

webarchiv.cz

Web archive of National Library of the Czech Republic

Marie Haškovcová, Zdenko Vozár

W

A

webarchiv.cz

today

- digital library which preserves websites for future generations
- Czech web resources (territory, language, authorship or topic/content) not only within the Czech domain
- more than 400 TB of data
- 4 people + IT support

Webarchiv

památník českého internetu, *vice*

hleděte „webarchiv.cz“ nebo „webarchiv“

Klimatická změna



Environmentální témata jsou důležitou součástí celospolečenské debaty o budoucí existenci Země. Problematika změny klimatu je natolik zásadní, že jsme se rozhodli zpracovat tematickou kolekci webových stránek s názvem [Klimatická změna](#). Naleznete zde stránky vědeckých institucí, odborné veřejnosti, státních subjektů, občanských iniciativ nebo médií. Více o kolekci se můžete dočíst v [e-zpravodaji NK](#).

První zdroj, který jsme vybrali, je web [Českého hydrometeorologického ústavu](#), který byl zřízen Ministerstvem životního prostředí ČR jako ústřední orgán zodpovědný za poskytování odborných informací a služeb v oboru kvality ovzduší, meteorologie, klimatologie a hydrologie. V našem archivu naleznete nejstarší archivní kopie z roku 2002. Druhým zdrojem jsou stránky organizace [Arnika](#), která se komplexně věnuje ochraně životního prostředí.

Výběr z katalogu stránek, [vice v oborovém třídění](#)

Český hydrometeorologický ústav

Informace o hydrometeorologickém ústavu, jeho historii, součástí aktuální stav počasí, hydrologické situace, stav ovzduší, monitoring sucha a historická data z meteorologie a klimatologie.
Vydavatel: Český hydrometeorologický ústav

[meteorologická pozorování](#),
[meteorologie](#), [hydrologie](#),
[meteorologické stanice](#),
[meteorologická měření](#),
[klimatologie](#)

Arnika

Nezisková organizace usilující o zlepšení životního prostředí. Informace o aktivitách sdružení, výroční zprávy a fotogalerie z akcí
Vydavatel: Arnika

[ochrana životního prostředí](#),
[ochránci přírody](#), [ekologie](#),
[ochrana přírody](#), [toxický odpad](#),
[mokřady](#), [Arnika \(organizace\)](#),
[Česko](#)

[Webarchiv](#) k 21.11.2021 obsahuje

409 TB

dat. První dokument byl archivován 3. 9. 2001.

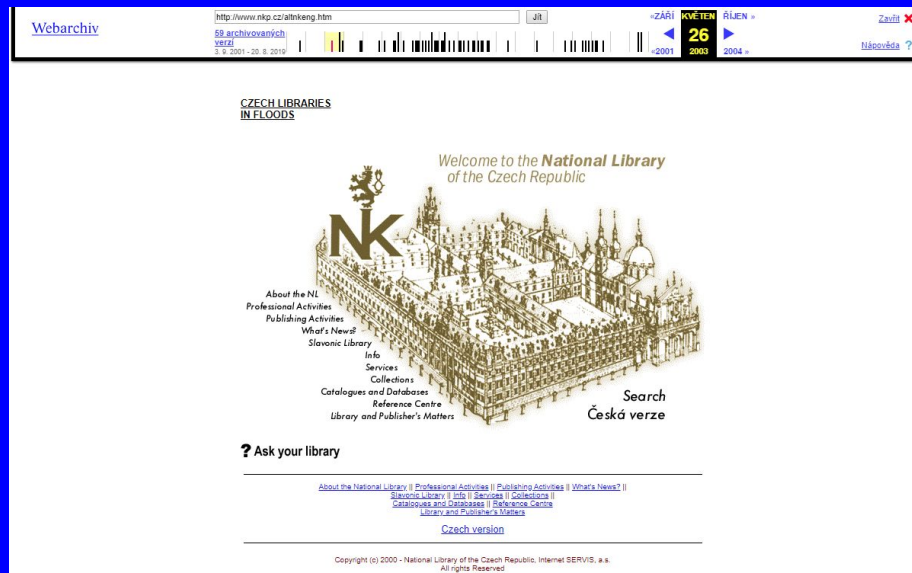
Celkem jsme s autory uzavřeli

4404

smluv. Poslední aktuální smlouvy:

[Cesta vlakem](#),
[Elektronická kultura a sémiotika](#),
[Přírodovědecká fakulta](#)
[Univerzity Karlovy](#),
[Jana Bernartová](#),
[Pražské centrum židovských studií](#)

- 2000 – project of National Library of the CR, Moravian Library and Masaryk University
- 2001 – first archived website
- 2005 – regular harvesting of content
- 2007 – joining the IIPC – International Internet Preservation Consortium
- 2020 – 20 years anniversary



- **Copyright act** – Library License allows the National Library of the CR to make a reproduction of a work for its own archiving and conservation purposes
- **Online access** – based on contract with publishers or on Creative Commons licence, the entire archive is available in the library building

less than **0,4 %** of the content is available outside the library building

- **Legal deposit act** – does not cover born digital documents
- **Directive of the European Parliament and of the Council on Copyright in the Digital Single Market** – has not yet been implemented in Czech legislation

webarchiv.cz

collection policy

- **Comprehensive harvests**
 - contract with czech domain provider CZ.NIC
 - once or twice a year crawl of the whole .cz domain
 - 1,4 million of second order domains / domain.cz
- **Selective harvests**
 - selective approach, curated resources
- **Topic collections**
 - collections of resources related to certain event or topic

webarchiv.cz

selective harvest

- selective approach
- resources with historical, scientific or cultural value
- online access – contract or CC, more than 5000 archived websites with online access
- crawled periodically
- cataloging records in Czech national bibliography
- catalog - resources sorted by topics according to the conspectus method

[home](#) [about Webarchiv](#) [browse](#) [topic collections](#) [nominate a site](#)



CZ EN

Browse the [Webarchiv](#) by subject

List of a contracted websites by classification system:

[Vše](#) 5317 / [Agriculture](#) 238 / [Anthropology](#) 237 / [Art and architecture](#) 369 / [Beletry](#) 37 / [Biological sciences](#) 295 / [Business and economics](#) 407 / [Chemistry](#) 50 / [Children's literature](#) 7 / [Computer sciences](#) 201 / [Education](#) 237 / [Engineering and technology](#) 301 / [Geography and earth sciences](#) 433 / [History and auxiliary sciences](#) 325 / [Language, linguistics and literature](#) 280 / [Law](#) 154 / [Library science, generalities and references](#) 316 / [Mathematics](#) 45 / [Medicine](#) 302 / [Music](#) 157 / [Performing arts](#) 258 / [Philosophy and religion](#) 255 / [Physical education and recreation](#) 226 / [Physical sciences](#) 138 / [Political science](#) 390 / [Psychology](#) 86 / [Sociology](#) 330

Art and architecture /

[Vše](#) 369 / [Architecture](#) 57 / [Arts](#) 76 / [Civic and landscape art](#) 22 / [Drawing and decorative arts](#) 16 / [Fine and decorative arts](#) 103 / [Graphic arts, printmaking and prints](#) 14 / [Painting and paintings](#) 13 / [Photography and photographs](#) 46 / [Plastic art - sculpture](#) 17

Display: [visual](#), [text](#)



1415 Bařův institut



abed : art brut



Action galleries



[Adolf Wölfli : stvořitel universa](#)



[Akademie vřtvárných umění v Praze](#)



Alice Nikitinová



[Alřova jiřhoeská galerie v Hlubokě nad Vřtavou : AIG](#)



Amatérská obrazárna



[Archeologické oddělení NPU Praha](#)



