

مجموعات الكتابات اليدوية العربية على الويب:

دراسة في المعالجة والتنظيم والاسترجاع

د. سيد ربيع سيد إبراهيم

مدرس نظم استرجاع المعلومات

كلية الآداب - جامعة بنى سويف

مستخلص

تستهدف هذه الدراسة تناول مواد الكتابات اليدوية العربية على الويب كمواد معلومات قديمة حديثة، وهذه النصوص المخوطة بخط اليد تمثل وافداً جديداً بين مواد معلومات الويب، وتقطّع الويب وأدوات بحثها إلى توصيف معايير وآليات التعامل مع الكتابات اليدوية معالجة وتكشيفاً واسترجاعاً. وانطلقت الدراسة من أساس اختلاف الكتابات اليدوية كونها نصوص في شكل صور رقمية **OCR**، تختلف في طبيعتها بين النص منفرداً والصورة منفردة. وقد قدمت الدراسة توصيفاً للبنية الرقمية المقترحة لملفات مواد الكتابات اليدوية، وأساليب التكشيف المبنية على المحتوى والنص للتعامل مع التحليل الموضوعي لهذه المواد. وقد خرجمت الدراسة بتوصيف مقترن لبنيّة وإجراءات الإدراك والمعالجة وأساليب البحث في أدوات بحث الويب التي تتوافق وطبيعة الكتابات اليدوية، كأول دراسة تتناول مواد الكتابات اليدوية في بيئة الويب.

الكلمات المفتاحية : الكتابات اليدوية، المخطوطات، تكشيف المخطوطات، إدراك النصوص اليدوية، القراء الآلية للحروف **OCR**، نظم استرجاع المعلومات، الويب.

مقدمة الدراسة :

١ / ٠ تمهيد

مثلت الويب منذ بدايتها مستودعاً كونياً للمعلومات والمعرفة البشرية بكل أشكالها وإنماط حمل المعلومات المتعددة، غير أن الويب كمستودع للمعلومات لم تكن منوطه بتنظيم المعلومات الرقمية وذلك لأن الهدف من الويب كان نشر المعلومات واتاحتها دون التطرق إلى أساليب التنظيم وآليات المعالجة. ومن ثم ترتب على تنوع وتنوع الملفات

وبنية ووسائل حمل المعلومات الرقمية على الويب أن تحول التعامل مع المعلومات الرقمية من عمليات التنظيم إلى آليات البحث والاسترجاع الملائمة لأنماط المختلفة التي تزداد تنوعاً وتحديثاً يوماً بعد يوم في متودع الويب. وكما شملت الويب النصوص والمواد المصورة المسموعة، أضيف إليها أنماطاً مستحدثة من المعلومات الرقمية مثل الرسوم الحيوية *animations* والمواد ذات الأصل التقليدي كالمخطوطات والكتابات اليدوية.

ولقد شكل المحتوى العربي من المعلومات والموقع على الويب مشكلة تقنية في عمليات البحث والاسترجاع لأدوات بحث الويب؛ حيث تميزت اللغة العربية بخصائص لغوية عجزت أدوات البحث عن مجاراتها والتعامل معها مما انعكس بالسلب على استرجاع وتناول المعلومات العربية على الويب حتى كانت الدراسات التي تناولت خصائص البحث باللغة العربية للمحتوى العربي من المعلومات الرقمية. وما نتج عن ذلك تمثل في انتاج آليات بحث واسترجاع تتوافق وخصائص اللغة العربية معتمدة بالأساس على استخدام تقنيات التحليل الصرفي والمعاجم الآلية لمحركات البحث، وكان تتوسيع ذلك بتوفير قدرات البحث عن المعلومات العربية مثل البحث بالترادف والبحث بجذور الكلمات العربية والبحث بمعنى ومقابلات المفردات العربية، حتى خرجت إلى فضاء الويب محركات بحث كاملة تدعم البحث باللغة العربية بشكل عميق.

وقد عمل تطور التقنيات والبرمجيات المستخدمة لتحويل المعلومات التقليدية إلى الشكل الرقمي على إستقبال الويب لمجموعات من المعلومات الرقمية العربية التي قد سبقت الويب في الوقت من حيث نشأتها واتاحتها مثل المخطوطات والكتابات العربية التراثية التي تعود إلى أزمان الترجمة والتعريب ثم ازدهار الانتاج الفكري العربي لقرون الإسلام الأولى. هذا فضلاً عن توافر برامجيات الكتابة اليدوية مباشرة على الوسيط الرقمي في عصرنا الحديث كالكتابة على الحاسوبات اللوحية والهواتف النقالة التي تمثل أدوات نشر للمعلومات الرقمية على الويب. ولقد مثل ذلك كله ظاهرة انتشار الكتابات اليدوية العربية على الويب سواء تلك التراثية أو الحالية التي تستدعي أدوات بحث الويب وأدوات استرجاعها إلى الاتجاه نحو آليات ومعايير للبحث والمعالجة تلائم تنظيم وبحث واسترجاع الكتابات اليدوية العربية.

٢ / مشكلة البحث

تتمثل مشكلة البحث في تزايد مجموعات المعلومات من الكتابات اليدوية العربية على الويب سواء تلك التي تم تحويلها إلى الشكل الرقمي بهدف الاتاحة والوصول والاستخدام الأكثر انتشار من خلال شبكة الويب مع الاحتفاظ بالنسخ الأصلية المتحفية التي تمثل قيمة تاريخية، أو تلك المعلومات الرقمية المكتوبة يدوياً وتم نشرها واحتاجتها على الويب بشكلاً مخطوط يدوياً. وانطلاقاً من وظيفة الويب الأساسية في توفير أدوات وآليات بحث لمختلف أشكال المعلومات التي تحملها، فإن مجموعات المعلومات العربية الرقمية يدوية الكتابة لا تتوافق لها أدوات وآليات البحث التي تتوافق وطبيعة نصوصها وكلماتها وحروفها التي تختلف وتتنوع بشكل يصعب على أدوات بحث الويب بحثها واسترجاعها بآلياتها الحالية. وتتعدد أطراف المشكلة في إيجاد انساق محددة لفهم تركيب وبنية النصوص اليدوية العربية، أيضاً آليات التعامل مع الحروف الرقمية يدوية الكتابة هل من خلال كونها حروف ذات دلالة أم بكونها صوراً بمضامينها؟ فضلاً عن توفير أساليب للبحث تستطيع الوصول إلى الاستدعاء والتحقيق اللازمين في بحث مواد المعلومات يدوية الكتابة. ومن ثم فإن البحث يقوم على فرضية رئيسة هي (إن بيئه وأدوات بحث الويب لا تتوافق آلياتها وتقنياتها وأداؤها مع مواد الكتابات اليدوية العربية الرقمية كأحدث أشكال المعلومات المتاحة على الويب)

٣ / تأولات الدراسة

يطرح البحث تأولات هي :-

١. ما التقنيات الازمة للتعامل مع معالجة وتكشف الكتابات العربية اليدوية على الويب؟

٢. ما آليات ومعايير البحث الازمة لأدوات بحث الويب لاسترجاع الكتابات العربية اليدوية؟

٣. ما خصائص قواعد البيانات ومستودعات الكتابات العربية اليدوية على الويب؟

٤. ما القدرات التقنية والبرمجية المطلوبة للتعامل مع مفردات النصوص العربية اليدوية على الويب؟

٤ / أهداف الدراسة

تهدف هذه الدراسة إلى تحقيق ما يلي :-

(١) فهم آليات وتقنيات تناول الكتابات اليدوية على الويب كمواد معلومات رقمية.

٢) تحديد معايير وآليات البحث المطلوبة لدى أدوات البحث للتعامل مع النصوص العربية اليدوية.

٣) رسم صورة مبدئية عن بنية وتكوين مستودعات مجموعات المعلومات النصية اليدوية على الويب.

٤) وضع روئي مقترحة حول معالجة وتنظيم وتشكيف مجموعات النصوص اليدوية الرقمية.

٥ / أهمية الدراسة

تكتسب هذه الدراسة أهميتها من المناطقات التالية :-

١. ان النجاح في فتح أفق المعالجة والبحث امام النصوص العربية اليدوية يمثل بداية انطلاق نحو فتح واستكشاف كنوز المخطوطات والكتب التراثية العربية عدد المخطوطات فقط فيها يصل الى ثلاثة ملايين مخطوطة تقريبا ؛ حيث ستتحول هذه النصوص الى مجموعات من المعلومات الرقمية قابلة للبحث والتکشیف على مستوى النصوص والكلمات والبحث في آفاقها الموضوعية الموسوعية.

٢. ستكتسب الويب نوعا جديدا من أدوات البحث قادرا على التعامل مع بحث واسترجاع النصوص اليدوية الرقمية، مما يجعل انتشار الكتابات اليدوية أسرع بقدر السرعة التي يكون عليها بحث واسترجاع النصوص المكتوبة يدويا.

٣. يمكن بناء نظم استرجاع متخصصة للنصوص اليدوية الرقمية بحيث تتحول مستودعات المخطوطات التراثية ومشروعات رقمنة التراث العربي الى مكتبات رقمية متخصصة في المخطوطات والكتابات العربية اليدوية.

٦ / منهج الدراسة

تتبّنى الدراسة استخدام منهج البحث الوصفي التحليلي وذلك لتبّع مجموعات الكتابات اليدوية العربية على الويب وتحري آليات المعالجة الحالية التي تتبنّاها أدوات بحث الويب في التعامل مع هذه المعلومات، واستقراء الانتاج الفكري والدراسات المرتبطة بهذه الظاهرة. بالإضافة الى استخدام منهج البحث التجاريبي وذلك للاحظة وتتابع موقع الويب المتخصصة ببحث واسترجاع المعلومات النصية اليدوية.

أما أدوات البحث فتتمثل في أداة البحث الوثائقي في جمع الانتاج الفكري المرتبط بظاهرة البحث، واستخدام أداة الابحاث والمعايشة مع الويب الى جانب استخدام أداة الملاحظة في الجوانب التطبيقية للبحث.

أما عينة الدراسة فقد عمل الباحث على اختيار عينة غرضية من موقع بحث المخطوطات العربية والأجنبية لاستقراء واقع تنظيم واسترجاع مواد الكتابات اليدوية في بيئه الويب، وقد تمثلت العينة في الجدول رقم (١).

جدول رقم (١) عينة الدراسة المستخدمة

الدولة	إدارة النظم	قواعد البيانات العربية
مصر	مكتبة الاسكندرية	http://wamcp.bibalex.org/
مصر	مجلس الوزراء	http://www.manuscripts.idsc.gov.eg/Manuscript/About.aspx
الإمارات	مركز جمعه الماجد	http://www.almajidcenter.org/ar/index.php
		قواعد البيانات الأجنبية
إنجلترا	المكتبة البريطانية	http://www.fihrist.org.uk
موريتانيا	جامعة الينوي	http://www.westafricanmanuscripts.org/default.php
بيروت	الجامعة الأمريكية	http://ddc.aub.edu.lb/projects/jafet/manuscripts/

٧ / حدود الدراسة : تتحدد الدراسة بالحدود التالية :-

- **الحدود الموضوعية** : تتناول الدراسة موضوع المعالجة والبحث لمواد المعلومات العربية المكتوبة يدويا من وثائق ومخوططات وغيرها من أشكال الكتابات اليدوية العربية.
- **الحدود النوعية** : تركز الدراسة على مواد الكتابات العربية وتعامل أدوات بحث الويب من حيث توفير آليات ومعايير البحث الملائمة.
- **الحدود المكانية** : ترتبط حدود الدراسة بمجموعات الكتابات العربية اليدوية على الويب في البيئة الرقمية، سواء تلك التي تنتهي للعالم العربي أو التابعة لمؤسسات دولية.
- **الحدود اللغوية** : تركز الدراسة على موضوع الكتابات العربية اليدوية دون اللغات الأخرى، واستخدام أدبيات الانتاج الفكري باللغتين العربية والإنجليزية التي تتناول الموضوع بالدراسة.

