



Tools for text digitisation and transcription

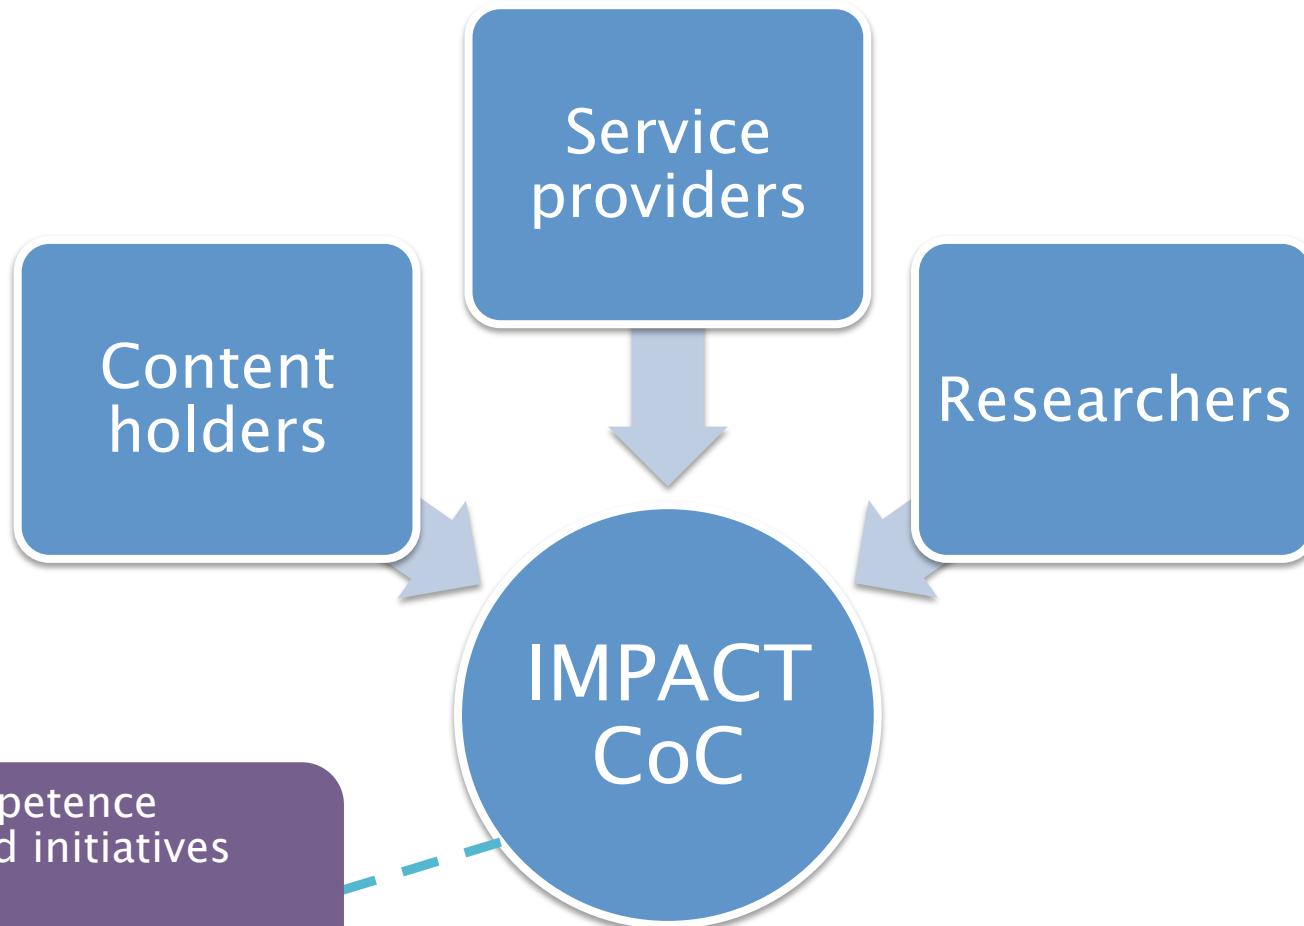
Tomasz Parkoła
Poznan Supercomputing and Networking Center



Agenda

- IMPACT Center of Competence
- Expertise, tools & events
- PSNC example
- Summary

IMPACT Centre of Competence in digitisation



- Other competence centres and initiatives
- Europeana
- Research infrastructures

IMPACT CoC members

Premium members

- Biblioteca Nacional de España
- Bibliothèque nationale de France
- British Library
- Fraunhofer-Gesellschaft zur Förderung der angewandten Forschung
- Fundación Biblioteca Virtual Miguel de Cervantes (Management and headquarters)
- Instituut voor Nederlandse Lexicologie
- Koninklijke Bibliotheek
- Contentra Technologies (formerly Planman Technologies)
- Poznań Supercomputing and Networking Center
- Universidad de Alicante