Architecture week



Archiweb.cz



ARSkontakt

- library system **Aleph**
- format for Bibliographic Data **MARC 21** (machine-readable cataloging)
- **RDA** (Resource Description and Access) - standard for descriptive cataloging providing instructions and guidelines on formulating bibliographic data, since 2015
- **WA-KAT** – cataloging tool, an application we developed for cataloging web resources, available at: <https://kat.webarchiv.cz/>
- **Cataloging manual** - recommendations on how to catalog a web resources <https://webarchivcz.github.io/katalogizacni-manual/>

webarchiv.cz

topic collections

collections of resources related to certain event or topic
more in depth capture of the topic in electronic resources

current events

- planned: elections, anniversaries
- unexpected: current political events, natural disasters

long-term collections – continuous harvesting

- Charles University, Czech media (harvested on a daily basis)

collaboration with IIPC (Olympics and Paralympics, Climate Change, Novel Coronavirus – COVID-19)

Webarchiv preserves Czech web

For basic informations about Webarchiv visit our [introduction](#)

Topic collections

[Display: visual](#), [text](#)

Topic collections are collections of resources which are related to certain event or topic.



LARP

A Live action role-playing game (LARP) is a type of game, where the players act out the actions of the character they are playing as, usually in costume. The plot ...



Second-hand bookshops

Second hand bookshops and their databases creates rich source of book covers. Also these bookshops represent historical document about book market and production.



Dungeons & Dragons

Dungeons & Dragons is a fantasy tabletop role-playing game (RPG). D&D's publication is commonly recognized as the beginning of modern role-playing games and the role-playing game industry. D&D departs from ...



Web Directories

A web directory or link directory is an online list or catalog of websites. A web directory includes entries about websites, including links to those websites, organized into categories and ...




10 websites for the eternity

We launched a blog, where we post a series called 10 websites for eternity, where personalities from various fields share a list of Czech websites they can not imagine life ...



Fake news websites

The Fake news websites topic collection contains over 50 websites which operates on Czech internet. The sources of Fake news seeds and websites that deal with fact-checking are included in ...



Senate and Municipal Election 2020

The collection of web resources focuses on the municipal elections and the elections to the Senate held on October 5 and 6 and October 9 and 10. Collection includes web ...



COVID-19

Coronavirus COVID-19 makes the world go round. The ongoing topic collection monitors its presence and impacts from different points of view. It seeks to capture government resources, topic websites ...



Czech media

The collection contains a selection of Czech media websites intended for continuous harvesting. It includes public and private media, mass and independent media. Due to rapid changes on news sites, ...



Prague City Hall



Jan Amos Comenius



30th Anniversary of the Velvet Revolution

The screenshot shows the 'Seeder' dashboard with a dark header bar containing 'Languages' and 'marie' dropdowns, and a search box. A left sidebar lists navigation options: Dashboard, Search, Sources, Harvests, Publishers, Contracts, Blacklists, Quality assurance, Topic collections, News, Search logs, Github, Bug report, Read the docs, Whitelist, and Harvests urls. The main content area is titled 'Dashboard' and features several panels:

- Sources needing QA (173):** Acta academica karviensia, Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis, Ararauna.cz : O papoušcích, jejich chovu a legislativě, Art for Good, Art has no history, Asociace sdružení pro ochranu a rozvoj kulturního dědictví ČR, Atelierforart.cz, Bezpečnostní management v regionech, Bioprospect, British Council Česká republika.
- Contracts in negotiation (8):** Malacologica Bohemoslovaca, Pojistné rozpravy : pojistněteoretický bulletin, Český lid, Hudební stránky, Studia Kinaanthropologica, Petr Malina, Český svaz neslyšících sportovců, The Messenger.
- Sources that need technical review (6):** Headliner, Historie - Otázky - Problémy, Mathematica Bohemica, Mezinárodní konference Historie matematiky, Ústav evropské etnologie, Veterinární-lékaři.cz.
- Sources curating (41):** adamquick.com, Africké fialky: internetová příručka o jejich pěstování, množení a typologii, Agentura pro podnikání a inovace, Agosto Foundation, Bytová správa Ministerstva vnitra, CryptoSvět, Dokoupil.estranky.cz, Etern, Ethnoentomology, Folk time.
- Contracts without scheduled communication (8):** Malacologica Bohemoslovaca, Pojistné rozpravy : pojistněteoretický bulletin, Český lid, Hudební stránky, Studia Kinaanthropologica, Petr Malina, Český svaz neslyšících sportovců.
- Open voting rounds (15):** Acta Moraviae (0), Upcycling.cz : Staré věci s novým využitím (0), Czech Hospitality and Tourism Papers (0), Didaktické studie (0), Studia Romanistica (0).
- Source without Aleph ID (52):** Acta academica karviensia, Ararauna.cz : O papoušcích, jejich chovu a legislativě.
- Voting rounds you manage (44):** Klinická biochemie a metabolismus (0), Tiskárna Ministerstva vnitra (1), OLYMP : centrum sportu Ministerstva vnitra (1).

