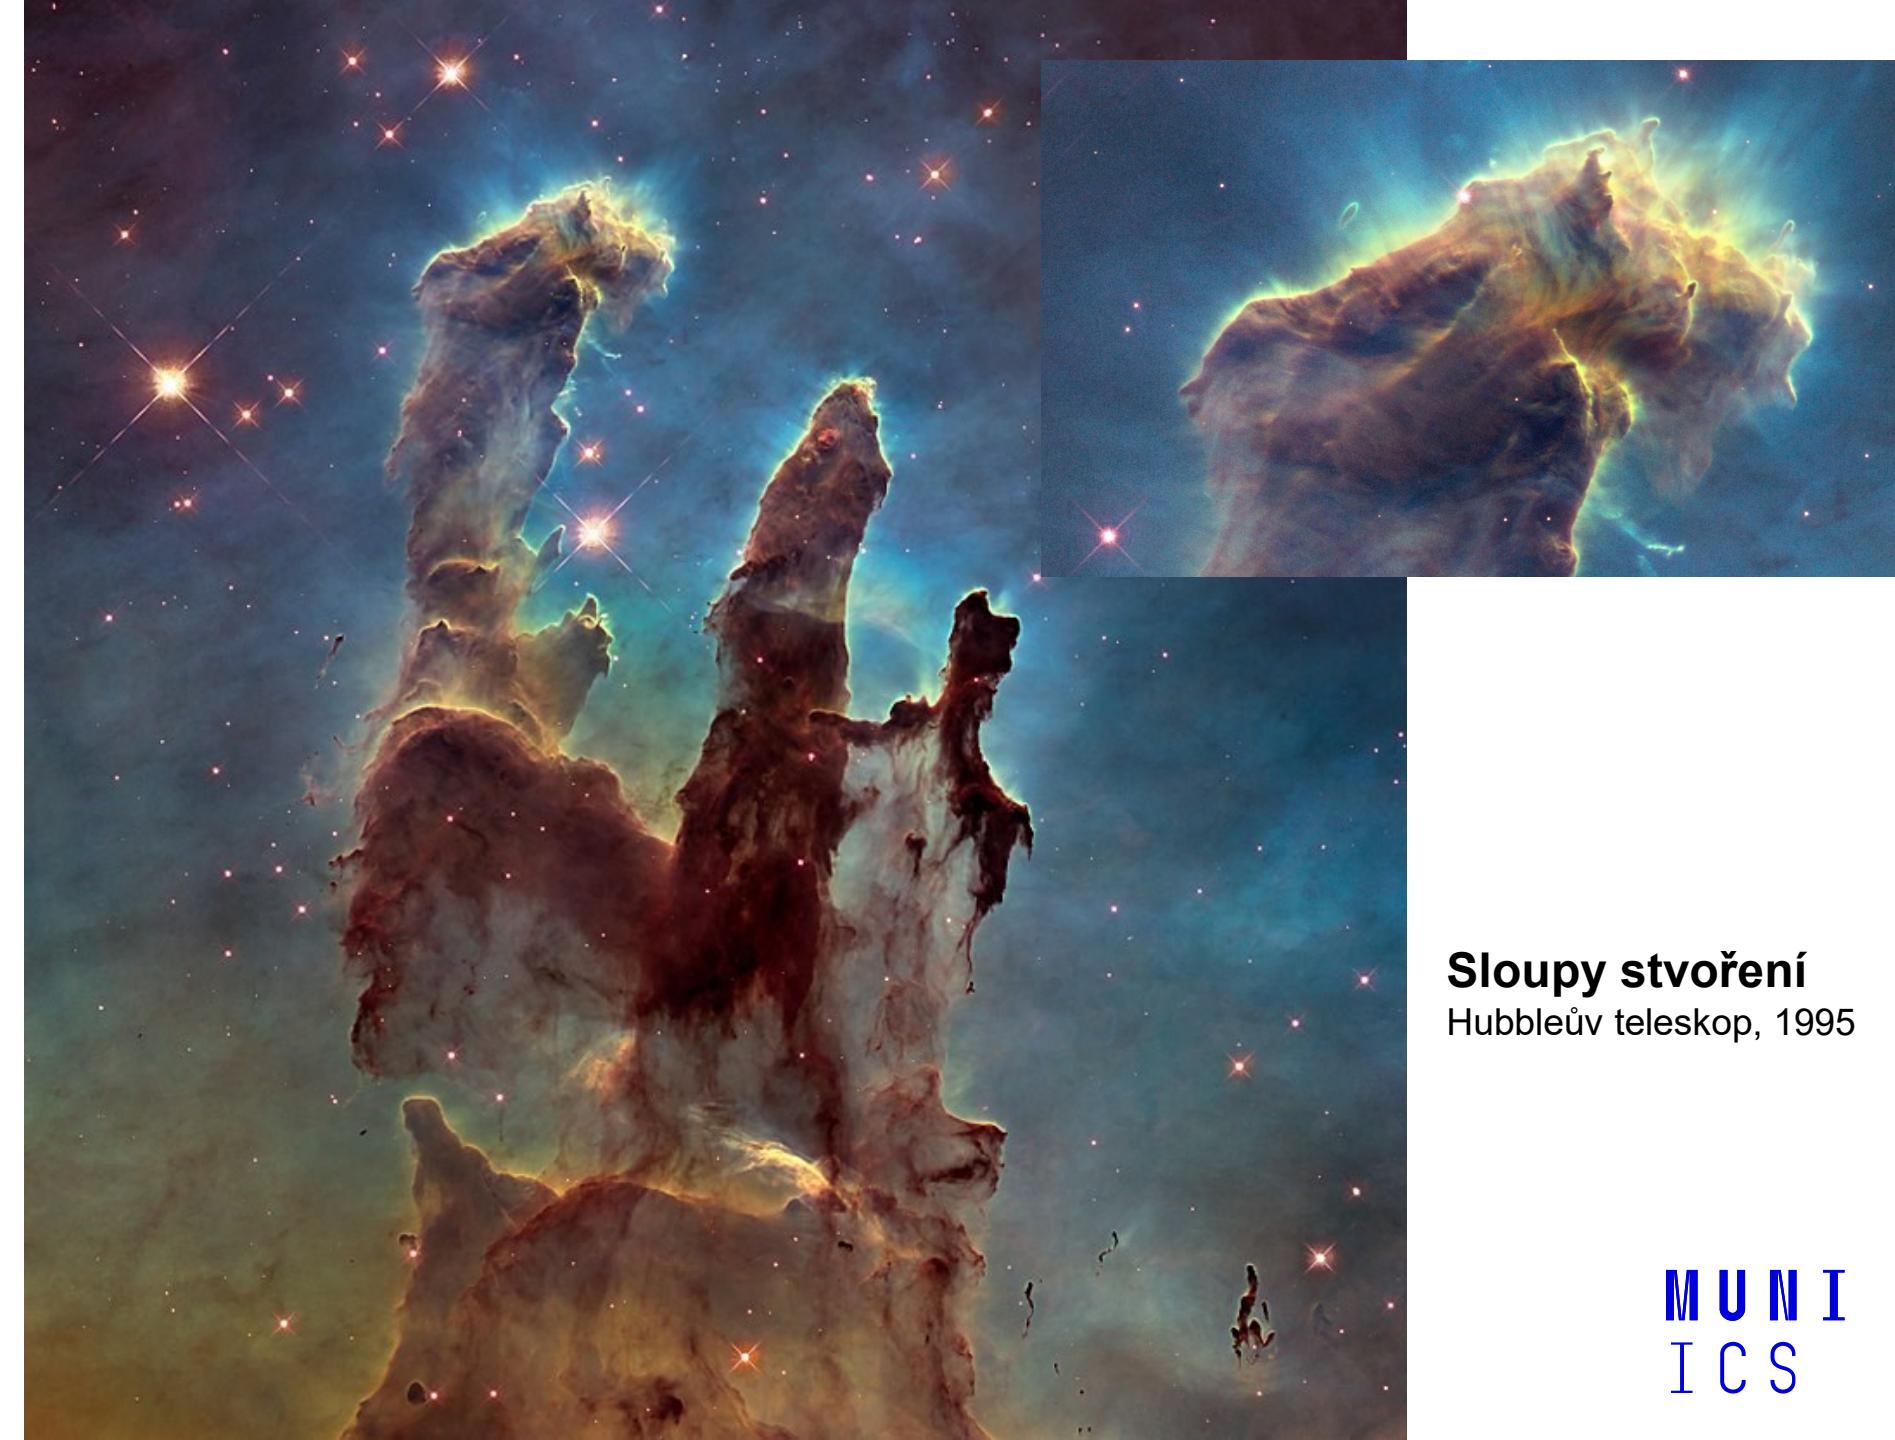
# Pro zájemce o další informace

**Digital Preservation Handbook**  
2nd Edition  