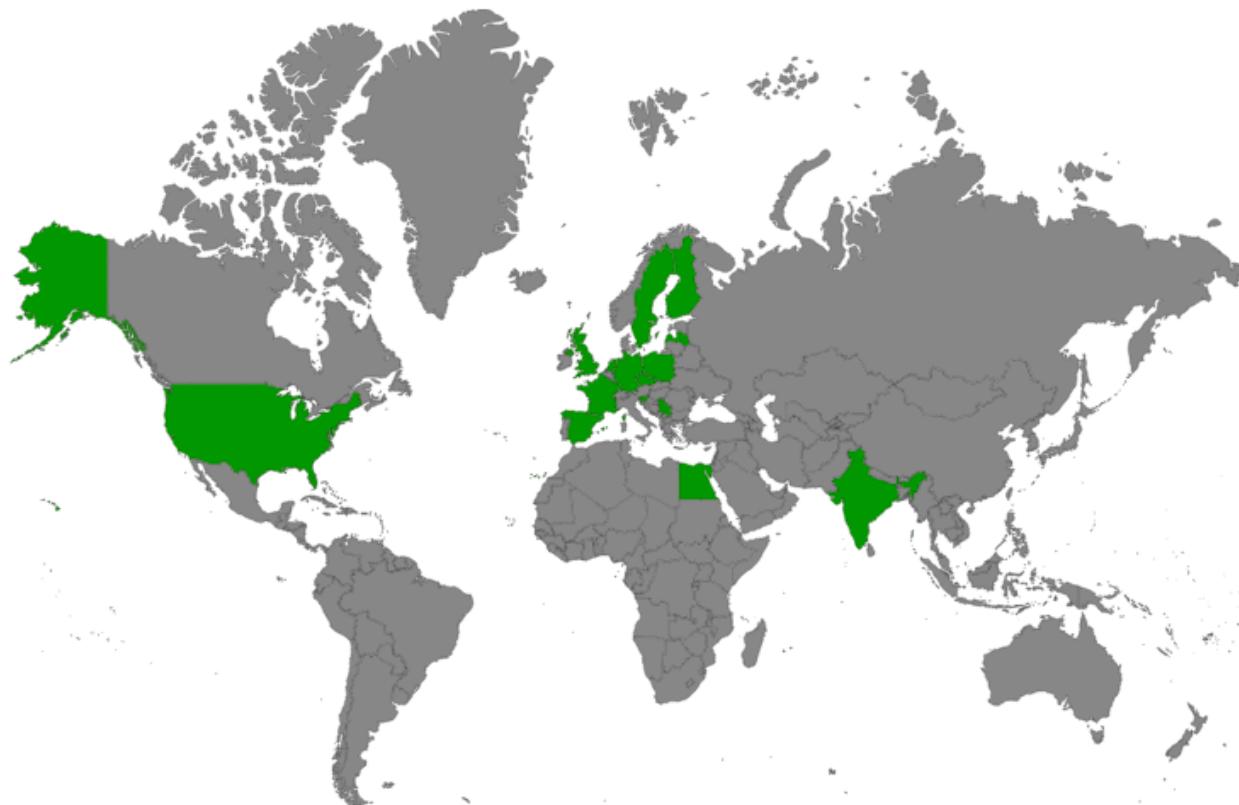
Standard members

- Biblioteka Uniwersytecka we Wrocławiu (Wroclaw University Library)
- California Digital Library
- Centro de documentación teatral
- DIGIBIS
- Elzaburu
- Göteborgs Universitet
- Hochschulbibliothekszentrum des Landes Nordrhein-Westfalen (University Library Centre of North Rhine-Westphalia)
- i2s Digibook
- KU Leuven
- Kungliga Biblioteket (National Library of Sweden)
- LIBNOVA
- Ludwig-Maximilians-Universität, Centrum für Informations- und Sprachverarbeitung

Standard members (cont.)