٨ / الدراسات السابقة

اتفقت أدبيات الانتاج الفكري العربي والأجنبي إجمالا على عدم تناول مواد الكتابات اليدوية على الويب من حيث التنظيم والاسترجاع كونها مواد معلوماتية لها طبيعة تنظيم

وتحليل واسترجاع مميزة عن غيرها. وقد اختلف كل من الانتاج الفكري العربي والأجنبي في زاوية تناول المخطوطات والكتب التراثية الرقمية ؛ حيث ركز الانتاج الفكري باللغة الأجنبية الذي جاء كاملاً من علوم الحاسوب على النواحي التقنية وعمليات الإدراك والتحليل لصور OCR حتى أنه استخدم مصطلح التكشيف Indexing للتعبير عن ناتج عملية الإدراك recognition، وقد توقفت الدراسات باللغة العربية عند تناول رقمنة المخطوطات وعمليات الفهرسة والضبط البibliographic، وقد تناول البعض منها تحليلًا لموقع المخطوطات من حيث التصميم والتقنيات المستخدمة. أما دراستنا الحالية فتعد الأولى في تناول مواد الكتابات اليدوية العربية من مخطوطات ووثائق تاريخية وكتب تراثية كمواد معلومات رقمية في بيئه الويب كتب بخط اليد ويتم تنظيمها ومعالجتها وتكتشيفها واسترجاعها باستخدام أدوات ومحركات بحث الويب. وقد استخدم الباحث قاعدة بيانات الرسائل الجامعية UMI proquest التي أفرزت الدراسات التالية :-

الدراسة الأولى :

Parves, Mohamed Tanvir. Arabic Handwritten text Recognition using structure and syntactic pattern attributes, King Fahd university, phd, 2010.
<http://search.proquest.com/pqdtglobal/docview/876013772/fulltextPDF?source=fedsrch&accountid=37552>

تناولت هذه الدراسة تقنيات وبرمجيات تحليل بنية صور نصوص الكتابات اليدوية الرقمية من حيث تحليل بنية الكلمات والحراف المصورة للتعرف عليها وإدراكتها، اعتمدت الدراسة في محورها على القراءة الآلية بنماذج ماركوف غير المرئية التي تستطيع تحليل صور وأبعاد الكلمات والحراف. ولم تخرج الدراسة عن إطارها التقني دون التطرق إلى عمليات البحث والاسترجاع على محركات البحث.

الدراسة الثانية :

Cao, Huagu. Indexing and retrieval of low quality handwritten documents, University of New York at Buffalo, PHD, UMI ProQuest LLC, 2008, cited at
<http://search.proquest.com/pqdtglobal/docview/305521651/fulltextPDF?accountid=37552>

تناولت الدراسة خصائص وطبيعة الصور الرقمية لمجموعات المخطوطات المعتمدة على تقنية **OCR**، وقد تناولت هذه الدراسة مصطلحات الاسترجاع والتكتشيف غير أن تناول

هذه المصطلحات لم يكن وفقاً لمفاهيم نظم المعلومات، وإنما بشكل برمجي وتقني جعلها تتعت عملية الإدراك للكلمات والحراف بمصطلح التكشيف، ومن ثم أتى مصطلح التكشيف **Indexing** والإدراك **Recognition** في شكل المترادفات.

الدراسات العربية :

أما الدراسات العربية مثل (مولاي محمد. المحتوى الرقمي العربي المخطوط على شبكة الانترنت : دراسة تقييمية) فقد ركزت هذه الدراسة على استخدام تقنية temesis لتحليل موقع المخطوطات العربية والأجنبية التي تضم مجموعات من المخطوطات المرقمنة، وذلك لقياس مجموعة من خصائص موقع الانترنت كالرؤية والتصميم والتقنية والخدمات والمحتوى المقدم في هذا الموقع. وقد اهتمت الدراسة بالجوانب التقييمية التحليلية لموقع المخطوطات عن دراسة المعالجة والتنظيم لمواد المخطوطات ذاتها. ودراسة أخرى مثل (حافظي زهير، أ. ملاح رشيد. فهرسة ورقمنة مخطوطات مكتبة جامعة الأمير عبد القادر للعلوم الإسلامية ووضعها ضمن شبكة الانترنت) حيث ركزت هذه الدراسة على عمليات الرقمنة والضبط الفني للمخطوطات المرقمنة وبناء مجموعاتها في البيئة الرقمية، دون التطرق إلى تحليلها أو الحديث عن أساليب البحث والتلخيص.

٩ / ٠ مصطلحات اجرائية

- **الكتابات اليدوية :** تمثل الكتابات اليدوية مجموعة مصادر المعلومات المكتوبة بخط اليد سواء تلك الكتب التراثية والمخطوطات أو مجموعات النشرات والمعلومات المكتوبة بخط اليد مباشرة باستخدام الحاسوب اللوحية الحديثة.
- **معالجة الكتابات اليدوية :** عمليات المعالجة للكتابات اليدوية الرقمية هي توفير قدرات المسح الضوئي والتعرف على أشكال الكلمات والحراف وهي الممهدة لعمليات التكشيف والتحليل الموضوعي لنصوص الكتابات اليدوية.
- **إدراك الكتابات العربية :** Handwritten Recognition هي عملية تحليل وقراءة آلية لصور الكلمات والحراف ومقاطع الكلمات الواردة في نصوص الكتابات اليدوية وفقاً لنقنية **OCR**.

المبحث الأول : الكتابات اليدوية العربية على الويب

شكل المحتوى العربي بصفة عامة والنصوص الرقمية العربية بشكل خاص صعوبة كبيرة أمام أدوات بحث الويب من حيث عمليات التنظيم والمعالجة والبحث والاسترجاع؛ حيث ترتبط بمواد المعلومات النصية العربية العديد من التحديات المتمثلة في الخصائص

الصرفية والتركيب في اللغة العربية، إلى جانب طائق الكتابة والأشكال المتعددة من الصياغات الفصحى والعامية، فضلاً عن إشكاليات الدلالة والترادف والمشتركات الفظوية واختلاف المعنى للكلمة الواحدة. وقد انتقلت هذه المشكلات إلى أدوات بحث الويب التي تعاملت معها عبر العديد من التقنيات والبرمجيات منتجة أشكال البحث باللغة الطبيعية وغيرها من آليات البحث، لكن ما شكل الصعوبة الأكبر هو انتقال تلك المشكلات إلى النصوص العربية المخطوطة بالأيدي خلاف تلك التي تم إدخالها عن طريق لوحات الكتابة على الحاسوب الآلي. فرقمنة الكلمات العربية منذ بدايتها تجعل نظم استرجاع المعلومات أكثر ادراكاً للحروف وتركيب الكلمات العربية أما انتقال النصوص العربية المكتوبة يدوياً إلى الشكل الرقمي يجعل ادراك معاني الكلمات غير ممكن في ظل انتقالها على هيئة صور للكلمات وليس حروف رقمية الأصل.

تختص النصوص العربية يديوية الكتابة بالعديد من الخصائص التي تمثل معها عملية بحثها واسترجاعها في بيئة الويب تحدياً كبيراً؛ فالكتابات العربية المخطوطة تتكون من ثمانية وعشرين حرفاً، تكتب بأشكال مختلفة، خلاف عمليات التشكيل والاعجام التي تتميز بها العديد من النصوص، هذا فضلاً عن مجموعات الوثائق والكتابات والمخطوطات والكتب التراثية التي لم تشهد حروفها وضع النقاط؛ حيث لم توضع النقاط على الحروف العربية إلا في وقت لاحق لعمليات الكتابة والنسخ العربية تحددت تقريرياً بالقرن السابع الميلادي. كما تختص نصوص اللغة العربية بعلامات مساعدة كالشدة وعلامات الضبط النحوي وغيرها بما يعود على نظام القراءة الآلي بمزيد من صعوبات الادراك لمواد المعلومات.^١




Fig. 1. Examples of Arabic words written in different fonts and styles:
(a) nine (b) one or part eleven, and (c) eighty.

شكل رقم (١) يوضح الاشكال المتعددة لكتابة الكلمات العربية^{*}

وقد أورد zaher al aghbari and salama brook بعضًا من خصائص اللغة العربية في الكتابة عامة والكتابات اليدوية خاصة التي تمثل تحدياً أمام نظم إدراك وتحليل نصوص الكتابات اليدوية على الويب، تتمثل في :-

(١) تكون اللغة العربية من ثمان وعشرين حرفاً، تتعذر أشكال كتابة الحرف الواحد بين شكلين إلى أربعة أشكال، فضلاً عن الحروف المتشابهة رسماً والمختلفة في النقاط التابعة لها.

(٢) تكتب كلمات اللغة العربية بحروف متشابكة من اليمين إلى اليسار، مع وجوب اتباع الفواصل بين الكلمات والحرروف.

(٣) تكون أكثر كلمات اللغة العربية من مقطعين أو أكثر تمثل صعوبة أمام الحاسب أثناء التعرف على الكلمات والمفردات في عملية الإدراك.

(٤) تكتب حروف اللغة العربية بالكتابة في رسم يميل إلى أسفل أو يرتفع إلى أعلى السطر مع تميز بعض الحروف بالاتفاق في الخط أثناء كتابتها (ط، ض).

(٥) تتبع الحروف في اللغة العربية توابع ثانوية مثل النقاط التي تأتي أسفل أو أعلى الحروف، والهمزة التي تأتي مع بعضها الآخر (ك، ق).