<https://www.dpconline.org/handbook>  
Digital Preservation Coalition © 2015



Illustration by Jørgen Stamp digitalbevaring.dk CC BY 2.5 Denmark

## 3. Digitální archiv



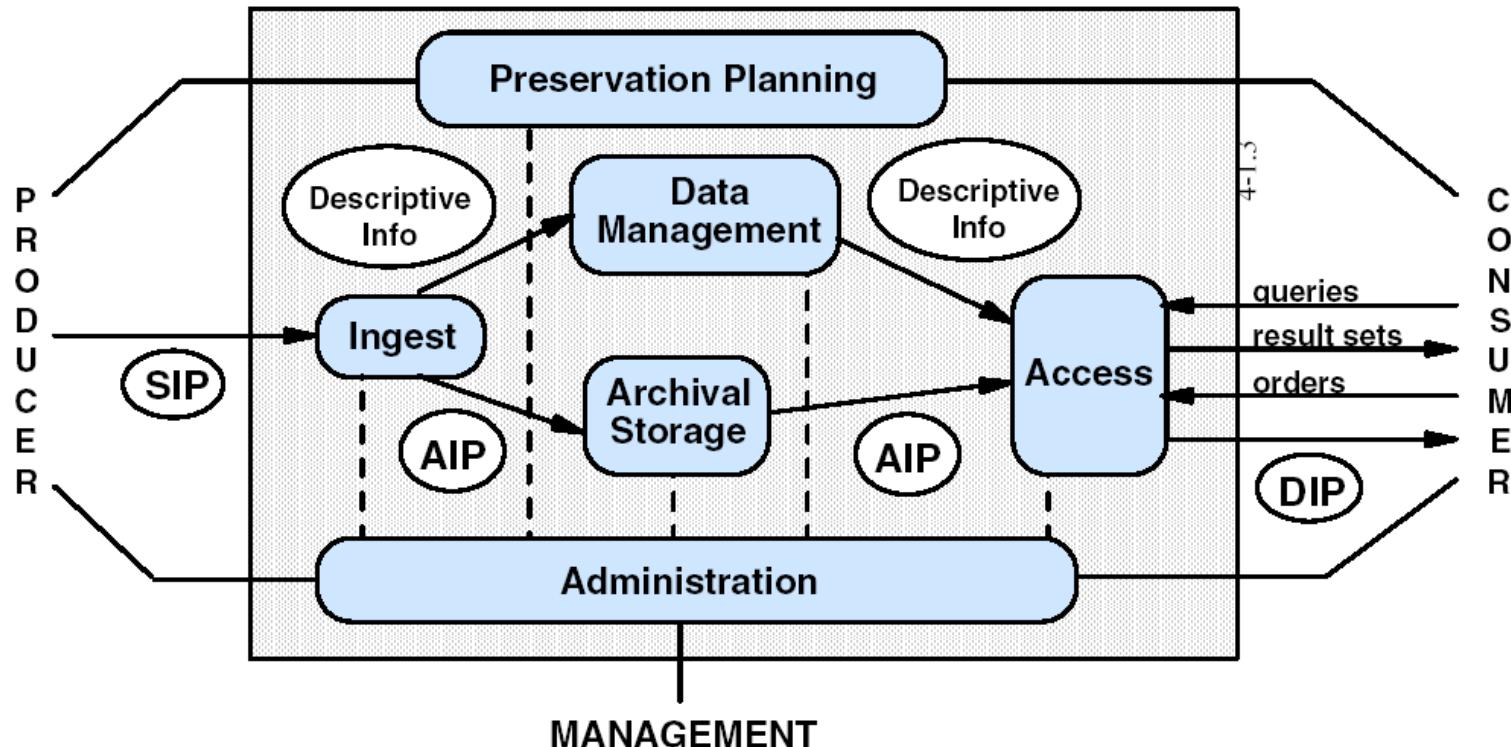
**Sloupy stvoření**  
Hubbleův teleskop, 1995