- Narodna in univerzitetna knjižnica (National Library of Slovenia)
- National Library of Czech Republic
- National Library of Egypt
- National Library of Finland
- National Library of Latvia
- National Library of Serbia
- Staats- und Universitätsbibliothek Bremen
- Tecnilógica
- Universitat de Barcelona
- Universidad Complutense de Madrid
- Universidad de Granada
- Universidad de Murcia
- Universidad de Salamanca
- Universidad de Valladolid
- University of Salford
- Vinfra

IMPACT CoC members

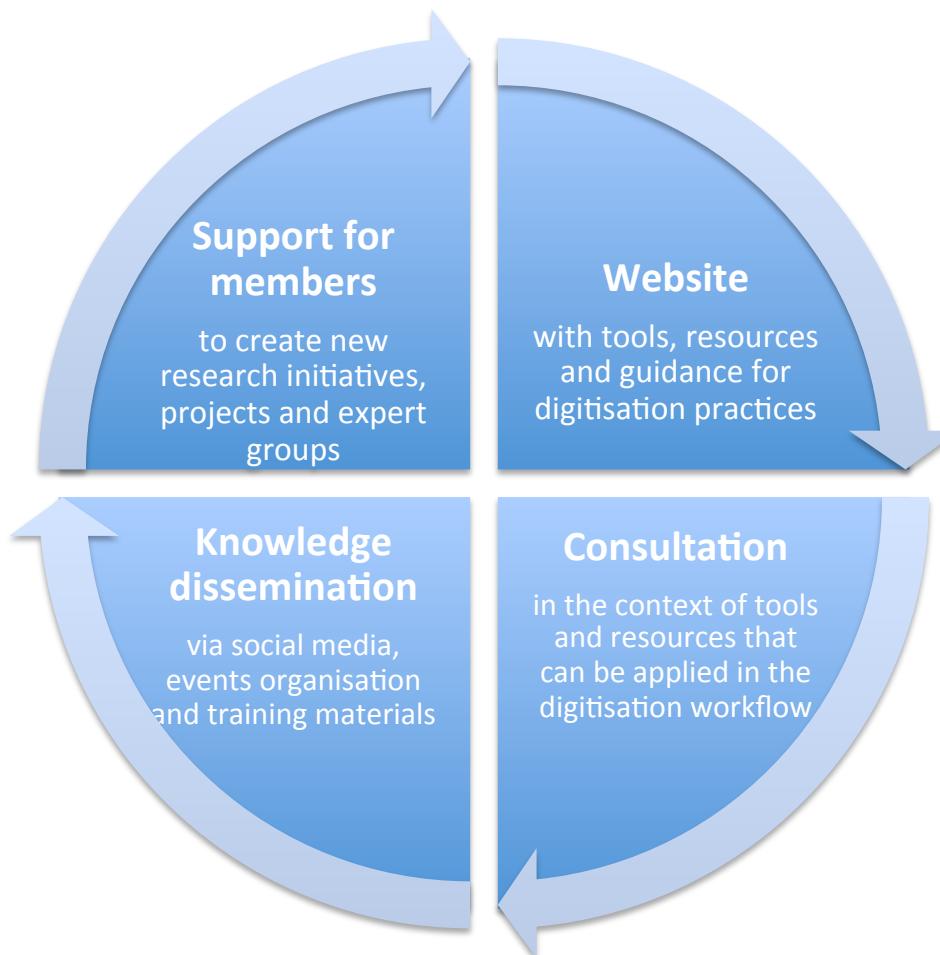


IMPACT CoC members



source: http://www.amcharts.com/visited_countries/

Main activities led by IMPACT CoC



Key benefits for members



Cultural heritage

- Access, validate and identify best digitisation technologies
- Meet the experts and define best practices
- Share experience and guide innovation

Research centres

- Learn about research challenges
- Collaborate and provide solution
 - Find project partners, sponsors or facilitators
- Share knowledge and experience

Companies

- Showcase your tools and services
- Meet your target customers
- Introduce innovation

Example: Geometric correction in the demonstrator platform

Demonstrator Platform

WORKFLOW CLIENT

Caution: Only execute workflows with strings as inputs and

Workflows containing services that require authentication ca
(0.2.1).

Please upload your workflow file:

Or login :

User:

Group: "J

Workflow

Show

Show in

Nie wybrano pliku

Show input values, if available

- Complex Abbyy FRE 9 OCR and Evaluation with Border Removal and Page Curl
- Complex Experimental IMPACT Workflow
- Complex Full Evaluation
- Complex OCR Evaluation FRE9 FRE10 Tesseract2 (French) + Repository
- Complex OCR Evaluation FRE9 vs CONCERT
- Complex OCR Evaluation FRE9 vs FRE10 with IMPACT image enhancement
- Complex Segmentation Combination
- Helper Convert a PAGE-XML into TXT files
- Helper Count characters in PAGE XML batch
- Helper CSV to List Conversion
- Helper Retain PRIM-A ID
- Helper Timer
- Helper URL to List Conversion
- IMPACT ABBYY FineReader 10 Binarisation
- IMPACT ABBYY FineReader 10 OCR
- IMPACT ABBYY FineReader 9 OCR
- IMPACT ABBYY FineReader 9 PAGE V3
- IMPACT ALTO to Text Transformation
- IMPACT FineReader
- IMPACT Gimp PNG to TIF Conversion
- IMPACT Gimp TIF to JPEG Conversion
- IMPACT Gimp TIF to PNG Conversion
- IMPACT Iconv Text Encoding Conversion
- IMPACT ImageMagick Conversion**
- IMPACT INL Named Entities Recognizer
- IMPACT INL Word Evaluation
- IMPACT LMU OCR Profiler
- IMPACT NCNR Binarisation
- IMPACT NCNR Border Removal V4
- IMPACT NCNR Character Segmentation
- IMPACT NCNR Geometric Correction V4
- IMPACT NCNR OCR Evaluation
- IMPACT OCR Evaluation by Levenshtein distance
- IMPACT OCROpus 0.3 Binarisation
- IMPACT OCROpus 0.3 Deskew
- IMPACT OpenJPEG Conversion
- IMPACT PAGE to Text Transformation
- IMPACT Results Repository
- IMPACT Tesseract OCR V3
- IMPACT USAL Layout Evaluation



113
zur Seligkeit führt! — In dieser allein liegt das Geheimnis des Umgangs mit der Geisterwelt: durch diese allein löst sich das Rätsel: — Seelenverbindung treut keine Zeit — keine Entfernung — kein Tod.

17.

Von Visionen, die ihren Grund in der Täuschung unserer Sinne haben.

Wir haben von Visionen geredet, die ihren Grund im Gedengesicht, und in der süssen Organisation haben. Wir reden nun von Visionen, die sich in der Täuschung unserer Sinne gründen.

Unter diese rede ich verschiedene Erscheinungen, die sich aus optischen und kategorischen Gründen erklären lassen.

Unter diese sehe ich wunderliche Erscheinungen Menschen und Thierähnlicher Tieren in der Dunkle; die Unschärfeverdunklung seiner eigenen Personen. Die künstliche Erscheinung lebender Personen aus optischen Regeln.

Wer den ersten ist anzumerken, daß Rauch und Nebel der Reflexion des Lichts empfindlich, und daß sie im Staube sind, Schattenbilder darstellen.

In Herbstzeiten schwirrt gegen die Nadeln ein jeder Nebel über den Blättern, Menschen, Weibern und unschönen Dingen. Wenn man nun so einen Nebel sieht, besonders gen Aufzug, so, daß die umstehende Sonne den Körper rücksichtslos beleuchtet, so führt sich oft,

113
zur Seligkeit führt! — In dieser allein liegt das Geheimnis des Umgangs mit der Geisterwelt: durch diese allein löst sich das Rätsel: — Seelenverbindung treut keine Zeit — keine Entfernung — kein Tod.

17.

Von Visionen, die ihren Grund in der Täuschung unserer Sinne haben.

Wir haben von Visionen geredet, die ihren Grund im Gedengesicht, und in der süssen Organisation haben. Wir reden nun von Visionen, die sich in der Täuschung unserer Sinne gründen.

Unter diese rede ich verschiedene Erscheinungen, die sich aus optischen und kategorischen Gründen erklären lassen.

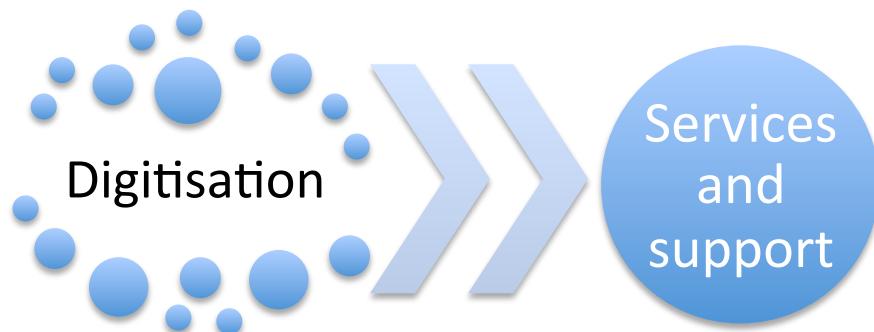
Unter diese sehe ich wunderliche Erscheinungen Menschen und Thierähnlicher Tieren in der Dunkle; die Unschärfeverdunklung seiner eigenen Personen. Die künstliche Erscheinung lebender Personen aus optischen Regeln.

Wer den ersten ist anzumerken, daß Rauch und Nebel der Reflexion des Lichts empfindlich, und daß sie im Staube sind, Schattenbilder darstellen.