webarchiv.cz

cooperation & research

- **archiving specific resources**
 - Czech Language Institute of the Czech Academy of Sciences – Czech Literary Internet
- **methodological support for building own archives**
 - Office for supervision of economic affairs of political parties and political movements
- **IIPC, University Library in Bratislava**
 - collaborative collections
- **Development of centralized interface for extracting big data from web archives**
 - ongoing research project, making data available to the research community
(NL CR, University of West Bohemia – Faculty of Applied Sciences, The Department of Cybernetics, Institute of Sociology of the Czech Academy of Sciences)

[webarchiv.cz](https://www.webarchiv.cz)

user generated seeds

Let's get [Webarchived!](#)

If you look for our certificate or our banners or logo visit [this page](#)

[Nominate a website](#) / [Creative Commons](#) / [Selective harvests](#) / [FAQ](#)

Nominate a website

URL

I can act for these sources

Source with Creative Commons license

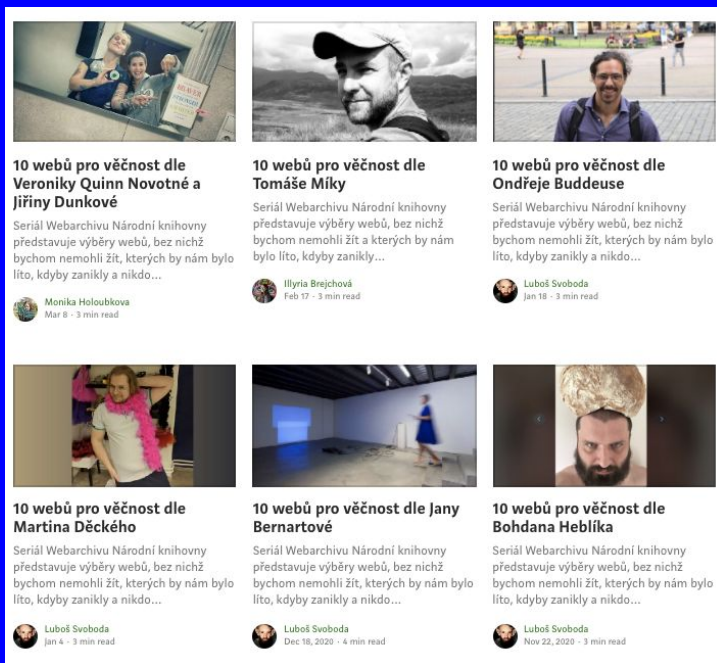
Name

Contact e-mail

Note

<https://www.webarchiv.cz/en/add>

we accept proposals for resources for archiving



10 webů pro věčnost dle Veroniky Quinn Novotné a Jiřiny Dunkové
Seriál Webarchivu Národní knihovny představuje výběry webů, bez nichž bychom nemohli žít, kterých by nám bylo líto, kdyby zanikly a nikdo...

10 webů pro věčnost dle Tomáše Míky
Seriál Webarchivu Národní knihovny představuje výběry webů, bez nichž bychom nemohli žít a kterých by nám bylo líto, kdyby zanikly...

10 webů pro věčnost dle Ondřeje Buddeuse
Seriál Webarchivu Národní knihovny představuje výběry webů, bez nichž bychom nemohli žít, kterých by nám bylo líto, kdyby zanikly a nikdo...

10 webů pro věčnost dle Martina Děckého
Seriál Webarchivu Národní knihovny představuje výběry webů, bez nichž bychom nemohli žít, kterých by nám bylo líto, kdyby zanikly a nikdo...