MUNI  
ICS

## 3.1 Systémová ochrana digitálních informací

- Digitální uchování je složité – jak to řešit „systémově“?
- Koncepce standardizovaného „Digitálního archivu“
- Podnět od kosmických agentur (NASA, ESA, ...) (obrovské objemy dat, spousta negativních zkušeností)
- 2002: **OAIS** – Open Archival Information System
  - Referenční model pro dlouhodobý Digitální archiv
  - ISO standard (od 2014 i ČSN)
- Pro naše potřeby příliš odborné/obsáhlé
- ...ale pár postřehů i pro osobní inspiraci...

## 3.2 OAIS



- **SIP** – Submittion Information Package
- **AIP** – Archival Information Package
- **DIP** – Dissemination Information Package

# Papírový archiv



<https://www.ceskatelevize.cz/porady/1142743803-reporteri-ct/212452801240049/0/44211-archivalie-zidovskych-obcanu-na-ceskem-sternberku/>

## Digitální „archiv“ (superpočítač Frontera)



<https://news.utexas.edu/2019/06/19/ut-austins-frontera-named-5th-fastest-computer-in-the-world/>

### 3.3 Důvěryhodnost Digitálního archivu

**Důvěryhodnost** – prokázaná schopnost úložiště zachovat digitální dokumenty v dlouhodobém horizontu přístupné a použitelné

Různé stupně jak prokázat důvěryhodnost (certifikace)

- Základní certifikace  
(Data Seal of Approval, 16 guidelines, self-assessment)
- Rozšířená certifikace  
(self-audit podle ISO 16363)
- Formální certifikace  
(externí nezávislý audit dle ISO 16363 certifikovanou autoritou)
- ISO 16363:2012 – **Audit and certification of trustworthy digital repositories**



### 3. ....a osobní archivace

## 3.4 Osobní digitální archivace

- Má smysl starat se „rozumně“ o svá osobní digitální data
- Library of Congress: <https://digitalpreservation.gov/personalarchiving/>
- **Pár tipů:**
  - Zálohovat: alespoň 2 zálohy na separátních médiích
  - Zálohy uchovávat na vzdálených lokalitách
  - Média označit a držet v bezpečných místech (jako důležité dokumenty)
  - Namátkově ověřit čitelnost médií
  - Alespoň každých 5 let vytvořit nová záložní média
  - Systematicky roztrídit své osobní sbírky (fotografie, audio, video, e-mail, osobní)
  - Vybrat nejdůležitější materiály, rozumně popsat (jména souborů, metadata)
  - Používat rozšířené (otevřené) formáty, důležitá data migrovat na nové

