



HAL
open science

Biblissima+ Cluster 3 - Intelligence artificielle, reconnaissance de formes et d'écritures manuscrites

Dominique Stutzmann, Daniel Stökl Ben Ezra

► **To cite this version:**

Dominique Stutzmann, Daniel Stökl Ben Ezra. Biblissima+ Cluster 3 - Intelligence artificielle, reconnaissance de formes et d'écritures manuscrites. Journées Biblissima+ 2024: Partager, décloisonner, réutiliser : outiller la recherche et développer de nouveaux usages, May 2024, Aubervilliers, France. 2024. hal-04955995


HAL Id: hal-04955995

<https://hal.science/hal-04955995v1>

Submitted on 19 Feb 2025

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



Biblissima

Observatoire des cultures écrites
de l'argile à l'imprimé

Cluster 3 – Intelligence artificielle, reconnaissance de formes et d'écritures manuscrites

CC-BY-NC-SA D. Stutzmann, D. Stoekl



Domaines d'action

Recherches sur les textes français et latins (IRHT)

- Classification des éléments graphiques (pages, zones de pages)
 - Classification iconographique des miniatures
- Reconnaissance d'entités nommées (cote, noms de personnes, titres d'œuvres)
 - Alignement des entités nommées sur des référentiels (*linking*)
- Catalogage automatique des manuscrits numérisés : identification des textes issus de HTR par comparaison avec référentiels textuels (Corpus corporum etc.)
- Référentiels de noms de lieux et de personnes dans les cartulaires médiévaux

Reconnaissance d'écriture Kraken (AOroC)

- Module HTR open source pour tous les systèmes d'écriture
 - Latin, grec, arabe, chinois, hébreu, syriaque, géorgien, geez
 - Ordre de lecture entraînable
- Développement et maintenance d'eScriptorium
 - nouvelle UI (openITI / Mellon)
 - alignement text2text avec passim, annotation de texte et d'image
 - extension de l'API, moteur de recherche, métadonnées au niveau d'image

Reconnaissance des filigranes du papier et des éléments décoratifs, héraldiques, sigillographiques et numismatiques

- Répertoire de filigranes : création de métadonnées, missions photographiques (IRHT)
 - Base de filigranes : métadonnées, images ; science participative (ENC-PSL / IRHT)
- Répertoire des décors typographiques : reconnaissance automatique des formes et des fontes pour l'identification des imprimeurs
- Monnaies et données numismatiques
 - Système automatique de reconnaissance des coins monétaires antiques (AOroC)
- Acquisition des données en musée et réserves et mise en ligne (Crahm - Caen)
- Module Sigiscript - épigraphie du sceau (Saprat)
- Référencement d'empreintes de monnaies sur supports céramiques


Détection de miniatures (Arkindex/Teklia)

Détection d'entités nommées. Ici: Corpus d'entraînement HOME-Alcar (doi: [10.5281/zenodo.5600883](https://zenodo.org/record/5600883)), présenté dans l'interface Arkindex de Teklia (Source: Dijon, Arch. dép., 7 H 7 Cart. 143)

Interface eScriptorium: détection de lignes verticales et transcription (Source: London, British Library, Or.8210/S.3011(A), IX^e s., *Entretiens de Confucius*)
Illustrations: CC-BY-NC-SA C. Brisson

Coordonner les développements, ouvrir et organiser les accès aux infrastructures, aux données et aux sources

- Publication de logiciels open source, coordonner les développements
 - Kraken (<https://github.com/mittagessen/kraken>)
 - eScriptorium (<https://gitlab.com/scripta/escriptorium>)
 - Arkindex (<https://gitlab.teklia.com/arkindex>)
- Publication de modèles entraînés
 - Communauté Zenodo (https://zenodo.org/communities/ocr_models/)
 - Huggingface
 - <https://huggingface.co/Teklia>
 - <https://huggingface.co/datasets/CATMuS/medieval>
- Infrastructures de calcul dédiées
 - <https://msia.escriptorium.fr/>, <https://escriptorium.inria.fr/>
 - Accès aux infrastructures : <https://cremmacall.sciencescall.org/>
- Publication des données d'entraînement



Faire communauté : les Journées du cluster 3 « Biblissim-IA »