١ / ١ أشكال الكتابات اليدوية الرقمية

تنوع الكتابات الرقمية ذات الشكل اليدوي على الويب ؛ حيث تستمد الكتابات اليدوية هذا التنوع اعتماداً على أصل النشأة لهذه المواد، فمنها ما هو تقليدي الأصل مثل الكتب التراثية والمخطوطات والوثائق التاريخية التي تدخل إلى بيئة رقمنة اعتماداً على أجهزة النسخ الضوئي **optical character recognition** المعروفة باسم **OCR** ؛ حيث يتم من خلالها استيعاب النصوص والمتون التقليدية أو المطبوعة في البيئة الرقمية وإدراك ما تحمله هذه المواد من كلمات وحروف. ومن مواد المعلومات أيضاً ما يعود إلى أصل رقمي النشأة وهو ما يتجلّى في استخدام الحاسوبات اللوحية **Tablet PC** وأجهزة الهواتف النقالة ذات أنظمة التشغيل الذكية مثل **Andorid** المنتجة بواسطة شركة **google**.^٤ وتعمل هذه التقنيات الحديثة على دعم حروف اللغة العربية منذ إدخالها وامكانية التعامل مع الكلمات المكتوبة فور إدخالها بالمعالجة والبحث والاسترجاع. ومن ثم فإن النصوص العربية اليدوية في البيئة الرقمية تتتنوع بين شكلين أساسيين هما :-

١ / ١ الكلمات والحواف المصورة

إن الكلمة المصورة هي الوحدة الأصغر في قواعد بيانات النصوص والكتابات العربية اليدوية الرقمية ؛ حيث تعمل تقنيات المسح الضوئي على التقاط صور شاملة لصفحات ووثائق الكتابات العربية ومن ثم يبدأ نظام قاعدة البيانات على استقراء الكلمات والحواف باستخدام تقنيات معالجة الصور الرقمية. وتحوّل حروف اللغة العربية في هذه الحالة إلى مقاطع مصورة أكبر هي الكلمة المكتوبة التي بدورها تكون مقطعاً في صورة أكبر للوثيقة التاريخية أو صفحة المخطوط العربي. ويتعامل نظام إدارة المجموعات النصية هنا بآليات القراءة والاسترجاع للصور الرقمية الثابتة ؛ فتباعد الحروف وارتباطها ومقاطع الكلمة الواحدة والمسافات الفاصلة بينها وبين الكلمات الأخرى لا تundo كونها مسافات رقمية تقاس بنقاط كثافة الصور الرقمية (**pixels**). وتتبنى على هذه الآلية العديد من أساليب الحاسوبات الرقمية التي تحكم في التعامل مع الكلمات الرقمية المصورة ؛ فيمكن للنظام على سبيل المثال تحديد قياس ثابت وشكل تصويري محدد لحرف الألف (أ) الذي يعبر في أغلب حالات اللغة العربية على بداية كلمة جديدة، بما يعني حساب المسافات والقياسات البدائية والمنتهية لهذه الكلمات ثم تحديد نقاط الكثافة للكلمة وتحديد الشكل أو الأشكال التي وردت عليها، ومن ثم اشتغالها واختزانها في ملف الكلمات المشتقة من النص لتجهيزها لعمليات المضاهاة والبحث فيما بعد. وقد نفذ فريق من الباحثين هذه الآلية في تصميم نظام للتعامل مع الوثائق العربية المكتوبة يدوياً سمي

— **CEDARABIC system** اعتمد في بناء قاعدة بياناته على عشرة وثائق يدوية الكتابة لعشرة كتاب مختلفين حتى يتم التعامل مع الخطوط المتباعدة للكلمات العربية وتكونت كل وثيقة من كلمات تراوح عددها بين ١٥٠ إلى ٢٠٠ كلمة بما يعادل اجمالاً ٢٠٠٠ كلمة يمكن التعامل معها في قاعدة بيانات النظام.

١ / ٢ الكلمات والحروف النصية

يكن الفارق في العمل بين الكلمات والحروف المضورة وهذه النصية في اعتماد أدوات المعالجة في حالة الكلمات والحروف النصية المكتوبة يدوياً على قاعدة بيانات مسبقة لمجموعات الأشكال المختلفة من حروف اللغة العربية، التي تستطيع التقارب مع الكلمات حالية الادخال بواسطة يد المستخدم ومن ثم إدراك الكلمات والحروف في الوقت الحقيقي لعملية الكتابة **real time recognition**. ويمكن القول بشكل آخر أن عملية المضاهاة وانتاج وقواعد بيانات الكلمات والحروف المكتوبة يدوياً في حالة النصوص اليدوية ذات الأصل المطبوع او التقليدي تكون لاحقة لعملية القراءة والادراك، أما في حالة الكلمات النصية فإنها تكون سابقة لعملية الادراك ولعملية الكتابة والنشأة بشكل رئيسي. وعلى ذلك فإن قواعد بيانات نصوص الكتابات اليدوية ذات الأصل الرقمي تكون أكثر جاهزية وفاعلية في التعامل مع أدوات بحث واسترجاع الكتابات اليدوية عنها في النصوص المضورة، ذلك لما لها من إدراك وتعريف سابقين، حيث يمكن تمييز وتحديد الكلمات والحروف موضع البحث والاسترجاع.

١ / ٢ رقمنة الكتابات اليدوية (OCR)

تمثل تقنية القراءة الضوئية للحراف **optical character recognition (OCR)** الباب الرئيس للتعامل مع مواد الكتابات اليدوية ليس من خلال الويب فقط، وإنما من خلال البيئة الرقمية ككل. فتحويل النص إلى قدرة القراءة الآلية وإدراك الحروف والكلمات ينبغي عليه كل ما يلي من إجراءات معالجة للكتابات اليدوية. وتعمل تقنية **OCR** على أنها عملية نقل الحروف والنصوص التقليدية إلى بيئه الحاسب الآلي من خلال أدوات تقنية كالكاميرات الرقمية وأجهزة الماسح الضوئي **scanners** لرقمنة هذه النصوص والتعامل معها حفظاً وتنظيمها وبحثاً كونها صورة رقمية. وتقوم تقنية **OCR** على آلية تصوير النصوص التقليدية وتحويلها إلى صور رقمية تقرأ داخل الحاسب الآلي بأكواد مخصصة كما في شفرات **ASCII text**. وتواجه تقنية المسح الضوئي نوعين مختلفين من أنواع الكلمات والخطوط التي تتعامل معها، فالكتابات التقليدية المطبوعة هي أكثر يسراً في

الإدراك والمعالجة عن تلك الكتابات اليدوية ؛ حيث تختلف مواد الكتابات اليدوية في أنواع الخطوط من كاتب إلى آخر، فضلاً عن الكتابات ذات الحروف المتصلة، التي تمثل تعقيداً أكبر أمام التعرف على كل حرف بشكل منفصل. وحري بالذكر أن معالجة OCR للنصوص التقليدية لا يتوقف عند كونها أداة رقمنة وحسب، بل تمتد إلى مستويات القراءة والإدراك وفهم النصوص المضورة رقمياً، فهي بذلك تتعذر حاجز الرقمنة إلى المعالجة والبحث للكتابات اليدوية.^٧


تمتلك نظم OCR مجموعة من قدرات التشغيل التي توفر سرعة إدراك وقراءة النصوص المضورة ؛ حيث يمكن لهذه النظم إدراك أنواع الخطوط وخاصة في الكتابات اليدوية، أيضاً حجم كتابة الكلمات وتنسيقات الفقرات المكونة للنصوص، بالإضافة إلى الجداول والرسوم التوضيحية والصور المرفقة ضمن النصوص. وتعمل هذه التقنية بمعدل قراءة وإدراك صفحة مطبوعة من حجم A4 في مدة دقيقة واحدة، ويمكن لهذه التقنية أن تعمل على أنواع مخصصة من الكتابات والنصوص، بل ويمكن لهذه التقنية إدراك الأنواع المخصصة من الكلمات والأرقام كذلك التي توجد في طوابع البريد واللقطات المصغرة. وتعتمد تقنية OCR على آلية انتخاب الكلمة أو المصطلح المقصود آلياً حتى يمكن تحديد الحرف أو الرقم بشكل مؤكد. وقد ذكرها Sebastian Stoliński, Wojciech Bieniecki رقمنة وإدراك النصوص المطبوعة تتم في أربعة خطوات هي :-^٨

الخطوة الأولى : معالجة صفحات الكتابات اليدوية عن طريق إزالة التحسيات والكتابات الزائدة وضبط خصائص السطوع والتعارض في ألوان الصورة المنتجة.

الخطوة الثانية : هي إدراك الصفحة من خلال عنصرين أولهما : تحليل الصفحة والتعرف على عناصرها الداخلية مثل الأرقام والحراف والجداول، ثانياًهما : إدراك الحروف والتعرف عليها من خلال تحديد حروف وكلمات فرضية للمقطع أو الحرف المصور.

الخطوة الثالثة : ضبط علاقات الحروف والمقاطع ببعضها والربط بين الحروف وال نقاط وعلامات الاعجام وغيرها.

الخطوة الرابعة : البحث داخل الحروف المعرفة ومحاولة استخدامها لإدراك الحروف التالفة.



II. Phases of General Character Recognition System

شكل رقم (٢) يوضح الخطوات المتبعة لرقمنة وإدراك الكتابات اليدوية وفقاً لتقنية **OCR**^٩ يمكن الهدف الرئيس لتقنية **OCR** في مرحلة ما بعد المعالجة في التأكيد على سلامة وصحة الحروف والكلمات التي تم إدراكتها والتعرف عليها، وذلك من خلال قوائم الحروف والكلمات المسحولة مسبقاً في قاعدة البيانات تبعاً للغة التي يتم معالجتها. وتستند قواعد بيانات **OCR** هنا على استخدام الأساليب الإحصائية في التعرف على الكلمات والمقطوع بجانب المعالجم اللغوية ومحللات اللغة، ويمثل نموذج **hidden Markov model** (HMM) أهم آليات العمل في تقنيات إدراك وتحليل الحروف الضوئية. وعلى ذلك فإن التكامل بين نظام إدارة قواعد بيانات الكتابات اليدوية **DBMS** وبين نظام معالجة الكلمات الضوئية أمر ضروري، وذلك حتى تعمل قاعدة البيانات بالكفاءة المطلوبة في عمليات البحث والاسترجاع للكتابات اليدوية وفقاً لحاجة المستفيد الموضوعية. ويرى الباحث أن ثمة مبادئ لا بد أن تتوافر في نظم معالجة **OCR** تتمثل في أولاً المرونة التي يجب أن يتحلى بها النظام في التعامل مع الكتابات اليدوية وخاصة العربية منها، ثانياً الدقة في عمليات التحليل والإدراك الإحصائية التي تبني على الأساس على استخدام الصيغ الاحتمالية في التحديد النهائي للحروف والكلمات. ثالثاً التكامل في الاستعانة بأدوات لغوية تتميز بالتعقق والدقة في عرض مفردات اللغة.^{١٠}

١ / ٣ البنية الرقمية للكتابات اليدوية (الكلمة المchorة)

تتعامل الويب وأدوات بحثها مع مواد ووسائل حمل المعلومات معالجة وتنظيمها واسترجاعاً وفقاً لطبيعة البنية والتكونين اللذين تتواجد بهما المعلومات الرقمية. ويسري هذا المبدأ على مواد الكتابات اليدوية الرقمية، فبحسب بنية الكتابات اليدوية تبدأ أدوات بحث الويب في تجهيز وتصميم البرامج والآليات المعالجة والاسترجاع المتواقة وبنية الكتابات اليدوية الرقمية، وخاصة العربية منها لما لها من خصائص لغوية مميزة. وبالنظر لواقع البنية والبيانات الرقمي للكتابات اليدوية على الويب، فإنها تجمع في صفاتها الوراثية المعلوماتية بين وسيطي النص والصورة الرقميين، فالنصوص الرقمية تتعامل معها أدوات البحث معالجة واسترجاعاً وفقاً لبنية صفحات ومحارف HTML، أما وسيط الصورة الرقمية فإن أدوات بحث الويب تسلاك سبلة أخرى مثل تحليل المحتوى content من خلال تحليل البنية واللون والشكل texture, color and shape based. وعلى ذلك فإن بنية الكتابات اليدوية تمثل مشكلة كبيرة أمام أدوات بحث الويب في كونها نص مصور أو صورة نصية تحتاج إلى دراسة آليات الإدراك والمعالجة لحروف وكلمات لا تقاس بالمعاجم اللغوية أو التحليل الصرفي إنما تقاس بمدى كثافة الصورة image resolution ووحدات قياس الأشكال المضورة pixels. ويرى الباحث أن نظم استرجاع الكتابات اليدوية على الويب تحتاج إلى معايير معالجة وآليات تنظيم واستراتيجيات بحث مزجية بين ما تستخدم للنصوص والصور، كما أن هذه النظم ستحتاج بشدة إلى أدوات عمل لغوية كالمعاجم اللغوية الرقمية والمحللات الصرفية، بالإضافة إلى برمجيات معالجة وقراءة الصور الرقمية.