### ! Další? Osobní zkušenosti?

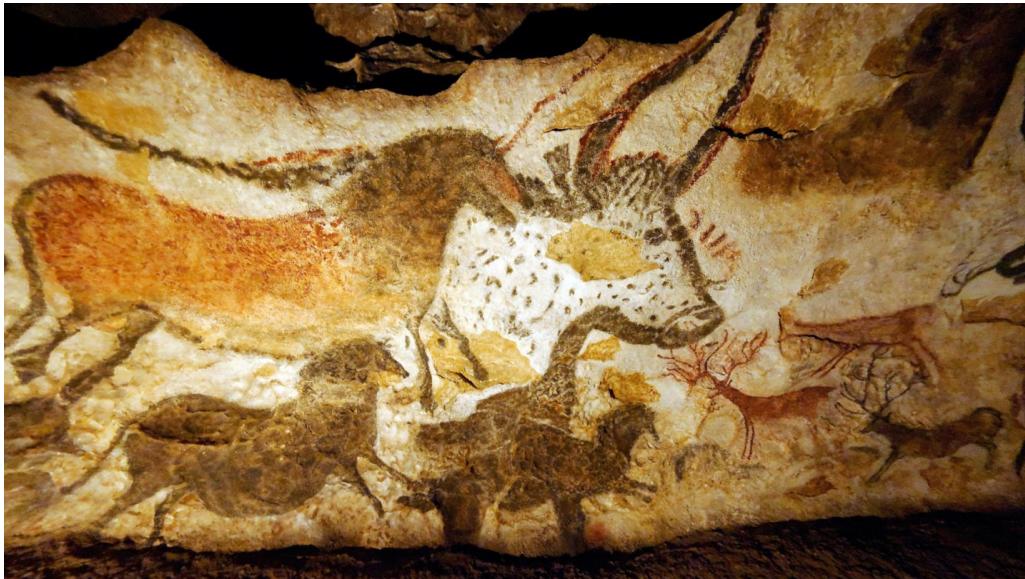
## 3.5 Chmurné perspektivy?

- Velké množství digitálních informací již dnes nenávratně ztraceno
- Trvale roste množství informací existující pouze v digitální podobě
- Stále se rozšiřuje množství formátů dokumentů a médií
- Informační technologie zastarávají velmi rychle
- Rychlé zastarávání fyzických paměťových nosičů
- Při vytváření digitálních zdrojů není počítáno s náklady na archivaci
- Snižování finančních zdrojů pro knihovny a archivy
- Nesmyslné ochranářské trendy omezující dostupnost info (právo být zapomenut)

„There is, at present, no way to guarantee the preservation of digital information. The first line of defense against loss of valuable digital information rests with the creators, providers, and owner of that information. It's every man for himself.“

U.S. Commission on Preservation and Access.  
Final report of a Task Force on the Archiving of Digital Information. 1996

## 3.5 Chmurné perspektivy?



Analog objects can survive with minimal care for centuries, but no electronic format can hope to persist more than a short while without careful (and perhaps expensive) intervention. There will be no digital equivalent of the Lascaux cave paintings, Mayan stone scripts, Dead Sea scrolls, or other kinds of rediscovered ancient knowledge.

Building Preservation Partnership. The LoC NDIIP Program

## 4. The Long Now

## 4.1 The Long Now

"When I was a child, people used to talk about what would happen by the year 2000. For the next thirty years they kept talking about what would happen by the year 2000, and now no one mentions a future date at all. The future has been shrinking by one year per year for my entire life. I think it is time for us to start a long-term project that gets people thinking past the mental barrier of an ever-shortening future.

I would like to propose a large (think Stonehenge) mechanical clock, powered by seasonal temperature changes. It ticks once a year, bongs once a century, and the cuckoo comes out every millennium."