- Mars 2023 (<https://biblissim-ia-2023.sciencesconf.org/>)
Tables-rondes thématiques sur l'IA en SHS
Ateliers prospectifs et de formation
- Mars 2024 (<https://biblissim-ia-2024.sciencesconf.org/>)
Avancées des projets d'analyse de document avec IA

lundi 20 mars 2023	
HEURES	ÉVÈNEMENT
14:00 - 14:45	Intelligence artificielle, reconnaissance de formes et d'écritures manuscrites: principes, enjeux et potentiels (Open Space - Humathèque) - Dominique Stutzmann / Daniel Stoekl / Laurent
14:45 - 18:00	IA et ressources humaines (Open Space - Humathèque)
14:45 - 15:45	(Ne pas) mettre l'humain au service de la machine ? Vérité terrain, legacy data, données ouvertes et modèles entraînés - Laurence Bobis, Bibliothèque interuniversitaire de la Sorbonne - textes - Simon Gabay, Université de Genève - Arsène Georges, Bibliothèque interuniversitaire de la Sorbonne - Thierry Kouamé, Université Bourgogne Franche-Comté (COMUE) - Martin Mo
16:00 - 17:00	Savoirs et formations - Emmanuelle Bernes, École nationale des chartes - Jean-Baptiste Camps, École nationale des chartes - Matthieu Husson, Observatoire de Paris - Peter Stokes, Éco
17:00 - 18:00	Le coût invisible des projets interdisciplinaires - Christopher Kermovant, TEKLIA, Laboratoire d'informatique, du Traitement de l'Information et des Systèmes - Elena Pierazzo, Centre d'ité
mardi 21 mars 2023	
HEURES	ÉVÈNEMENT
09:30 - 12:30	IA et recherche en humanités : questions d'épistémologie (Open Space - Humathèque)
09:30 - 10:30	► Applicabilité de l'IA : y a-t-il des domaines où appliquer l'IA (n'est pas) pertinent ? - Bertrand Coussanon, Institut de Recherche en Informatique et Systèmes Aléatoires - Laurent Habot, É
10:30 - 11:30	► L'intelligence artificielle et les financements de la recherche en SHS - Alexandre Gefen, THALIM - Théorie et histoire des arts et des littératures de la modernité - UMR 7172, Institut des S
11:30 - 12:30	► Intelligence artificielle, science de la donnée, néo-positivisme numérique et stratégies de recherche - Elisa Grandi, Université Paris Cité - Torsten Hiltmann, Humboldt Universität zu Berlin
12:30 - 14:00	Déjeuner (Open Space - Humathèque)
14:00 - 17:30	Concevoir un projet de recherche avec l'IA (Open Space - Humathèque)
14:00 - 17:30	► Concevoir un projet avec de l'IA ? Brainstorming et speed dating... - Matteo Ferrari, École pratique des hautes études - Antony Hostein, École pratique des hautes études - Jean-Philippe
mercredi 22 mars 2023	
HEURES	ÉVÈNEMENT
09:30 - 13:00	Atelier n°1 : eScriptorium (Campus Condorcet - Bât. Recherche Nord - Salle 0.010)
09:30 - 13:00	► Atelier d'initiation à l'usage d'eScriptorium - Daniel Stoekl Ben Ezra, EPHE-PSL - Colin Brisson, EPHE-PSL - Simon Gabay, Université de Genève - Paweł Jablonski, EPHE-PSL - Benjamin
14:00 - 17:00	Atelier n°2 : Sigillographie et IA (Campus Condorcet - Bât. Recherche Nord - Salle 2.001)
14:00 - 17:00	► Sigillographie et Intelligence Artificielle - Victoria Eynarabide, Sorbonne Université - Laurent Habot, École pratique des hautes études - Delia Prêteux, Atelier national de recherche typogr
14:00 - 17:00	Atelier n°3 : Plans de gestion de données (PGD) (Campus Condorcet - Bât. Recherche Nord - Salle 2.001)
jeudi 23 mars 2023	
HEURES	ÉVÈNEMENT
09:30 - 12:30	Atelier n°1 : eScriptorium (Campus Condorcet - Bât. Recherche Nord - Salle 2.001)
09:30 - 12:30	► Atelier d'initiation à l'usage d'eScriptorium - Daniel Stoekl Ben Ezra, EPHE-PSL - Colin Brisson, EPHE-PSL - Simon Gabay, Université de Genève - Paweł Jablonski, EPHE-PSL - Benjamin