تتعامل أدوات بحث الويب مع الصور الرقمية من خلال النصوص المصاحبة للصورة الممثلة في عناصر الميتاداتا metadata والنصوص الواردة في متن صفحة الويب التي وردت بها الصورة وتأخذ منها امتدادها الرقمي URL. وذلك حيث لا تتوافق لدى محركات بحث الصور الرقمية حتى الآن تقنيات التعامل مع ملفات الصور الرقمية وتحليل عناصرها الرسومية المضورة، غير أن هذا التفاعل لا يتوافق وتحليل صور الكتابات اليدوية؛ حيث لن يقف حد المعالجة والبحث عند النصوص المصاحبة أو حقول الميتاداتا، إنما يتعدى ذلك إلى تحليل أشكال الحروف والكلمات الواردة في الصورة الرقمية، حتى يتم بحث نصوص الكتابات اليدوية ذاتها، وهو المستهدف من رقمنة الكتابات اليدوية على الويب. وما يمكن أن يحدث تأثيراً إضافياً هو موقع صور الكتابات اليدوية على الويب، كونها توجد داخل قواعد بيانات رقمية متاحة على الويب، أو من خلال التواجد داخل

متون صفحات وموقع الويب ؛ حيث تختلف بنية الملف الرقمي الذي يحمل الصورة في قاعدة البيانات المهيكلة عنها في ملفات الصور على صفحات HTML. فتحمل الصورة الرقمية في قاعدة البيانات مجموعة من العناصر البليوجرافية للميتادات مثل Dublin Core التي تمثل وصفاً فنياً معيارياً لمواد الصور الرقمية، وفي الوقت ذاته تفتقر ملفات الصور داخل صفحات الويب إلى هذه المعايير. ويؤكد ذلك كله أن الصور الرقمية التي تحمل نصوص الكتابات اليدوية سوف تتبادر في ملامعتها للمعالجة الاسترخاع داخل محركات البحث.^{١١}

إن الاهتمام بما ستكون عليه البنية الرقمية لصور الكتابات اليدوية الرقمية على الويب المرقمنة بالمسح الضوئي هو أول خطوات التجهيز لما قبل المعالجة والتفاعل مع محركات بحث الويب. فالبنية الرقمية المزودة بملف رقمي يشتمل على عناصر وصف فني معيارية يمكن محركات البحث من دقة التنظيم والبحث للكتابات اليدوية الرقمية. هذا بالإضافة إلى استخدام عناصر وصف للمنت و النص تمثل مرآة نصية للكلمات والحراف الواردة في صورة الوثيقة أو المخطوط، ويقترح الباحث إضافة حقول أخرى تتوافق وصور الكتابات الرقمية مثل حقل content أو المحتوى لنقل النص الوارد في صورة الوثيقة حيث يمكن لمحركات البحث استخدامه في البحث النصي ومعالجته وفقاً للمعاجم والمحللات الصرفية. ويتم إضافة هذه الحقول إلى تلك التي خلصت إليها أطروحة الباحث للماجستير عن الصور الرقمية، ومن ثم تكون العناصر الموافقة صور الكتابات اليدوية كالتالي^{١٢} :

جدول رقم (٢) عناصر المعالجة والضبط المقترنة لمواد الكتابات اليدوية على الويب

المعيار	المستهدف	العنصر
DC	عنوان المادة	العنوان :
DC	المؤلف	(المؤلف) :
DC	رؤوس موضوعات	الموضوع :
DC	تاريخ OCR	تاريخ التقاط الصورة :
DC	النشر على الويب	تاريخ صنع الصورة الرقمية :
DC	بنية قواعد البيانات	تاريخ وضع التسجيلة :
DC	اسم قاعدة البيانات أو موقع الويب	الناشر :
DC	برمجيات القراءة والعرض	شكل ملف الصورة :

DC	الحجم بوحدات القايس بالميجابايت	حجم ملف الصورة :
DC	الهيئة المسئولة عن النشر	حقوق نشر الصورة :
مقتراح	كتب التراث المنسوخة او الوثائق	الناسخ أو الكاتب
مقتراح	(مخطوط او وثيقة)	النوع
مقتراح	النص الكامل لصفحة او الوثيقة	النص الكامل
مقتراح	الهيئة التراثية او المتحف المسجلة لديه المادة	الهيئة المسئولة
مقتراح	مسار الوصول الرقمي على الويب	المصدر على الويب URL

المبحث الثاني : معالجة وتكشيف الكتابات اليدوية على الويب

١ / بيئة المعالجة الرقمية لكتابات اليدوية

فرضت البيئة الرقمية للويب بتقنياتها المختلفة مجموعة من آليات معالجة مواد المعلومات الرقمية تمثل دورها فارقا جليا بين طبيعة المعالجة داخل أدوات بحث الويب **on-line**، وبين معالجة نفس مواد المعلومات في قواعد البيانات التي تعمل خارج أو داخل النطاق الشبكي **off-line**. حيث يمكن تشبيه الفارق هنا بفارق بين آلية العمل داخل النظم المغلقة والعمل داخل النظم المفتوحة ؛ فتمثل قواعد بيانات مواد المعلومات الرقمية خارج نطاق الويب بيئة النظم المغلقة، فلا يرتبط نظام إدارة قاعدة البيانات بغير مجموعات المعلومات المختزنة داخل قاعدة البيانات، فعليه تتم عمليات المعالجة وعليها أيضا تتم عمليات البحث والاسترجاع من جانب مستخدمي قاعدة البيانات دون اتصال او ارتباط شبكي على الخط المباشر. أما انتقال نظام إدارة قاعدة البيانات الى تقديم البحث والاسترجاع من خلال الرابط الشبكي فإنه بذلك يتخطى حاجز النظم المغلقة الى حدود النظم المفتوحة التي تتبدل المعلومات في اتجاهين مستمرتين هما استقبال الاستفسارات البحثية وارسال النتائج المسترجعة داخل شبكة المعلومات (الخط المباشر).


ويرى الباحث أن اختلاف نمط العمل على مجموعات الكتابات اليدوية بين قواعد البيانات خارج الرابط الشبكي وقواعد البيانات على الويب يمثل بينيتين مختلفتين تماما للعمل على معالجة وبحث الكتابات اليدوية الرقمية. فممة متطلبات وأدوات للمعالجة ينبغي توافرها لاستكمال عمليات المعالجة والبحث المتكاملة لكتابات اليدوية إذا ما أرادت قواعد بيانات الكتابات اليدوية تقديم خدماتها على الخط المباشر من خلال موقع الويب، وهو في غالب الأمر سيتمثل في موقع المكتبات الرقمية التراثية ومركزا حفظ التراث والمخطوطات. وبناء على ما تقدم فإن معالجة الكتابات اليدوية تتم في بينيتين مختلفتين

تحتاج كل منها إلى آليات ومعايير مختلفة، وذلك كما يلي :-
١ / ١ المعالجة في بيئة قواعد البيانات off-line

تف معالجة الكتابات اليدوية في قواعد البيانات عند حدود الوصف والإدراك للكلمات والحرروف داخل الوثائق المكتوبة يدوياً، ولا تتعذر ذلك إلى عمليات المعالجة المعلوماتية التي تشمل عمليات التحليل الموضوعي وبناء آليات البحث والوصف الفني للمعياري لمواد المعلومات داخل قاعدة البيانات. فالنتيجة النهائية لقاعدة البيانات هي كلمات بحثية تتطابق وصور الكلمات والحرروف موضوع المعالجة. وتعمل قواعد البيانات وفقاً لنظرية النظام المغلق في معالجة مجموعات الكتابات اليدوية على عناصر داخلية متكاملة وأهم هذه العناصر هو مستودع من الحروف والكلمات في شكل صور ثابتة؛ حيث يبني على استخدام هذا المستودع محاولة إدراك الكلمات والحرروف داخل الكتابات اليدوية. وتتوقف عمليات الضبط البليوجرافي في قواعد البيانات عن أرقام الترميز IDs التي تعطى لكل وحدة أو كلمة داخل قاعدة البيانات حتى يتم استرجاعها فيما بعد كما في شكل (٣). ولا يتطلب العمل في قواعد البيانات خارج الويب التحليلي بدعائم الربط مع محركات البحث مثل محرف الترميز meta tags أو حقول الوصف العام لمواد المعلومات التي من خلالها تستطيع محركات البحث تدقيق عمليات التكشيف والتحليل. وقد ذكر Yefeng Zheng, Yi Li, David Doermann في دراستهم عن تحليل وإدراك الكتابات اليدوية آلية العمل التي تسير عليها قواعد البيانات، وهي :-^{١٣}

- أولاً : يتم رصد الكلمات ومقاطع الكلمات داخل الصفحة مع ترميزها برموز محددة IDs.
- ثانياً : يتم الوقف على الشكل النهائي لمقاطع أو الكلمات مع عرضها على مستودع الكلمات المضورة حتى يتم تحديد شكل المقطع أو الحرف.
- ثالثاً : يتم حساب أو وزن كل مقطع بالنسبة للسطر الذي وجد به حتى يرمز له بكونه مقطع أو كلمة كاملة يتم التعرف عليه.
- رابعاً : المقاطع التي لا تمثل كلمة أو حرف محدد يتم ترتيبها وفقاً لمقاييسها ثم وضعها في أسطر لإعادة معالجتها مرة أخرى.
- خامساً : يتم رصد الصورة الأقرب لمقاطع التي تدل على هوية المقطع إذا ما تجاوزت درجة التقارب نسبة ٥٠%.
- سادساً : يتم اعتبار المقاطع التي تم التعرف عليها مقاطع معرفة أو محددة processed .

سابعاً : يتم تجميع المقاطع الأقرب كتابة أو الأكثر تلزماً واعتبارها كلمة واحدة لمقاطع متعددة.



شكل رقم (٣) معالجة الكتابات اليدوية في بيئة قواعد البيانات خارج الخط المباشر^{١٤}

١ / ٢ المعالجة في بيئة الويب on-line

تضمن بيئة الويب شتاتاً ضخماً متنوعاً من مواد المعلومات الرقمية تختلف فيما بين النصوص والصور والمواد السمعية تقليدية الأصل ورقمي النشأة، وتتبع الويب درب ما يضاف إليها من أنماط جديدة من المعلومات الرقمية بالمعالجة والبحث والاسترجاع من خلال أدوات بحثها التي تعمل على مدار الثانية تنظيمها واسترجاع لفضاء الويب. ولعل الكتابات اليدوية الرقمية أحدث أشكال مواد المعلومات التي تنظر لها الويب بعين التنظيم بغية إحكام التوافق بينها وبين محركات البحث حتى تيسر لمستخدمي الويب الوصول إلى تلك الكتابات وتحقيق مبدأ الاتاحة والاستخدام. وإذا كانت قواعد البيانات خارج الويب تمثل النظم المغلقة، فإن الويب بفضائها وأدوات بحثها تمثل بحراً لا شطآن له من مواد المعلومات الرقمية تحرر داخلها سفن محركات البحث لجمع واصطياد كل ما تجده من مواد معلومات لإيصاله إلى المستفيدين. ومن ثم فإن تواجد مواد الكتابات اليدوية الرقمية في فضاء الويب سواء أكانت في جوف قواعد البيانات أو على موقع وصفحات [html](#) يجعل محركات البحث منوطة بالوصول إلى كلمات وحروف الوثائق والمخطوطات الرقمية ومعالجتها لدعم الوصول والاتاحة أمام مستخدمي الويب.