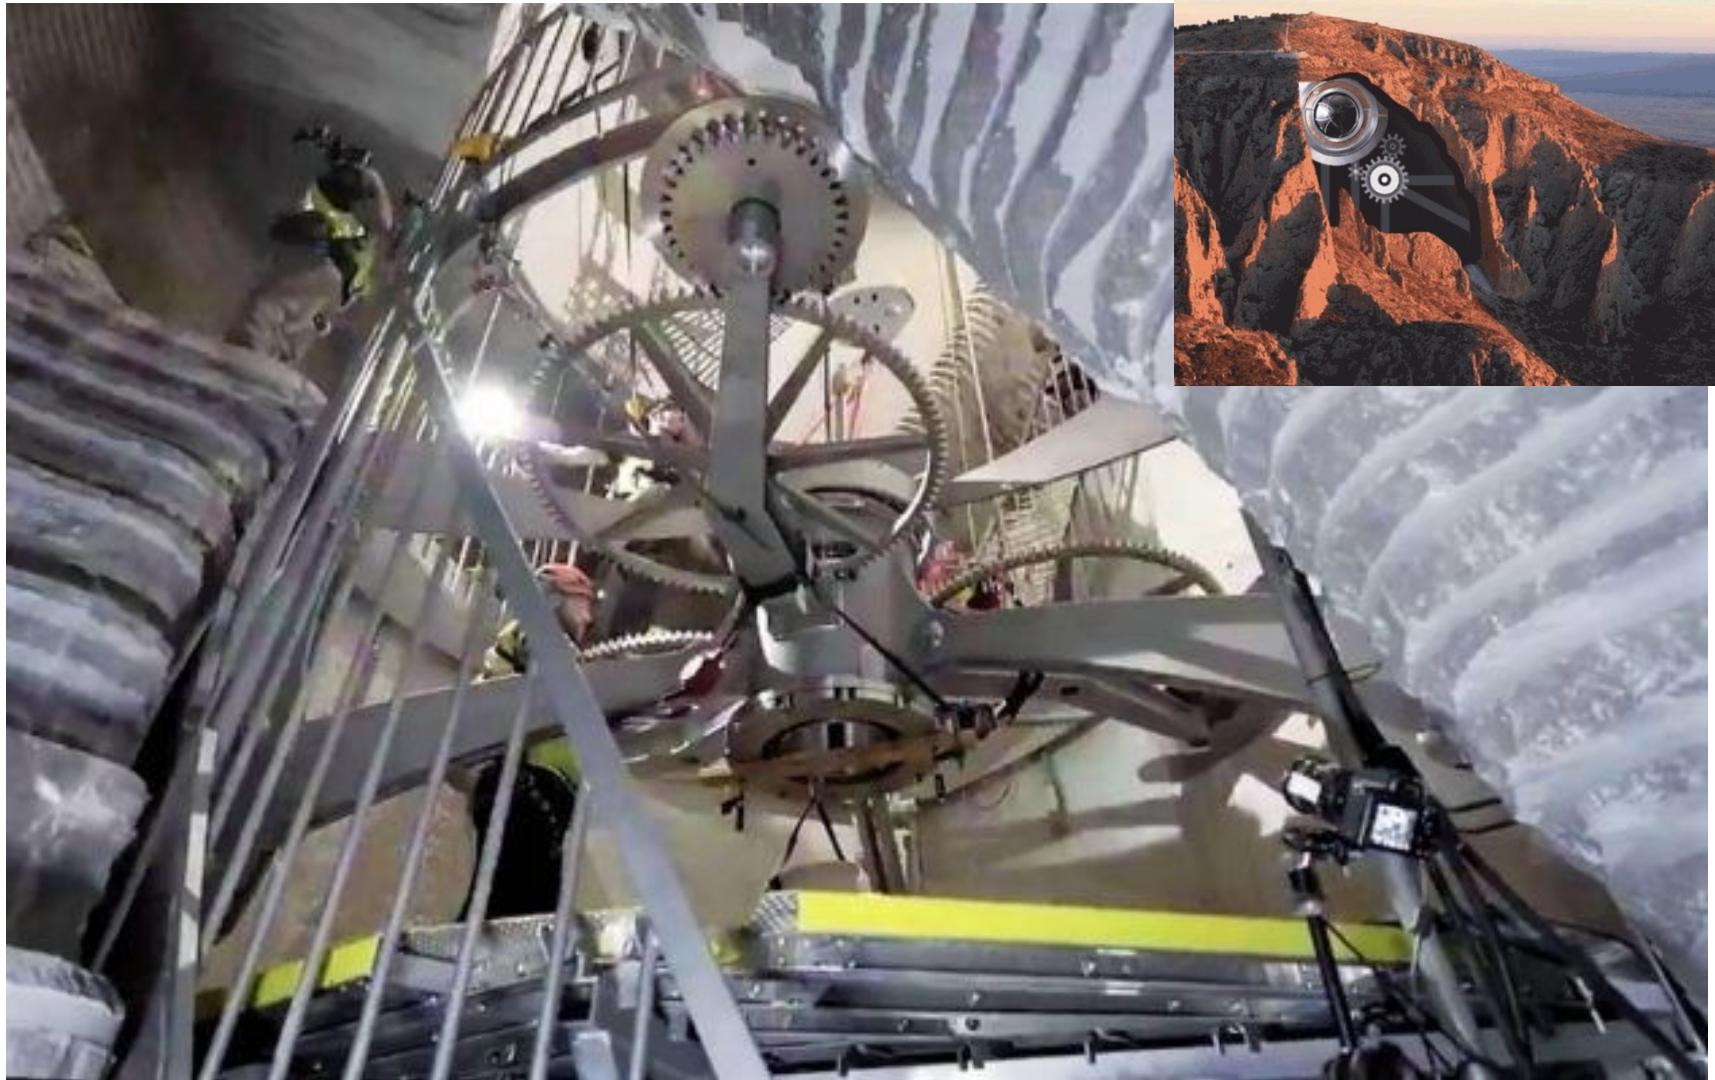
**Daniel Hillis, The Long Now Foundation**  
<http://www.longnow.org>