10 webů pro věčnost dle Jany Bernartové
Seriál Webarchivu Národní knihovny představuje výběry webů, bez nichž bychom nemohli žít, kterých by nám bylo líto, kdyby zanikly a nikdo...

10 webů pro věčnost dle Bohdana Heblíka
Seriál Webarchivu Národní knihovny představuje výběry webů, bez nichž bychom nemohli žít, kterých by nám bylo líto, kdyby zanikly a nikdo...

<https://medium.com/webarchiv>

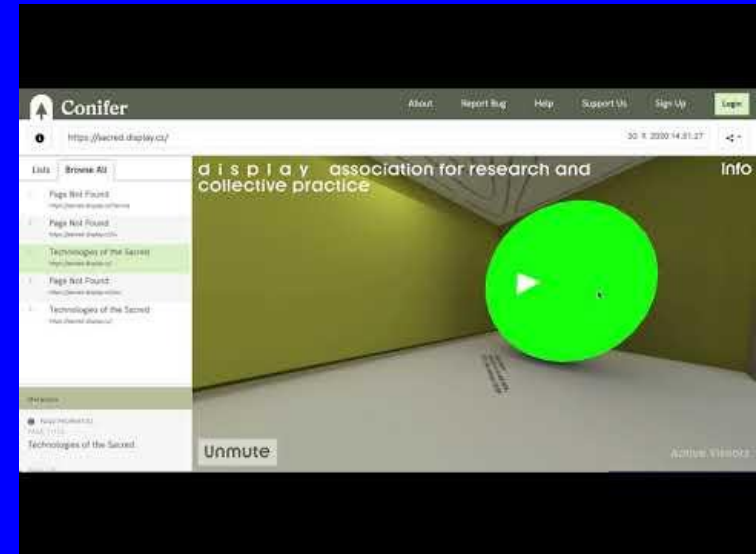
10 websites for eternity - personalities suggest webs for archiving

webarchiv.cz

challenges

- make the archive data and metadata as accessible to the public as possible
- social media archiving (personalized content) and dynamic content
Webrecorder / archiveweb page / browsertrix (FB, IG, TW, dynamic websites)


- cooperation with research communities
- quality assurance
- automatization, data protection



IT operation

Key issues

- Absorption capacity each year
 - Scrapers ban
- Reliable archiving / Deduplication
 - LTP logical protection
 - Optimization and QA
 - Automatisisation
- Sufficient personal capacities
 - Legal depot / questions

