

ARABASE : Base de données Web pour l'exploitation en reconnaissance optique de l'écriture Arabe

Noura Bouzrara*, Nacéra Madani Aissaoui**, Najoua Essoukri Ben Amara***

*Ecole Nationale d'Ingénieurs de Tunis (ENIT)

bouzrara_noura@yahoo.fr

**Faculté des Sciences de Monastir (FSM)

Aissaoui.Nacira@fsm.rnu.tn

***Ecole nationale d'Ingénieurs de Sousse (ENISO)

Najoua.Benamara@enim.rnu.tn

Nous proposons dans ce travail ARABASE une base de données d'images d'échantillons d'écriture arabe pour l'exploitation en reconnaissance optique de l'écriture (OCR-Optical Character Recognition). Cette base est implémentée sur un réseau à longue distance.

L'étude des particularités morphologiques de l'écriture arabe, dans sa forme imprimée et manuscrite (en ligne et hors ligne), et les différents problèmes liés à l'OCR arabe, nous ont conduit aux choix retenus au niveau de notre base de données.

Le contexte de ARABASE est diversifié (montant littéraires, noms de villes, texte libres, ligatures, nombres, signatures...), il correspond aux différents modes d'écritures : imprimé et manuscrit (hors ligne et en ligne). Pour chacune des classes du contexte correspondent des sous classes associées aux mots, pseudo-mots et aux caractères qui composent l'entité considérée. Des informations relatives à l'origine du document source et aux différents modes d'acquisition des données sont également disponibles dans ARABASE. Un document est produit par un périphérique d'entrée (un scanner, une tablette graphique, une imprimante...).

Dans le cas du manuscrit, nous considérons un contexte multi-scripteurs (Essoukri Ben Amara, 2005).

L'ensemble des informations de ARABASE est organisé dans le diagramme de classe statique selon la méthode orientée objet UML- Unified Modelling Language (Roques, 2002), la figure 1 donne un extrait de ce diagramme.

Plusieurs fonctionnalités sont offertes par cette application, nous citons en particulier :

- La consultation des différentes entités du contexte et des informations relatives aux outils d'acquisition.
- Les recherches selon des critères spécifiés par l'utilisateur, qui peut être administrateur ou client.
- La possibilité d'effectuer diverses statistiques relatives aux différents types d'informations

En plus de ces fonctionnalités classiques, ARABASE offre la possibilité d'enrichir le contexte de la base de données par l'ajout d'une nouvelle classe au modèle conceptuel, c'est-à-dire l'ajout de nouveaux vocabulaires au contexte de la base.

L'application est réalisée sous l'environnement SQL Server- Microsoft Structured Query Language Server (Spennik et Sledge, 2001) ce qui assure la sécurité des données.

L'interface de l'application se présente sous forme de pages WEB, elle est développée avec le langage de script PHP- Hypertext Pre-Processor Defrance (2004), constituant le site « ARABASE ».




FIG. 1 – Extrait du diagramme de classe de « ARABASE ».

Références

Essoukri Ben Amara, N., O. Mazhoud, N. Bouzrara, N. Ellouze (2005). *Arabase : a relational database for Arabic OCR systems*. IAJIT, 2(4), October 2005, pp.259-266.

Defrance, J.M. (2004). *PHP/MySQL avec Dreamweaver MX*, Paris: Eyrolles.

Roques, P. (2002). *UML par la pratique*, Paris: Eyrolles.

Spenik, M. et O. Sledge (2001). *SQL Server DBA*, CampusPress.

Summary

In this Paper, we present a database of Arabic image writing for the use in Arabic OCR systems. The topics addressed by ARABASE concern different styles of documents: machine printed text, off line and on line handwriting. Data corresponds to a variety of context: city names, literal amounts, isolated characters, digits, free texts, words/sub-words, isolated characters. ARABASE contains also information describing the process of data acquisition. Therefore, we use the method oriented object UML for modelling the system. ARABASE provides multiple functionalities to their users (webmaster and clients).