The Long Now Foundation was established in 01996 *to creatively foster long-term thinking and responsibility in the framework of the next 10,000 years.*

## 4.2 The 10.000 year Clock



- Ikonický projekt pro dlouhodobé uvažování
- Postavit mechanické hodiny (udržovatelné „technologiemi doby bronzové“) které přežijí a budou fungovat 10 tisíc let!
- **Výzvy:**
  - Jaké použít materiály, technologie, aby vydržely
  - Čím hodiny pohánět
  - Jak zajistit správné zobrazování času po tak dlouhou dobu
  - Jak prezentovat čas/datum na hodinách budoucím uživatelům
  - Ochrana proti vandalství (aby lidé hodiny sami nezničili), ...
- 01999 prototyp: 28bitový mechanický počítač (Science Museum, Londýn)
- Zakoupen pozemek v poušti v Texasu
- Výstavba hodin ve skále (výška 200 stop)



Workers install the 10,000 Year Clock inside an underground chamber in Texas. (Long Now Foundation)

## 4.3 Rosetta Disc

- Dlouhodobý lingvistický archív a překladatelský nástroj pro obnovu jazyků ztracených v hluboké budoucnosti
- Inspirace Rosettskou deskou (rozluštění egyptských hieroglyfů)
- Paměťové médium: 3“ niklová deska, litograf. nano-technologií vyrytý analogový text a obrázky (až 200.000 stran, životnost 2K-10K let)
  - Archiv (Languages of the World)
  - Cíl: lingvisticky podrobně zdokumentovat 7.000 současných jazyků světa
  - Pro každý jazyk stejná struktura informací:  
podrobný lingvistický popis jazyka, fonologie, gramatika, stejné texty  
(Genesis, OSN – Deklarace lidských práv), mapy a další
  - Aktuální stav: 70.000 stran o 2.500 jazycích

### – Rosettský disk v1

- 13.000 stran informací o 1.500 jazycích
- čitelné při 650násobném zvětšení
- dar při 10 000 Membership  
(předávat z pokolení na pokolení)



MUNI  
TCS

# Diskuse