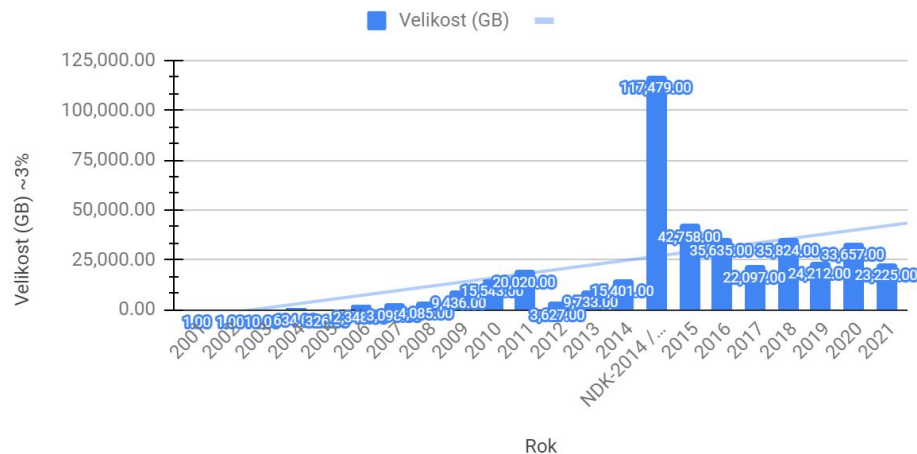


Czech Webarchive - Acquisition

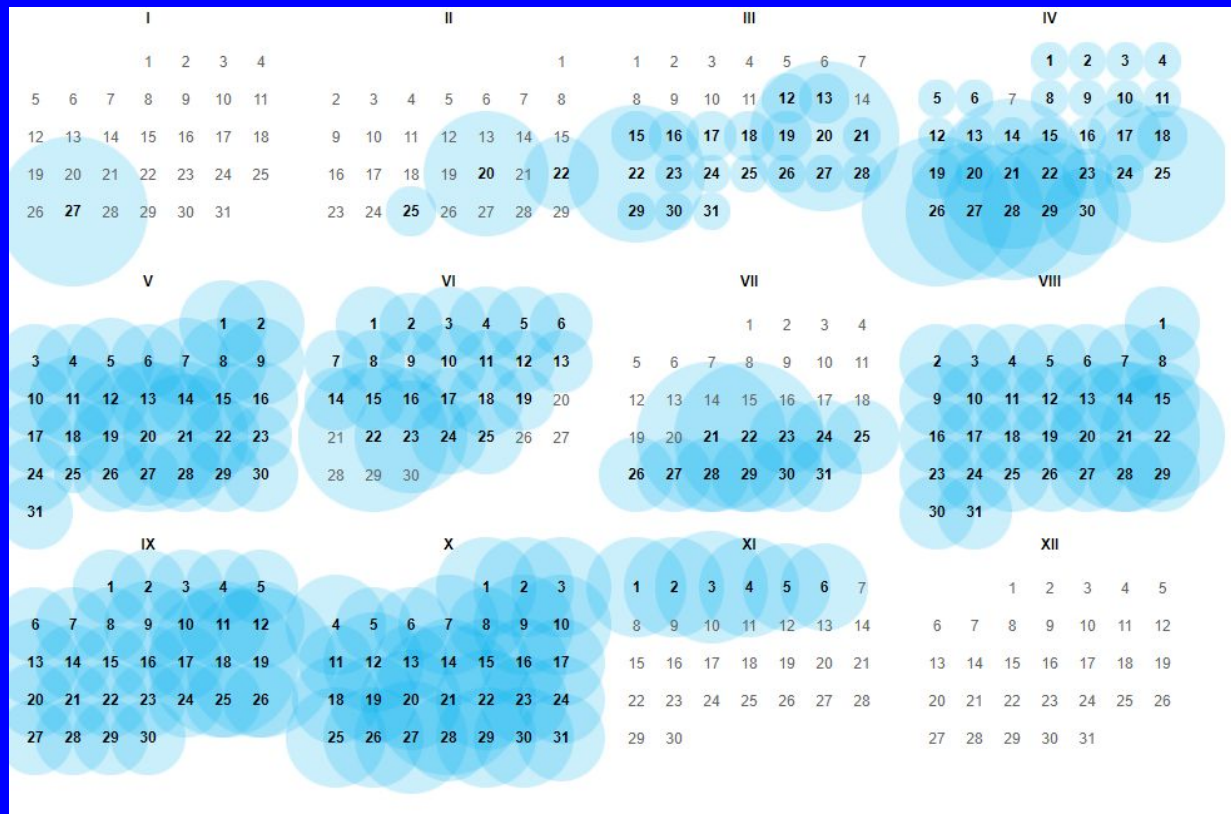
- stored: 409 TB zipped data:
 - yearly acquisition 25-50 TB (last five years)
 - this year 23 TB so far
- **daily**
 - Continuous - from 170 GB till 40 GB with deduplication
- **monthly**
 - Serials - from 4 TB till 700 GB with deduplication
 - Topics - from 2 TB till 300 GB with deduplication
- **once/twice a year**
 - Totals - from 30 TB till 15 TB - with no dedup / with dedup

Velikost (GB) vs. Rok

NK ČR: Z.Vozár, 2021/11/16



Continuous campaign Czech media (eg. *blisty.cz*)



Key technologies and principles

- virtualisation via VMware
- hierarchical storage via Spectrum Protect + TSM
- custom networking policies / absorption capacity
 - quantity of crawlers