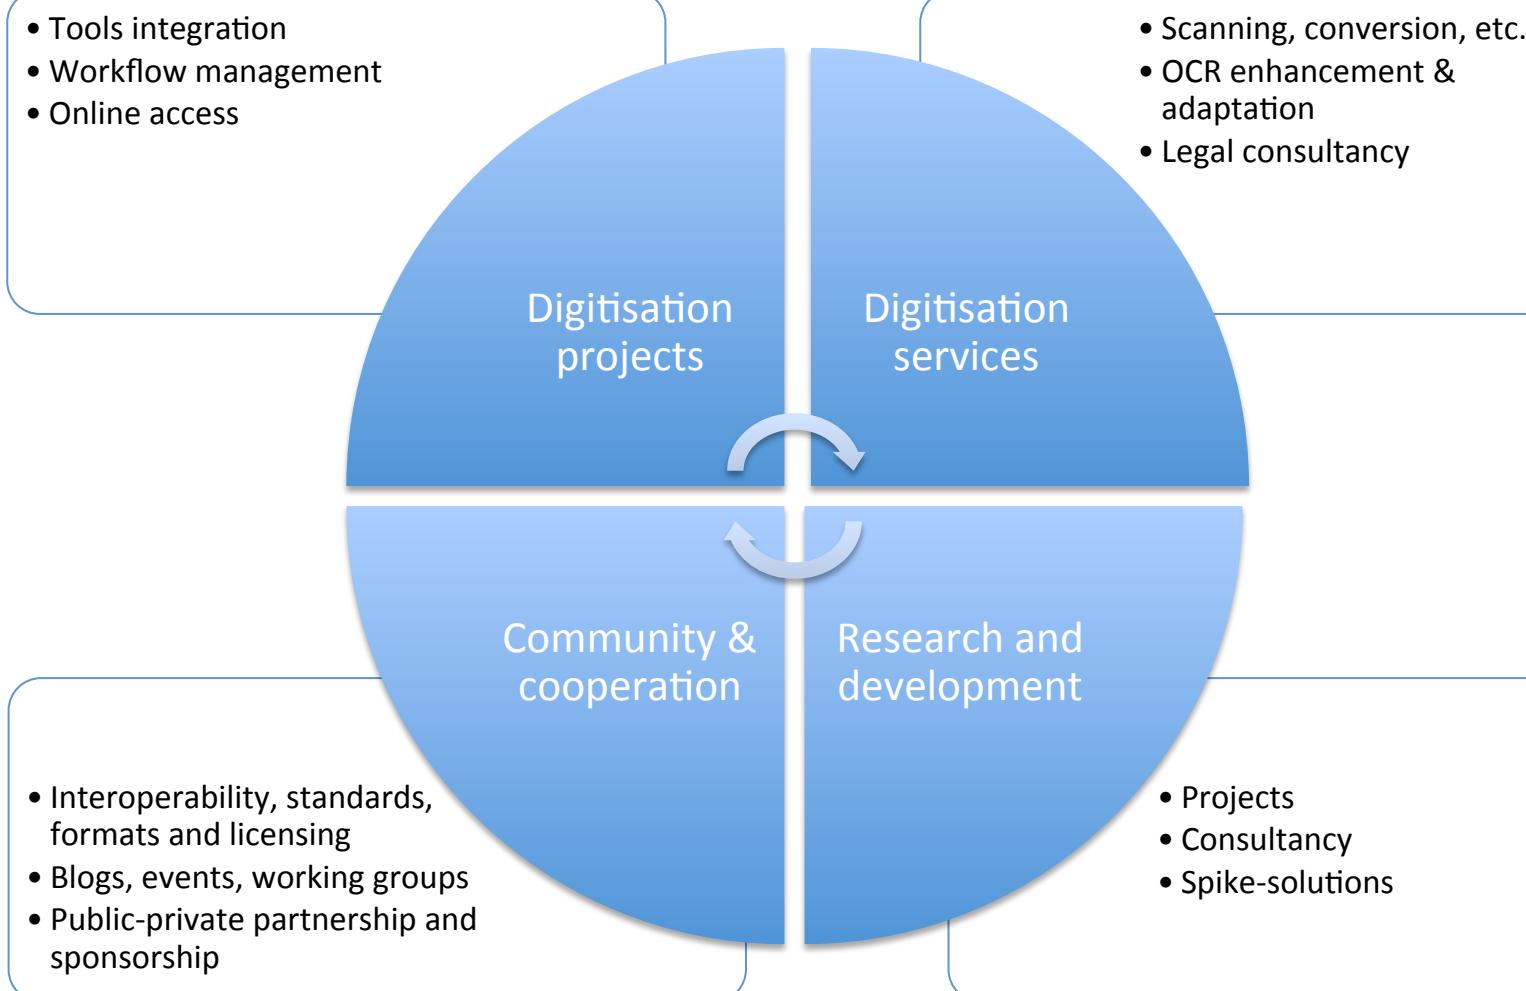
In Herbstzeiten schwirrt gegen die Nadeln ein jeder Nebel über den Blättern, Menschen, Weibern und unschönen Dingen. Wenn man nun so einen Nebel sieht, besonders gen Aufzug, so, daß die umstehende Sonne den Körper rücksichtslos beleuchtet, so führt sich oft,