إن الويب تعتمد على أدوات بحث ذات مكونات محددة متكاملة الأداء والعمل تهدف جميعها إلى تحقيق غاية أدوات البحث في ضم ومعالجة واتاحة مواد المعلومات الرقمية على الويب، ومن ثم فإن أول ما يمكن التفكير به هو جعل الكتابات اليدوية العربية من مخطوطات ووثائق بصيغة رقمية تتوافق وطبيعة عمل برامج أدوات البحث ؛ فكيف يمكن لبرامج الزاحف أو العنكبوت **spider or crawler** أن تصل إلى الكتابات اليدوية الرقمية و تستطيع نسخها واصفتها إلى قاعدة بيانات محرك البحث دون أن تكون هذه المواد بصيغة رقمية تسمح لبرامج الزاحف بالتعامل معها، أيضا لا يمكن لبرامج المكافحة **indexer** أداء مهامها داخل محرك البحث بتكتشيف وتحليل محتوى مواد معلومات الويب دون أن تكون مواد الكتابات اليدوية على الشكل الذي يمكن برنامج المكافحة من التعرف على الكلمات الدالة أو الكشفية في الوثيقة أو المخطوط. وعلى ذلك فإن مواد الكتابات العربية اليدوية تحتاج إلى التوافق وبنية **HTML** التي تسحب محركات البحث داخل مخارفها وتعتمدها في اتمام عملها.


يبقى في هذا الصدد الحديث عن تحد مهم يكاد يقطع الطريق على محركات البحث في التعامل المباشر مع مواد الكتابات اليدوية العربية، ألا وهو أن المخطوطات والوثائق التي تحمل النصوص اليدوية العربية تتواجد في بيئه الويب في شكل صور ثابتة تحمل أشكالا من الكلمات والحراف لا تكاد تعيها محركات البحث أو تستطيع إدراكتها سوى كونها صورة رقمية **digital image**. وقد تمحورت دراسات محركات البحث في التعامل مع الصور الرقمية من خلال النصوص المصاحبة التي تتواجد في موقع او صفحة الويب التي تحوي الصورة، وبناء على ذلك فإن محركات بحث الويب تحتاج إلى آلية تحليل الكلمات داخل الصورة وإدراكتها فيما يعرف بأآلية البحث باستخدام المحتوى **content word based image retrieval .image recognition**

٢ / معالجة وإدراك الكتابات اليدوية الرقمية

إن ثمة حقيقة مؤكدة في واقع التعامل مع الكتابات اليدوية على الويب من خلال أدوات بحث الويب، ألا وهي أن مواد الكتابات العربية على الويب عبارة عن مواد نصية في وسائل معلومات مصورة. واعتمادا على هذه الحقيقة المعلوماتية يمكن البناء لكل ما سيأتي فيما بعد في التعامل مع مواد الكتابات اليدوية كمواد معلومات يتم معالجتها

وتنظيمها وبحثها واسترجاعها من خلال محركات البحث أو باقي أدوات بحث الويب. لقد تناول الباحث في دراسة له من قبل التعامل مع الصور الثابتة وكيفية معالجتها وآليات توافق محركات البحث معها تنظيمًا واسترجاعًا، غير أن الفارق الجوهرى في حالة الكتابات اليدوية على الويب يمكن في أن المعالجة والتنظيم يمتد إلى داخل بنية الصورة والمتمثلة في النصوص الكتابية المخطوططة بالأيدي، التي تستمد الكتابات اليدوية أهميتها والحرص على تنظيمها من النصوص والمتون التي هي غاية رقمنة الكتابات اليدوية بالأساس.

لقد عملت الويب على تعديل العديد من المفاهيم والمصطلحات المرتبطة بنظم استرجاع المعلومات؛ حيث سيمر البحث هنا بمرحلتين متتاليتين كانتا قد انضمتا فيما سبق في التعامل مع جل مواد المعلومات الرقمية على الويب، ثم يرى الباحث هنا حتمية فصلهما وهما مرحلتي المعالجة والتكتشيف لمواد الكتابات اليدوية على الويب. فمرحلة المعالجة هنا تركز على كيفية قراءة وإدراك أشكال الكلمات المصوره داخل مواد الكتابات اليدوية والعمل على تحويلها إلى نصوص مفهومة من قبل نظم وأدوات البحث على الويب حتى يمكن التعامل معها تنظيمًا واسترجاعًا. أما العنصر التالي بعد ذلك ترتيباً وتفعيلًا هو تكتشيف الكتابات اليدوية على الويب والتعرف على الكلمات الكشفية الدالة على الموضوعات والأفكار التي ترخر بها الكتابات اليدوية مثل المخطوطات والوثائق التاريخية. ويمكن الحديث هنا عن المعالجة في إطار المراحل التي تأخذها مواد الكتابات اليدوية منذ كونها مواد معلومات تقليدية أو مطبوعة إلى كونها مواد رقمية على الويب. وتتمثل في ثلاثة مراحل هي ما قبل المعالجة والمعالجة ذاتها ثم مرحلة ما بعد المعالجة من إجراءات، وذلك كما في شكل (٤).



شكل رقم (٤) مراحل وإجراءات المعالجة والإدراك لكلمات الكتابات اليدوية على الويب^{١٥}

يوضح شكل (٤) البنية العامة لعملية المعالجة والإدراك لكلمات الكتابات اليدوية على الويب بمراحلها الثلاث والإجراءات المتدعية داخل كل مرحلة، وذلك على النحو التالي

-:

٢ / ١ / ٢ مرحلة ما قبل المعالجة Pre- Processing

تبعد مرحلة المعالجة والإدراك للكتابات اليدوية بعض الإجراءات التجهيزية لمواد الكتابات اليدوية تشكل معاً مرحلة ما قبل المعالجة، وذلك انطلاقاً من أن إدراك الكلمات المضورة داخل الكتابات اليدوية يتم بشكل رقمي خالص مما يستوجب معه ضبط هذه

النصوص حتى تتسم عملية الإدراك بالدقة الكافية لمعرفة الكلمات والحراف والمكتوبة المكونة لمتن الكتابات اليدوية. وتتلخص الإجراءات التجهيزية فيما يلي :-

٢ / ١ / ١ تطبيع الكتابات اليدوية الرقمية normalization

تتسم عملية المسح الضوئي عامة بتباين درجات جودة الناتج النهائي من الصور الضوئية الرقمية، وهذا على اختلاف طبيعة مواد المعلومات التي يتم رقمتها من خلال الماسح الضوئي. وتزداد درجات الجودة في حالة المعلومات المصورة عنها في المعلومات النصية، خاصة تلك النصوص ذات الكتابات اليدوية التي تخضع جودتها لجودة خط الكاتب، وعدم تأثر الوثيقة الأصلية بعوامل التلف والطمس. وعلى ذلك فإن ثمة عملية يطلق عليها التطبيع لا بد أن تمر خلالها مواد الكتابات اليدوية الرقمية بعد رقمتها وقبل إخضاعها لبرامج الإدراك والقراءة. وتهتم عملية التطبيع برفع درجة جودة صور الكلمات والحراف في الكتابات اليدوية من خلال حذف الزوائد والصور التشويشية حتى يمكن تأمين دقة قياس الارتفاع والانخفاض والامتداد لحراف ومقاطع وكلمات الكتابات اليدوية، ومن ثم تحديدها بواسطة الحاسب والتعرف عليها. وتنتهي عملية التطبيع بوضع خط وهي يمر منتصف الكلمات والحراف عرضه يساوي نقطة واحدة في كثافة الصورة one-pixel-wide حتى تمثل مرتكزا لقياس أبعاد الحروف والكلمات.^{١٦}

٢ / ١ / ٢ التقسيم والتجزئة Segmentation

تحتوي صفحات الوثائق والمخطوطات على العديد من أشكال المواد المصورة والنصية، تختلف بين الصور والجدوال والعلامات والكلمات. وحيث أن التركيز هنا يكون على معالجة وإدراك الكلمات والحراف، فإنه يتم تجزئة وتقسيم صفحة الوثيقة أو المخطوطة إلى أسطر منفصلة يستقل كل منها بمعالجة محددة، ثم يتواتي بعد ذلك تقسيم وتجزئة السطر الواحد إلى مجموعة الكلمات والمقاطع داخل السطر، ومنها يتم تقسيم كل مقطع وكلمة إلى الحروف المكونة لها. وذلك كله يأتي في منظومة التعرف على الوحدة الأصغر في النص ثم بناء التراكيب والتتابع اللازمين لتكوين شكل الكلمة النهائية اعتماداً على المعاجم اللغوية. وتزداد صعوبة تقسيم الأسطر وتمييزها من الكتابات المطبوعة إلى الكتابات اليدوية، وذلك لاتسام الكتابات اليدوية بالعديد من الخصائص مثل امكانية تداخل الخطوط وفقاً لجودة الكتابة، أو تعدد متابعة الأسطر وتحرير المساحات الفارغة في الوثيقة، أو التحسينات الدخيلة على النص من تعليقات وغيرها.^{١٧}

وتنتقل عملية التجزئة من الأسطر إلى تجزئة الكلمات لحروف ومقاطع يطلق عليها **graphemes**، وتعتمد نظم الإدراك على آليات تستخدم نقاط الضبط الرقمية المحددة للاتجاهات الأفقية والرأسية للكلمات **horizontal and vertical projections**. كما تستخدم المعاملات الرياضية والتصويرية **mathematical morphological techniques** للتعرف الحروف المكونة للكلمة من خلال استخدام نقاط قياس الكثافة والرسم شكل تقريري للمسارات التي يمر بها الحرف في صورة الكلمة ككل، ومن ثم التعرف على الشكل النهائي لهذا الحرف، كما في شكل رقم (٥).



شكل رقم (٥) تجزئة الكلمات الى حروف باستخدام الامتدادات التصويرية للكلمة

٢ / ١ / ٣ استخراج الملامح Feature Extraction

يمثل إجراء استخراج أو اشتقاء ملامح الكلمات والحروف خطأ فاصلاً بين مرحلتي ماقبل المعالجة والإدراك للكتابات اليدوية، فاستخراج الملامح الشكلية التي تصف اتجاهات وأبعاد الحروف يعمل على تمييز شكلي محدد لحروف اللغة في ذاكرة نظام إدراك الكتابات اليدوية. ويترتب على عملية التحديد المميز لكل حرف امكانية التواصل مع المعاجم اللغوية بشكل محدد للحرف يسهل استخراج الحرف الموافق للملاح الشكلية المشتقة. وتنتمي عملية اشتقاء الملامح اعتماداً على ترحيل شكل الحرف من الوثيقة إلى شاشات النظام لتصفيته الرقمية حتى يختفي الشكل الحقيقي للحرف وتظهر نقاط رسومية ممثلة لبنية الحرف الرقمية من اتجاهات وأبعاد وزوايا يمر بها الحرف في كتابته. وتراعي نظم إدراك الكتابات اليدوية خصائص حروف اللغة العربية التي تتميز عن غيرها من اللغات بإمكانية كتابة الحرف الواحد على أكثر من جزء، فبعض حروف اللغة العربية مثل (ك، ن، ت، ي) تكتب على مقطعين أحدهما يمثل الجزء الرئيس من الحرف الآخر يمثل الجزء الثانوي التابع للحرف مثل النقاط في حروف (ن، ت، ض)، وحرف الهمزة مع حرف الكاف، وبالاعتماد على الحسابات الرياضية والرسومية تستطيع تحديد