Heritrix web - crawler

- version 3.4.0 (latest stable version: 3.4.0-20210923)
- diff. flavors of 3.4.0
- GH: <https://github.com/internetarchive/heritrix3>

Openwayback - presentation playback

- version 2.3.2
- java application used to play back archived websites
- no longer under active development
- customised in 2016
- GH: <https://github.com/iipc/openwayback/>

CDX server

- massive index of 7 bil. items
- no alone instance

Seeder - own

- Ca. 3 times a year new version

WA-KAT - own

- dockerised catalogisation SW

pywb

- HiFi Webarchive - python web archiving toolkit for replaying archive
- Implementation with OutbackCDX and pywb index cdxj
- customization of UI and integration of UKWA UI faceted search

Seeder

- Czech Webarchive curating tool
- CI / CD integration in Test env, Jenkins
- New functions for collections and crawl automatisaton
- Python / Django
- open-source: <https://github.com/WebarchivCZ/Seeder>

Grainery + Extractor

- Revision of WA content
- Preparation of metadataset for LTP ingest
- Python / Flask

R&D - Centralized interfaces - collab. (2018 -2022)

Data mining

- WARC processing
 - AUT tools - SPARK - initial DF
 - text extraction from txt/html
 - boilerplate removal
 - sound/video text extraction
 - other formats TD
- NER, Link extraction
- Network analysis

Topic modelling

- Topic identification based on catal. metadata
- Use of deep neural networks (Kerberos + Tensorflow, Pytorch)

New storage techs

- shift or paradigm:
 - hierarchical to object storage
 - capacity is cheaper than data loss
 - I/O resiliency
- set of 6 new servers for HDFS POC
- data operations as service



R&D - Centralized interfaces - Discovery and Output

Data exploration & exportation

- datasets for scientists based on their research requirements
 - analysis of topics and their automatic detection or analysis of audio files
 - approaches based on deep neural networks for document classification
- **1. Discovery UI interface**
 - filtration via facets (eg harvest, dates, contents, types, formats)
 - creation of collections
 - creation of very own data filters
 - Stop words
 - **2. REST API interface**
 - Jupyter NB
 - JAVa, Python, Scala
 - **3. Export on demand**
 - JSON, CSV
 - Fulltexts, Collocations, Network analysis data

R&D - Centralized interfaces - Discovery and Output

Discovery UI:

- Filtration
- Data Base
- Evocation
- Dry run

Iterative export:

- Filter It
- Extract It !

The screenshot displays a web search interface for 'Webarchiv'. On the left, there is a 'Filtre' (Filters) sidebar with the following settings:

- Téma: CR
- forum
- Datum skizne od: 01.10.2021
- Datum skizne do: 31.10.2021
- Operator: obsahuje
- URL
- Sentiment: (slider)
- Nastavení (Settings):
 - Stop slova: a, a by, aj, ale, ani, ast, atd, atp, ...
 - Počet záznamů: 1000

The main area is titled 'DOTAZ' (Query) and contains the search query: `topics:"CR" AND (webType:"news" OR webType:"forum") AND sentiment:[0.2 TO 1] AND date:[2021-10-01T00:00:00Z TO 2021-10-31T00:00:00Z]`. A 'VYHLEDAT' (Search) button is located to the right.

Below the query, there are 'Logické operátory' (Logical operators): AND, OR, NOT, and parentheses.

The 'STATISTICKÉ DOTAZY' (Statistical queries) section shows two query configurations:

- Colocation:** Typ dotazu: Colocation, Zadejte text pro vyhledávání: (empty), PRIDAT button, Seznam vyrazů: webarchiv, Pridat kontext (checked), Počet slov kontextu: 5.
- Raw:** Typ dotazu: Raw, Zadejte text pro vyhledávání: (empty), PRIDAT button, Seznam vyrazů: NKP, NK.

A '+ Pridat další dotaz' (Add another query) button is located at the bottom left of the main area.

webarchiv.cz

contacts

Thank you!

www.webarchiv.cz

www.facebook.com/webarchivcz, https://twitter.com/webarchiv_cz

https://www.instagram.com/mrtve_weby/

webarchiv@nkp.cz