daß

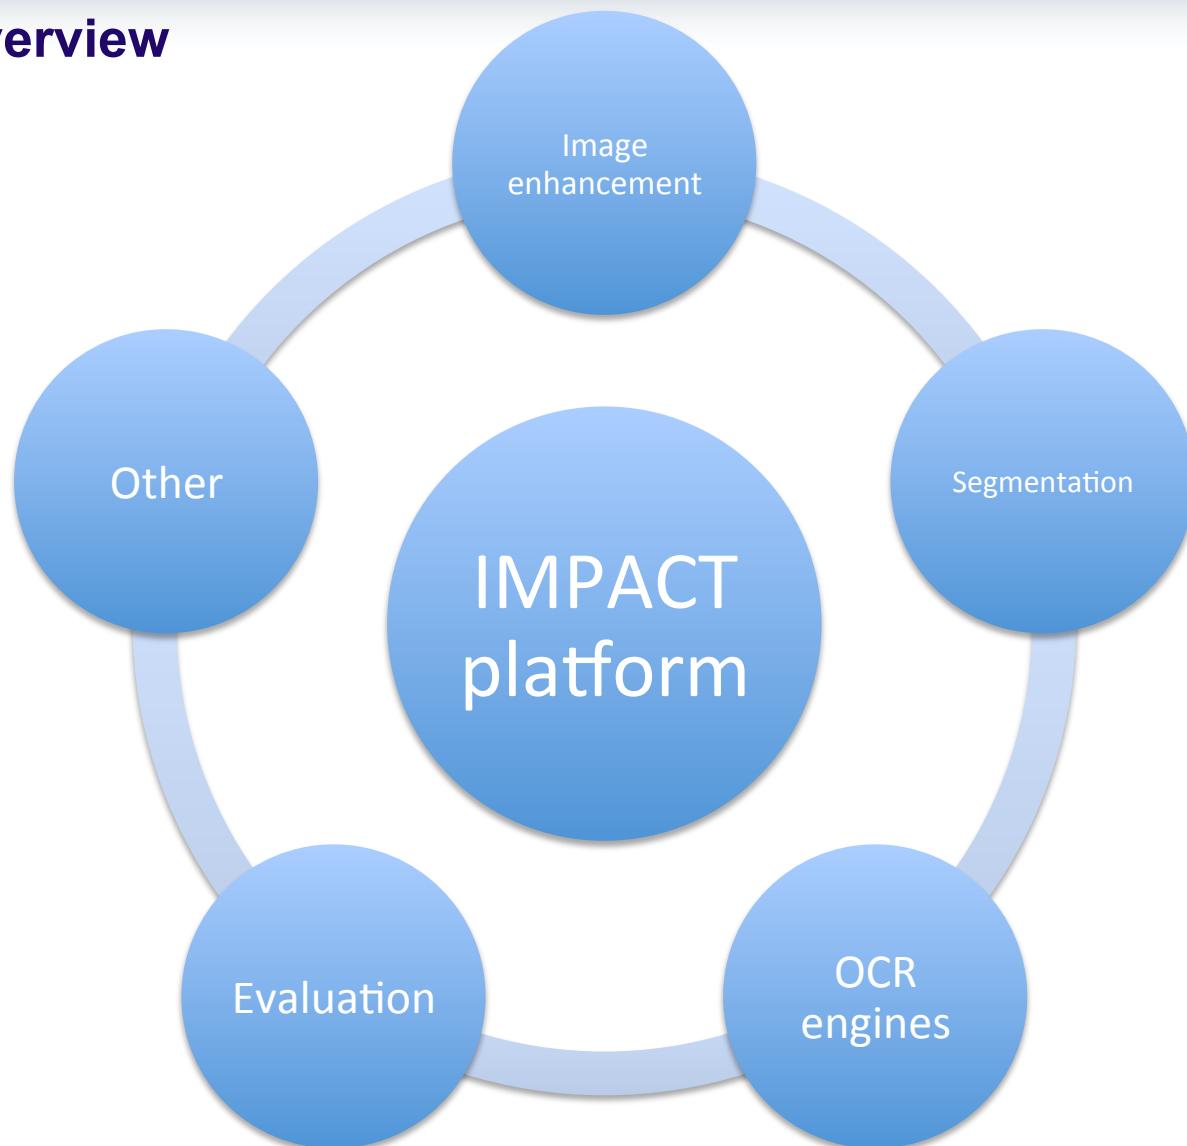
Expertise and experience: overview



Expertise and experience: examples



Tools: overview



Tools: examples (<http://digitisation.eu/demonstrator-platform>)