الاجزاء الثانوية التابعة لكل حرف وضمه أو إلـغائه عند تحديد الملامح الشكلية النهائية لكل حرف.^{١٨}

تستهدف عملية اشتقاء ملامح الحروف والكلمات انتاج مجموعة من المعلومات التي تصف شكل الحرف بشكل محدد يميزه النظام بها عن غيره من الحروف. وهذه المعلومات حول وصف الحروف تأتي اعتماداً على مدخلين أساسيي في وصف حروف الكتابات اليدوية ؛ هما أولاً الملامح البنوية Structural features وتمثلها طبيعة البنية الرقمية التي يوجد بها الحرف المتمثلة في شكل البداية والنهاية للحرف والزوايا والاتجاهات التي تمر بها كتابة الحرف. ثانياً الملامح الإحصائية Statistical features المتمثلة في نقاط كثافة الصورة التي يمر بها الحرف، وقياس المسافات الرقمية بين أجزاء الحرف. ومن خلال تدقيق المعلومات الإحصائية والبنوية لحروف الكتابات اليدوية يمكن لنظام الإدراك التمييز والفصل بين حروف اللغة العربية التي تتشابه في الجزء الرئيس لها وتختلف في اتجاهات الأجزاء التابعة لها مثل ما هو كائن في حRF (ن، ب) أيضاً امكانية التمييز بين الحروف ذات الرسم الواحد مع اختلاف عدد النقاط التابعة لها مثل حروف (ب، ت، ث) وحروف (س، ش). وبالتالي إلى هذه الملامح يبدأ نظام الإدراك في الانتقال إلى مرحلة المعالجة لاستخراج الحروف النصية والكلمات من المعجم اللغوي والتعامل مع النصوص.^{١٩}

٢ / ٢ مرحلة المعالجة (الإدراك) Processing (Recognition)


تستهدف مرحلة المعالجة والإدراك استخدام مجموعة الملامح الشكلية للحروف في عملية المضاهاة مع المعاجم الآلية داخل النظام للتعرف النهائي على نص الكلمة والحرف، ومن ثم استخدام الحروف والكلمات لبناء النص النهائي المقابل لصور الكتابات اليدوية واحتزارها في قواعد البيانات النهائية لإجراء عمليات البحث والاسترجاع من قبل مستخدمي النظام. وتنتمي عملية المعالجة وإدراك الكتابات اليدوية وفقاً لخطوات منهجية تعتمد في أدائها على أدوات عمل كنموذج الأشكال والمعاجم الآلية.

٢ / ٢ / ١ الإدراك Recognition

تمثل خطوة الإدراك واسطة العقد لكل مراحل وخطوات المعالجة لمواد الكتابات اليدوية الرقمية ؛ ففي هذه العملية يبزغ النص النهائي المتولد عن مضاهاة أشكال الحروف المصورة مع المعاجم الآلية. وسيحل النص المتولد عن هذه العملية محل الكتابات اليدوية الأصلية في باقي عمليات البحث والاسترجاع داخل نظام استرجاع الكتابات اليدوية على

الويب، ومن خلال النص المنتج يمكن إجراء المعالجات اللغوية والصرفية على مجموعات المخطوطات والوثائق التراثية التي لم يكن لأحد أن يفكر في تطويقها بحثا واسترجاعا في بيئه الويب. حيث سيتمثل النص المتولد عن إدراك الكتابات اليدوية الوجه المطابق لمادة المخطوط أو الوثيقة الذي يمكن أدوات بحث الويب من سهولة التعامل مع توفير النموذج المصور النهائي للمخطوطات والوثائق للعرض النهائي.

تبنت العديد من الدراسات آلية محددة لإجراء عمليات المعالجة والإدراك للكتابات اليدوية، يطلق على هذه الآلية نماذج ماركوف غير المرئية **Hidden Markov Models** (HMM). وترت肯 هذه الآلية إلى استخدام التحليل الشكلي لحرروف الكتابات اليدوية واستخدام الملامح الشكلية الناتجة في الخطوات السابقة في المضاهاة المقنة بين صور الحروف ونظائرها الأكثر تشابها في المعاجم اللغوية. وقد وصفت هذه الآلية بغير المرئية نظرا لأن الصور الرقمية للحروف موضع القياس تكون عبارة عن نقاط توزيع لبنية الحرف، دون ظهور الحرف ذاته. وتتبع آلية HMM أسلوبا منظما يقضي بمقاربة حروف الكلمة الواحدة الناتجة من التحليل الشكلي وفقا للترتيب والتتابع الذي جاءت به في الكتابات اليدوية مع قواعد بيانات المعاجم الآلية، وهي بذلك تحافظ على ترتيب الحروف الكلمة وترتيب مقاطع الكلمة الواحدة، بحيث ينتج الشكل النهائي للكلمات والعبارات الواردة في الكتابات اليدوية، كما في شكل رقم (٦). ويأتي الاصرار من جانب الباحثين على استخدام هذه الآلية لما اثنته من نجاح في التعامل مع إدراك الكلمات الشفوية على مواد المعلومات الصوتية.^{٢٠}



شكل رقم (٦) طبيعة المعالجة والإدراك لإحدى عبارات الكتابات اليدوية باستخدام آلية HMM

٢١

٢ / ٢ / ٢ / ٢ التصنيف والتوزيع classification

تفاعل الملامح الشكلية لحروف الكتابات الرقمية مع وحدات التحليل اللغوي في قاعدة البيانات للوقوف على النصوص النهائية للكتابات اليدوية، ويتم ذلك في ظل ما تزخر به اللغة العربية من أشكال متعددة لحراف و الكلمات المكونة للنصوص العربية، وخاصة الكتابات اليدوية. وعلى أساس التجانس بين الكلمات أو الحروف المحددة والعديد من الكلمات والحراف داخل المعاجم اللغوية، فإن آلية الإدراك في نظام بحث الكتابات اليدوية تبدأ بعمل توزيع وتصنيف لكل ما خرج من ملامح شكلية لحراف والمقطوع وكل ما يقابلها من كلمات وردت متشابهة في عملية المضاهاة. إن كلمة واحدة في اللغة العربية يقابلها العديد من الأشكال والصور التي قد تأتي بها في مواد المخطوطات والوثائق، وعلى الجانب الآخر فإن صورة كلمة ما ودت في إحدى مواد الكتابات اليدوية يقابلها

العديد من الكلمات الفرضية التي قد تكون دالة على الملامح الشكلية للكلمة موضع التحليل.

٢ / ٢ / ٣ فك الترميز decoding

ت تكون قاعدة بيانات نظام إدراك الكتابات اليدوية من قواعد بيانات فرعية تختص كل منها بمهام محددة وتسجيل مجموعة متكاملة مع غيرها من بيانات النظام الأخرى. ويختزن النظام مجموعات الملامح الشكلية والصور الرقمية لكلمات وحروف الكتابات اليدوية، بجانب مجموعات الكلمات المسجلة في قاعدة بيانات المعجم اللغوي، وإن ثمة ربط تقني وأرقام تحديد IDs تستخدم لإكمال عمليات البحث والاسترجاع لا بد من تكوينها داخل النظام ككل. إن عملية التجزئة والتقطيع segmentation الواردة في مرحلة ما قبل المعالجة والإدراك قد شملت أسطر وكلمات الكتابات اليدوية الواردة في صفحات متعددة للمخطوطات والوثائق، وقد نتج عنها سلسلة متتابعة من الحروف والمقاطع المتتالية غير محددة ببداية أو نهاية لكلمات معرفة. مثلت هذه السلسلة المتتابعة من صور الحروف الرقمية ترميزاً وشفرة معقدة تحتاج إلى تدقيق متعمق في قاعدة بيانات المعاجم الآلية التي تستطيع وحدتها فك رموز سلسلة الحروف المتتابعة، من خلال تكوين كلمات لها دالة لغوية وشكل كتابي محدد، تبدأ بحرف محدد وتنتهي عند حرف ذاته. ومن ثم تتحول سلسلة الحروف المشفرة إلى مجموعات من الكلمات المعرفة ذات دالة محددة بما يعكس فك تشفير ورموز حروف الكتابات اليدوية الرقمية داخل النظام. وهو ما توضحه الخطوتان الأخيرتين وما قبلهما في شكل رقم (). وينتهي النظام في مرحلة المعالجة بتكوين قاعدة بيانات فرعية للكلمات النصية المؤكدة ورودها في متن الكتابات اليدوية، مع الكلمات الفرضية التي تتوافق بنسبة كبيرة صور الكلمات والحوروف.

٢ / ٢ / ٤ أدوات نظام إدراك الكتابات اليدوية

تنتهي مرحلة الإدراك للكتابات اليدوية بانتهاء عملية فك الترميز وتكوين الكلمات النصية النهائية المعبرة عن صور الحروف والكلمات، غير أن الباحث لا يمكنه إغفال الحديث عن أداتين أساسيتين لا تعتمد عليهما عملية الإدراك وحسب، وإنما تعتمد عليهما نظام البحث والاسترجاع للكتابات اليدوية ككل. وهاتان الأداتان هما قاعدة نماذج الأشكال shape model والمعاجم اللغوية lexicon، وعلى الرغم من اختلاف ما تحمله كل منهما من معلومات، غير أن نجاح نظام إدراك الكتابات اليدوية يعتمد على درجة التوافق في التفاعل بينهما. فقاعدة نماذج الأشكال تحوي مجموعات الصور الرقمية لحروف وكلمات

الكتابات اليدوية، وتحوي المعاجم الآلية مجموعات الكلمات النصية التي تفاصس على أساسها الملامح المقتبسة وتحديد الكلمات الدالة عليها تلك الملامح. ونظراً لما تفعله هذه الأدوات من تأثير على عملية إدراك الكتابات اليدوية، فإن الاهتمام بمعاجم آلية وفيرة الكلمات يساعد على تحقيق الدقة والكفاءة المأمولةين في بحث واسترجاع المستفيدين لمواد الكتابات اليدوية.^{٢٢}

٢ / ٣ مرحلة ما بعد المعالجة Post Processing

لا تنتهي مراحل وخطوات المعالجة والإدراك للكتابات اليدوية العربية عند خطوة الإدراك والتعرف على الكلمات المضورة وتحويلها إلى كلمات نصية مستخرجة من المعاجم الآلية، إنما تتم المراحل بمرحلة ما بعد المعالجة والإدراك. ويتم في هذه المرحلة عمل مختلف الإجراءات التنظيمية والتقيحية للنصوص المستخرجة من عملية الإدراك؛ فمواد المعلومات العربية التراثية من مخطوطات ووثائق وغيرها تتلاءم واستخدام اللغة الطبيعية في الكتابة أكثر من اللغة الفصحى المقيدة المحددة بقواعد التراكيب والصرف في اللغة العربية. وفي مجال نظم استرجاع المعلومات الرقمية، فإن معالجة نص على طبيعته وعلى الشكل المكتوب به دون تغيير أو تعديل، يستلزم ذلك استخدام آليات وأساليب معالجة اللغة الطبيعية (Natural Language Processing (NLP) في التنظيم والاسترجاع. فضلاً عن أمر مهم يتطلب معه استخدام اللغة الطبيعية، ألا وهو القيمة التراثية التاريخية التي تتميز بها هذه النصوص والدراسات التاريخية الاجتماعية التي تستدعي دراسة متون ونصوص المواد التراثية الوثائقية كما كانت عليه من كتابة وصياغة وأسلوب ومفردات مستخدمة تحاكي الوقت والعصر الذي كتبت فيه. وتقوم المعاجم الآلية في هذه المرحلة على ضبط جودة وسلامة النصوص المستخرجة من حيث الشكل الاملائي والصرف في النص النهائي، ويتأتي ذلك من تزويد قواعد المعاجم الآلية داخل النظام بمجموعات الأشكال الشائعة من الأخطاء اللغوية والكتابية المرتبطة باستخدام تقنية OCR في رقمنة الكتابات اليدوية، ومن ثم يجري المعجم مسحًا شاملًا للنص لاستخراج الأخطاء ومعالجة الكلمات الواردة بها.