jeudi 7 mars 2024	
HEURES	ÉVÈNEMENT
09:15 - 10:00	Accueil - petit déjeuner (Foyer)
10:00 - 11:00	Discours introductif - Cluster 3 Biblissim+ (Auditorium 150) - D. Stutzmann, D. Stoekl Ben Ezra
11:00 - 11:30	A presentation of ManuscriptAI, an upcoming project aiming to build an AI-tool to facilitate the integration, accessibility, and usability of heterogeneous cultural heritage data on medieval manuscripts
11:30 - 12:00	Classification of Ancient Greek Coins - Challenges Using AI methods (Auditorium 150) - P. Ulrike
12:00 - 12:30	DIANET : Développement d'une interface web simplifiée pour l'utilisation d'un système intelligent de comparaison de coins monétaires (Auditorium 150) - K. Gruel, O. Masson, M. Bul
12:30 - 14:00	Déjeuner (Foyer)
12:30 - 14:00	Session poster (Foyer)
14:00 - 14:30	Vers une segmentation robuste du tracé dans les manuscrits anciens (Auditorium 150) - C. Brisson
14:30 - 15:00	Transcribathon : Results of the 1st Week of the Digital Hebrew Book (2024) (Auditorium 150) - D. Stoekl Ben Ezra, L. Bambaci, B. Kiessling
15:00 - 15:30	Low-tech AI: Iconography for everyone (Auditorium 150) - D. Stutzmann
15:30 - 16:00	Pause café (Foyer)
16:00 - 16:30	AI and the paleography of Greek papyrus: presentation of the new EGRAPSA project (Auditorium 150) - G. De Gregorio, I. Marthot-Santaniello
16:30 - 17:00	PapyTwin net: a Twin network for Greek letters detection on ancient Papyrus (Auditorium 150) - M. Tu Vu, M. Beurton-Aimar
17:00 - 17:30	PapyroLogos: Large data and little resources (Auditorium 150) - H. Essler, R. Ast
vendredi 8 mars 2024	
HEURES	ÉVÈNEMENT
09:15 - 10:00	Accueil - Petit déjeuner (Foyer)
10:00 - 10:30	Ansund: Using Machine Learning to Develop a New, Exhaustive, Open Access Corpus of Old English (Auditorium 150) - M. Faulkner, E. Magnanli
10:30 - 11:15	Keynote speech : Signs, symbols and secrets: HTR faced with ciphered texts and music scores (Auditorium 150) - A. Fornes
11:15 - 11:30	Pause café (Foyer)
11:30 - 12:00	Deep Digital oriental: A state of the art for Sanskrit oriental handwritten text recognition (Auditorium 150) - S. Thottempudi
12:00 - 12:30	Intégration de modèles Seq2Seq pour la correction et la normalisation de textes issus de l'HTR (Auditorium 150) - S. Yatsyk
12:30 - 13:00	Entraînement from scratch ou fine-tuning ? Modalités et enjeux d'un choix d'un projet HTR sur les registres de plaidoiries du Parlement de Paris (fin XIVe-XVe siècle) (Auditorium 150) - P. Spychala
13:00 - 14:00	Déjeuner (Foyer)
13:00 - 14:00	Session poster (Foyer)
14:00 - 14:30	How Do Large Language Models (LLMs) Impact Document Image Analysis? An Open Discussion. (Auditorium 150) - A. Scius-Bertrand, L. Voegtlin, N. Wegmann, A. Fakhari, A. Fischer
14:30 - 15:15	TR and LLM feedback for automatic transcription in Divergent Use Cases (Auditorium 150) - H. Miller, M. Lavee, N. Bontemps
15:15 - 15:45	Integrating Vision Transformers and Large Language Models for Enhanced Handwriting Text Recognition and Named Entity Identification in Documentary Manuscripts (Auditorium 150) - S. Aguilari
15:45 - 16:00	Torres
15:45 - 16:00	Pause café (Foyer)
16:00 - 16:30	« Un simple OCR ? » : outils, algorithmes et méthodes de reconnaissance de document en humanité numérique. (Auditorium 150) - C. Kermovant, Y. Schneider, M. Blanco
16:30 - 17:00	Retour(s) d'expérience(s) d'indexation de registres d'emprunteurs de bibliothèques parisiennes: chaîne de production et de diffusion des archives de PRET19 (Auditorium 150) - V. Rebollo-Druin, C. Kermovant
17:00 - 17:45	Keynote speech : Information extract