Image enhancement

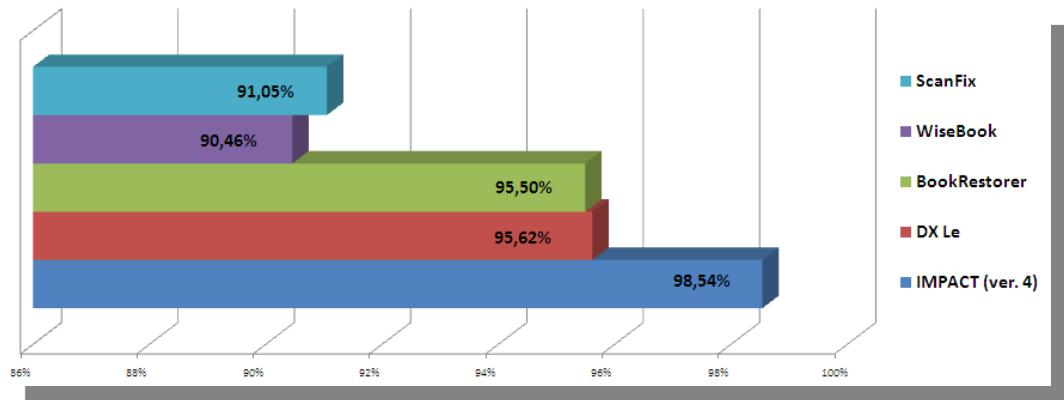
NCSR Border removal

NCSR Geometric Correction

NCSR Binarisation

Abbyy FineReader 10 Binarisation

Unpaper



Tools: examples (<http://digitisation.eu/demonstrator-platform>)

Segmentation

Abbyy FineReader 10 Segmentation

Uni. Salford region, line, word Segmentation Service

NCSR character segmentation.

Uni. Innsbruck



Tools: examples (<http://digitisation.eu/demonstrator-platform>)

OCR engines

Abbyy FineReader 10 OCR

Abbyy FineReader 10 with external dictionary

Uni. Salford Typewritten OCR

Tesseract 3.00

Gocr

Ocroptus

Cuneiform



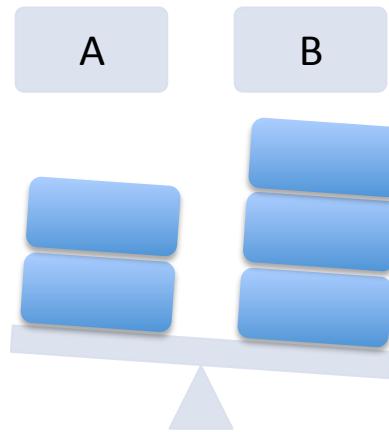
Tools: examples (<http://digitisation.eu/demonstrator-platform>)

Evaluation

NCSR OCR Evaluation service

Uni. Salford layout evaluation service

INL word evaluation service



Tools: examples (<http://digitisation.eu/demonstrator-platform>)

Other

ALTO and PAGE XML transformation

Uni. Salford ground-truth normalisation

Uni. Salford PAGE XML to svg

JP2

Exif



Resources

- Linguistic data
 - OCR/IR lexica: Slovene, German, Spanish, Czech, Polish, Dutch, English, French and other coming soon.
- Images and ground truth
 - Czech, Spanish, Polish, Bulgarian, Slovene, Biodiversity Heritage Library and other coming soon.
- Annotated corpora
 - Spanish.

Recent activities

- Past events (2013–2014)
 - Developer workshop for tools integration
 - TPDL tutorial (state of the art tools for text digitisation)
 - Digitisation Days, DATecH and Succeed awards
 - Workshop to investigate interoperability issues in digitisation
- Upcoming events (2014–2015)
 - November 28th, 2014: Succeed in digitisation. Spreading Excellence.
<http://www.succeed-project.eu/succeed-digitisation>
 - September, 2015: TPDL 2015 organised by PSNC (premium member of IMPACT CoC) <http://tpdl2015.info/>
 - 2016: Digitisation Days and DATecH
- Supporting take-up of tools and resources
 - A dozen of cultural heritage institutions validating and integrating state of the art digitisation tools (Tesseract, ScanTailor, ImageMagick, JHOVE, NER, Korrektor, Gimp, Alchemy API, COBaLT, Omnipage, Abbyy FR)
- Cooperation with other initiatives and centres of competence (e.g. Open Preservation Foundation)

PSNC example: who are we?