إن عمليات التقسيم والتجزئة التي تمر بها الكتابات اليدوية أثناء المعالجة من الصفحات إلى الأسطر إلى الكلمات ثم الحروف المكونة لكل الكلمة، يجعل من السهل جداً حدوث أخطاء متعددة أثناء عمليات التقسيم وتفكيك الكلمات ثم ما يتلوها من عمليات إدراك وتجميع بواسطة المعاجم الآلية، وكل ذلك من شأنه إحداث أخطاء لغوية وتركيبية بين

مقاطع الكلمات وحروفها. وتقوم المعاجم الآلية بتبيان وتوضيح طبيعة الحروف المفقودة أو التي وضعت في أماكن خاطئة أو علامات الترقيم وضبط النص ”؟“ و ”!“ التي تصاحب الحروف في متن الكتابات اليدوية، بما يساعد على إعادة استقامة النص مرة أخرى.^{٢٣}

٤ / ٢ تكشف الكتابات العربية اليدوية

تتجه الدراسة بالحديث عن تكشف الكتابات اليدوية من الوجهة التقنية المعلومانية إلى الوجهة المعلومانية الخالصة، فعملية التكشف إحدى عمليات التنظيم والتحليل الموضوعي التي تقوم عليها عمليات البحث والاسترجاع لمختلف مواد المعلومات على الويب. بل ويمكن القول أن مختلف أدوات بحث الويب تطلق مصطلح التكشف تحديداً على عمليات التحليل الموضوعي المستخدمة مع مجموعاتها الرقمية، فالغاية المنشودة لدى أدوات البحث هي توفير مجموعات من الكلمات الكشفية الدالة على المحتوى تنظيماً، واستخدام تلك المجموعات بحثاً واسترجاعاً من جانب مستخدمي الويب. ومن ثم اختار الباحث عملية التكشف خاصة دون سواها من عمليات التحليل الموضوعي كالتصنيف والاستخلاص لأنها الأكثر ملاءمة في التعامل مع مواد الكتابات اليدوية العربية الرقمية، فالكلمة الدالة هنا والمصطلح الكافي سيكون كل كلمة وردت في متن المخطوط أو الوثيقة، أيضاً الكلمة المفتاحية المتوقع طرحها من جانب المستفيد هي كل كلمة قد وردت في نفس المخطوط أو الوثيقة. وذلك انطلاقاً من مبدأ أن الأهمية المعلومانية والتاريخية التراثية للكتابات العربية المتضمنة في النص تستوجب إجراء التكشف على مستوى الكلمات والنص ككل، كما هو متبع في حال تكشف النصوص القانونية أو المقدسة.

تحدد نوعية التكشف المتبعة في تحليل محتوى مواد المعلومات الرقمية وفقاً لمجموعة من المحددات المستمدّة من نوعية مادة المعلومات ذاتها؛ فمواد المعلومات النصية تستخدم معها نوعية التكشف الاشتراقي Extracted Indexing أما باقي وسائل حمل المعلومات فتستخدم التكشف بالتعيين Assigned Indexing والفارق بينهما يأت وفقاً للمصدر المأخوذة عنه المداخل الكشفية، فإذا ما كانت الكلمات الدالة من بين كلمات النص المكافف كان التكشف اشتراكياً كما في حالة الكتابات اليدوية العربية، أما باقي المواد فتكون المداخل مختارة من المكانز وعليه فيكون التكشف بالتعيين، كما سيلي ذكره. ويتحدد نوعية التكشف المبني على الاشتراك، فإنه يمكن القول أننا حددنا اللغة الطبيعية في التكشف Natural Language Processing (NLP) دون اللغة المقيدة، وذلك لأن

الكتابات اليدوية سيتم تكشف النص الكامل لها وفقاً لما وردت عليه من مؤلفيها. كما تتحكم مواد الكتابات اليدوية اختيار أسلوب محدد من أسلوب تكشف المواد الرقمية، فأولهما التكيف المبني على المحتوى والمتافق وممواد المعلومات المصورة والمسموعة، وثانيهما أسلوب التكيف المبني على النص للمواد النصية، لأن مواد الكتابات اليدوية هي نصية مصورة، فإن كلاً الأسلوبين يتم استخدامهما مع تكشف الكتابات اليدوية العربية.^{٢٤} إن ثمة اعتبارين يجب توصيفهما واعتبارهما أساسين لانطلاق عملية التكشف للكتابات اليدوية العربية؛ أولهما : أن الكتابات اليدوية العربية على الويب توجد على حالتين ؛ مخترنلة في قواعد بيانات ذات بنية نظم إدارة قواعد البيانات DBMS، وتوجد في صفحات ومواقع الويب كصور مضافة لصفحات ذات بنية HTML. وهذا الاعتبار من شأنه التأثير على آليات التكشف وأدوات التكيف المتباينة في الحالتين، بل وقدرة أدوات بحث الويب على القيام بعملية التكشف كما يجب. ثانيهما : أن الكتابات اليدوية العربية عبارة عن كلمات ونصوص تتوارد في شكل صور رقمية، فالملف المستخدم لتداولها على الويب هو ملف الصور الرقمية، أما المطلوب منها في التداول فهو النص المتضمن في الصورة الرقمية المنتجة بواسطة OCR. وهذا الاعتبار من شأنه التأثير على عمليات آليات وأدوات التكيف المتباينة ؛ حيث يختلف تكشف التنصيبي والكلمات عن تكشف الصور. وانطلاقاً من الحقيقة المذكورة سلفاً بأن الكتابات اليدوية الرقمية هي نصوص في وسيط مصور، فإن خصائص وأساليب التكيف المذكورة لاحقاً سوف تصبح عملية تكشف متكاملة تتوافق وطبيعة مواد الكتابات اليدوية الرقمية.

يبقى في التمهيد لت Kushnering الكتابات اليدوية العربية الحديث عن المستهدف من ت Kushnering هذه المواد، فالغاية المراد الوصول إليها ستحدد أساليب وأدوات العمل الواجب اتباعها، بل وستحدد طبيعة التكيف وركائزه المتباينة. ويرى الباحث أن غاية ت Kushnering الكتابات اليدوية على الويب هي توفير قدرات البحث والاسترجاع لنصوص الكتابات اليدوية العربية وفقاً للشكل الذي كتبته به وخرجت عليه، دون المساس بصيغة وبنية النص المكتوب، مع عرض صور رقمية مطابقة لأصل المخطوط أو الوثيقة موضع الت Kushnering. وعلى ذلك فإن المراد استرجاعه ملف قاعدة بيانات أو صفحة HTML تحتوي على صورة رقمية للوثيقة أو صفحة المخطوط مع ميتاداتا كشفية للنص الكامل والبيانات البليوجرافية عن المادة المسترجعة. ووفقاً لهذه الغاية وهذا المراد تستكمل الدراسة باقي عناصرها.

٤ / ١ خصائص ت Kushnering الكتابات اليدوية

تتسم عملية تكشيف الكتابات اليدوية بالعديد من الخصائص التي تتحكم في الشكل والمنتج النهائي لعملية البحث والاسترجاع على قواعد بيانات ومحركات بحث الويب. وتمثل هذه الخصائص أساس التشغيل والمعالجة والبحث، فضلاً عن سياسات وبنية أدوات بحث الويب. وأهم هذه الخصائص :-

أولاً : تتوقف عملية التكشيف بالأساس على مكان إجراء تلك العملية في دورة تداول الكتابات اليدوية على الويب، فقد تضطلع قواعد بيانات الكتابات اليدوية بإجراء التكشيف وأضافة حقل **content** إلى عناصر الوصف الفني (الميتاداتا) تحمل النص الكامل الوارد في متن الكتابات اليدوية. ومن ثم لا تحتاج محركات البحث إلى إجراء عملية التكشيف واستخدام هذا العنصر في البحث والاسترجاع. أما في حالة تزويد محركات البحث وأضافة ملفات نصوص الكتابات اليدوية مباشرة من الويب، فإن ذلك يستلزم تزويدها بآليات تحليل الصور المبني على المحتوى **.content based image retrieval**.

ثانياً : ستعتمد عملية تكشيف الكتابات اليدوية الرقمية على تحليل صور المسح الضوئي لنصوص الكتابات اليدوية، مما يعني إدخال متطلبات آلية لمحركات بحث الويب تختص بتحليل بنية الكلمات المضورة، مثل نموذج ماركوف غير المرئي **HMM** المخصص لإدراك صور الحروف والكلمات، واستخدام المعاجم الآلية لتحديد هوية الكلمات والعبارات مع التدقير التركيبي والصرافي لكلمات اللغة العربية.

ثالثاً : تتجاوز عملية تكشيف الكتابات اليدوية المفاهيم المعروفة عن تكشيف النصوص الرقمية؛ حيث تتطوّي مفاهيم تكشيف النصوص على استخراج الكلمات الدالة والمعبرة عن موضوعات وأفكار النص المكشف، ويتم ذلك بواسطة محركات بحث الويب أثناء التحليل وقبل عملية البحث، أما تكشيف نصوص الكتابات اليدوية داخل صور المسح الضوئي فإنها تتمثل في اقتباس كل الكلمات ومقاطع الكلمات الواردة في صورة النص وإدراكها واستخراجها في نص منفصل، واستخدام كل الكلمات الناتجة عن ذلك ككلمات كشفية تستخدم للبحث والاسترجاع. بما يعني اجمالاً أن تكشيف الكتابات اليدوية إنما هو اشتراق كل كلمات النص وتعيينها ككلمات كشفية.