PSNC is a R&D centre located in Poznan, Poland, focused on ICT in the context of :

- Cloud technologies (archiving & computing) and HPC
- Network technologies (protocols, tools, management)
- **Innovative applications & services**

PSNC example: who are we?

In the context of cultural heritage we provide

- Polish National aggregator for Europeana and others
- **DInGO toolset for digitisation projects with over 100 production-mode deployments**
- **Virtual Transcription Laboratory tool with OCR training module and OCR execution support**
- Expertise (over 20 R&D projects, Digital Libraries Conference, training, workshops, consultancy)



VIRTUAL TRANSCRIPTION LABORATORY

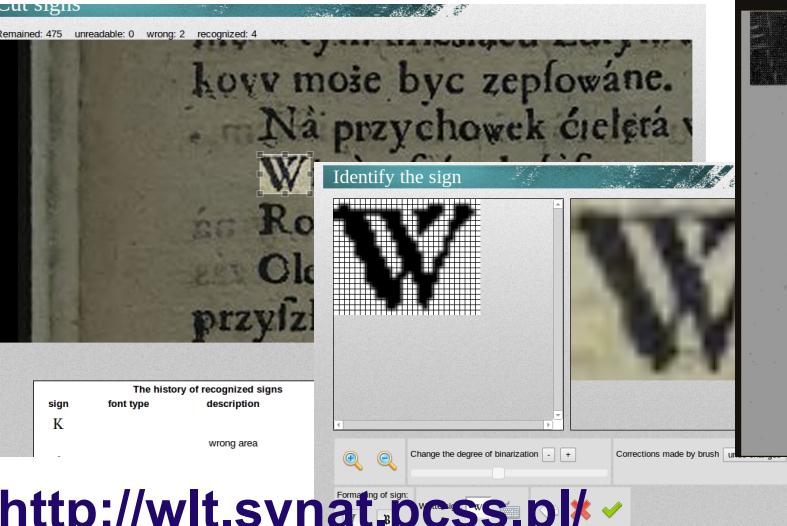
PSNC example: Virtual Transcription Laboratory

Web portal which provides access to:

- **Cutouts** tool (creation of customised recognition profiles)
- **OCR engine** with multiple recognition profiles
- **Transcription editor** with QA interface and group work support
- **TXT, hOCR and ePUB output formats**

Cut signs

Remained: 475 unreadable: 0 wrong: 2 recognized: 4



The history of recognized signs

sign	font type	description
K	-	wrong area

Fonting of sign: Change the degree of binarization Corrections made by brush

Formating of sign:

VIRTUALNE LABORATORIUM TRANSKRYPCJI



tyiąc barek leżących w wodzie uniemożliwiało żeglugę. Odróżnicy wodniacy tylko dwieście części taboru rzecznego objęt w posiadanie. Już w sierpniu tysiąc pięćset jedenbarek masyw odrysiskiem skaliem na wodę transport węgla.

Audit									
Statistics for the page: Total: 1868 Checked: 1110 Corrected: 758 (40.57816%) in this document 0 (0.0%)									
Ustawienia: Ilość znaków: 20 refresh Wielkość kontekstu [px]: 15 refresh									
Znak	Finalny	Oryginalny	Z kontekstem	Nieczytelny	Czcionka	Poprawny	Autor	Decyzja	
E							dteam	<input type="radio"/>	<input type="radio"/>
o								<input type="radio"/>	<input type="radio"/>
e								<input type="radio"/>	<input type="radio"/>
d								<input type="radio"/>	<input type="radio"/>
a								<input type="radio"/>	<input type="radio"/>
u								<input type="radio"/>	<input type="radio"/>

PSNC example: why?

1

High quality, efficient mass digitisation is currently one of the crucial challenges for cultural heritage institutions.

2

PSNC is involved in the IMPACT CoC to help these institutions to overcome existing barriers and to face new challenges in this context.

3

We believe that expertise of IMPACT CoC members can significantly contribute to successful R&D activities and cutting-edge information technologies for digitisation.

Summary: Join us!

Become standard member

get support in the digitisation programmes

access part of the IMPACT CoC resources

meet the experts advice

Become premium member

steer activities led by IMPACT CoC

get full access to IMPACT CoC resources

actively investigate and innovate digitisation

Contact: info@digitisation.eu



Thank you!

Tomasz Parkoła
tparkola@man.poznan.pl

CERL annual seminar, 28.10.2014, Oslo, Norway