رابعاً : تعد عملية التكشيف المحدد الرئيس لطبيعة البنية التي ستكون عليها أدوات بحث الكتابات اليدوية، ذلك لأن محركات البحث في بنيتها الطبيعية تشمل عملية التكشيف مع عمليتي الإضافة والبحث، فإذا ما تركت عملية تكشيف الكتابات اليدوية لمحركات البحث، فسوف تكون وفقاً لبنيتها المطابقة لمفهوم عمل محركات البحث. وأما إذا كانت

عملية التكشيف تتم داخل قواعد بيانات مخصصة للكتابات اليدوية وتتاح هذه القواعد في بيئة الويب، فإن دور محرك البحث ثو يقف عند كونه واجهة لبحث الكتابات اليدوية دون التدخل في عمليات التكشيف والمعالجة والإدراك للكتابات اليدوية الرقمية على الويب. وستكون بنية عمل محركات البحث هنا مطابقة مع مفاهيم محركات بحث قواعد بيانات الويب غير المرئية Deep web search engines التي تناولها الباحث في أطروحته للدكتوراه، حيث تبني محركات البحث أحد خيارات في التعامل مع مجموعات الكتابات اليدوية في قواعد البيانات ؛ فإذاً أن يكون محرك البحث أداة لإرسال كلمات البحث واستقبال النتائج المستدعاة، أو أن يبني نموذج بحث عام يمكنه إجراء البحث مباشرة في مجموعات قواعد بيانات الكتابات اليدوية واسترجاع صورها ونصوصها.^{٢٥}

٤ / ٢ / أسلوب تكشيف الكتابات اليدوية

لقد استخدمت أدبيات الانتاج الفكري حول الكتابات اليدوية على الويب مصطلح التكشيف indexing كمفهوم مرادف لمصطلح الإدراك recognition، ويأتي ذلك من تبني وجهة نظر واحدة في التعامل مع الكتابات اليدوية كونها صور رقمية يتمثل تكشيفها في تحليل محتواها سواء أكان عناصر رسومية أم كلمات مصورة. ومن ثم فإن إدراك الكلمات المصور في داخل صور الكتابات اليدوية يمثل تكشيفا تقنياً أو برمجياً لدى باحثي علوم الحاسب، أما وجهة النظر المعلوماتية فتتمثل إلى تحليل محتوى الكلمات النصية المشتقة من صور الكتابات اليدوية والخروج بالمصطلحات الأكثر دلالة لاستخدامها كمدخل كشفية في عملية التنظيم والاسترجاع. لذا ومن المنطقي هنا عند التعرض لأساليب التكشيف المستخدمة مع الكتابات اليدوية، فإن الأقرب إلى التناول والاستخدام هو التكشيف المبني على المحتوى content based retrieval، ذلك لأن مادة الكتابات اليدوية ستكون في شكل صورة رقمية، إلى جانب أن المراد من التكشيف هو اشتقاء النص الكامل، وليس فقط الخروج بالمداخل والمصطلحات الكشفية. وقد ساعد على أن يكون التكشيف على مستوى النص الكامل، ما وصلت إليه أدوات بحث الويب من إمكانات تقنية يمكنها البحث على مستوى النصوص الكاملة، واستخدام كافة ما ورد في البحث من كلمات ومقاطع كمداخل كشفية، وهو ما يشير إليه ظهور آليات البحث باللغة الطبيعية.

٤ / ٢ / ١ التكشيف المبني على المحتوى

ينطوي التكشيف المبني على المحتوى على استخراج مجموعات الرسوم المضمنة في الصورة سواء أكانت أشكال أم كلمات، واستخدامها في عمليات تنظيم واسترجاع محتوى

الصور الرقمية وفقاً لأساليب تنظيم وبحث تقنية تقوم على برمجيات تحليل اللون والبنية والشكل للصور الرقمية. وتقف صور الكتابات اليدوية في مكانة وسطى بين الصور الرقمية التي تحوي أشكال مصورة، وبين النصوص الرقمية على الويب، ولذلك تبدأ عملية تكشيف صور الكتابات اليدوية العربية وتنتهي مع عملية إدراك وانشقاق الكلمات المصورة الواردة في صور الكتابات اليدوية. ويعتمد تكشيف الصور المبني على المحتوى على ثابت مهم هو انشقاق العناصر المصورة وإدراكتها ثم استخدامها بنفس بنيتها الرفقة في إجراء عمليات البحث والاسترجاع، مما يعني بدوره أن استخدام تكشيف الكتابات اليدوية المبني على المحتوى سوف ينتج عنه صور لكلمات نصية تستخدم كأشكال مصورة أثناء عمليات البحث. ولكن ما تسعى إليه هذه الدراسة هو استخدام معاملات إدراك الكتابات اليدوية ومقومات المعاجم الآلية في تحويل الكلمات المصورة المشتقة من صور الوثائق والمخطوطات وتحويلها إلى نصوص من كلمات وحروف يمكن للمستفيد البحث داخلها بكلمات مفتاحية وليس بصور أو أشكال مصورة. وقد ظهر مفهوم Content على يد Kato عام ١٩٩٢ عندما بدأ العمل في اتجاه استرجاع الصور للصورة ويكون برنامج نظام الاسترجاع ذا خصائص تمنحه القدرة على تحليل مكونات الصورة الأساسية وهي اللون والشكل shape والبنية texture.^{٢٦}

٢ / ٤ / ٢ التكشيف المبني على النص

يهدف التكشيف المبني على النص إلى استخدام النص الكامل لمادة المعلومات في استخراج المصطلح أو المصطلحات الدالة على فكرة وموضوعات محتوى مادة المعلومات النصية. وقد عكست عملية معالجة وإدراك نصوص الكتابات اليدوية أنه لا مكان لمفهوم التكشيف المبني على النص في هذه العملية، وذلك لأن صور الكتابات اليدوية بتقنية OCR تستخدم برمجيات وأليات حاسوبية تعمل على إدراك مختلف الأسطر والكلمات والحراف المكونة لهذه الأسطر، وتحويلها إلى نصوص معرفة لدى أدوات بحث الويب تستخدم في البحث والاسترجاع. بما يعني أن النص الكامل للكتابات اليدوية الرقمية هو بالأصل نص مصور لا يمكن معه استخدام آليات التكشيف المتتبعة لدى أدوات البحث، فضلاً عن ذلك فإن أدوات بحث الويب تستخدم كل كلمات النصوص الكاملة كمصطلحات كشفية ومدخل بحث لاسترجاع مواد المعلومات النصية، وذلك لتحقيق ميزة تنافسية مع باقي أدوات البحث التي تمتلك قدرات متكاملة في اختزان وبحث واسترجاع مواد المعلومات. ومن ثم لا تتمكن أدوات بحث الويب بالأساس من استعراض نصوص

الكتابات اليدوية، ما لم تكن تملك أدوات الإدراك والتحليل **Recognition** لصور الكتابات اليدوية بتقنية **OCR**، وستقتصر عملية التكشيف المبنية على النص على تحليل عناصر الوصف الفني (الميتادات) المصاحبة لملف صور الكتابات اليدوية. وعند استخدام تحليل النصوص المصاحبة لصور الكتابات اليدوية في قواعد البيانات أو ضمن نصوص صفحات الويب، فإن ثمة إجراءات محددة تمر بها عملية التكشيف المبني على النص، وهي :

(١) إعداد قائمة الاستبعاد للكلمات كثيرة التواجد غير الدالة كحروف العطف وظرف الزمن والمكان.

(٢) يتم تجريد الكلمات من السوابق والواحدة الواردة معها.

(٣) حساب عدد مرات التكرار لكل الكلمات وترتيبها ترتيباً تنازلياً بحسب عدد مرات التكرار، ثم اختيار الكلمات التي تتصدر الترتيب.

(٤) يتم اعتبار الكلمات التي تجاوزت عدد مرات تكرارها عدد محدد من المرات، هي أكثر كلمات دلالة لمحتوى الوثيقة داخل نظام الاسترجاع، وإعطائها وزناً نسبياً أكبر أثناء بحث واسترجاع النصوص.

٤ / ٣ مقومات تكشيف الكتابات العربية

تبني عملية تكشيف الكتابات اليدوية على عناصر عمل متكاملة تمثل مقومات التكشيف التي لا يمكن لنظام بحث واسترجاع الكتابات اليدوية العمل دونها، وتختلف هذه المقومات بين التقنية والبرمجية واللغوية، ذلك لأن الكتابات اليدوية تجمع بين البيئة الرقمية واللغة العربية. كما أن عملية التكشيف ذاتها لهذه المواد تتم بأسلوبين أحدهما آلي تقني العمل، والآخر نصي لغوي البنية. وتمثل مقومات عملية تكشيف الكتابات اليدوية في التالي :-

أولاً : تقنيات إدراك النصوص **text recognition** : وأهم أشكالها نموذج ماركوف غير المرئي **HMM** ؛ حيث تعمل هذه التقنيات بمساعدة تقنية **OCR** لرقمنة الكتابات اليدوية وتحليل محتوى صفحات موادها وتقسيم الأسطر إلى كلمات ومنها إلى حروف، بما ينتج عنه اشتراق النص الكامل في شكل نصي بعد الشكل المصور، وهو ما يمثل تكشيفاً على مستوى النص الكامل للمخطوط أو الوثيقة.

ثانياً : **المعاجم اللغوية الآلية Lexicon** : فاستخدام هذه الأدوات يأتي في مرحلتين ؛ أولاًهما عند تحليل وإدراك النصوص المصورة واحتراق الكلمات، وثانيهما عند إجراء عمليات البحث بمشتقات أو معاني أو تصريفات الكلمة الواحدة. ويتركز الحديث هنا حول

الاعتماد المقترن لاستخدام المعاجم الآلية في مرحلة التنظيم (التكشيف) التي تتصل باشتغال الواصلات الموضوعية الكتابات اليدوية . و تعد المعاجم الآلية العمود الفقري لتنظيم واسترجاع الكتابات اليدوية العربية حيث يتتوفر بذلك إجراءات التنظيم في تحليل الأشكال المختلفة للكلمة الواحدة ، ومن ثم يمكن التدقير في حساب تكرار الكلمة إذا ما اعتمد محرك البحث على اشتغال الكلمات المفتاحية بحسب تكرارها في النص . أما إجراءات الاستدعاء فهي تتمثل في تحليل كلمات البحث المستخدمة من جانب المستفيد لاستدعاء صفحات الويب ، مما يساعد على أداء خدمات الاسترجاع في اللغة العربية مثل استدعاء المقابلات أو استدعاء الوحدات التي تحتوي على معنى كلمة البحث أو جذر كلمة البحث بمختلف السوابق واللوائح ، وهو ما يتراوله الحديث في التعرف على التحليل الصافي للغة العربية .
٢٨

ثالثا استخدام اللغة الطبيعية : تمثل اللغة الطبيعية Natural Language Processing : تمثل اللغة الطبيعية العمود الفقري لإدارة معالجة وبحث مواد الكتابات اليدوية ، فاللغة الطبيعية هي لغة المؤلف حين يكتب المادة المعلوماتية ، وهي لغة التكشيف عندما تعتمد نظم الاسترجاع على النص في اشتغال كلماته الدالة ومداخله الكشفية ، وهي أيضا لغة المستفيد حينما يستخدم كلمات مفاتيحية غير مأخوذة عن مكنز أو قائمة رؤوس موضوعات مقتنة . وعلى ذلك فإن آليات اللغة الطبيعية تمثل جناح التكشيف والبحث لمواد الكتابات اليدوية على الويب ، فضلا عن كونها الأنسب لتجهيز أدوات البحث في التكشيف على مستوى النص الكامل ، وتحليل وإدراك نصوص الكتابات اليدوية كما وجدت عليه بصياغتها ومفرداتها . ولم تقصر دراسات التطوير للغة داخل نظم استرجاع المعلومات على النقدم في معالجة اللغة الطبيعية ، وإنما امتد الأمر إلى تطوير قدرات نظم استرجاع المعلومات على معالجة اللغات الحية المستخدمة في كتابة الوثائق والإنتاج الفكري على مستوى العالم . ومن هذه الدراسات ما تم عن طريق naserdine semmar وزملائه في تطوير قدرات نظم استرجاع المعلومات للعمل على تنظيم واسترجاع المعلومات المسجلة بلغات مختلفة . من خلال توفير برامج للتحليل اللغوي والإحصائي داخل نظام الاسترجاع يأتي دورها في العمل عند إضافة الوثائق ومعالجتها . ويعمل هذا النظام اعتمادا على مجموعة من برامج تحليل اللغة سواء المستخدمة في استفسار البحث أم تلك المستخدمة في كتابة الوثائق . وعلى ذلك فإن ثمة ترابط قد أحدهته هذه الدراسة بالجمع بين آليات المعالجة والبحث وبرامج تحليل اللغة ، ومن البرامج المستخدمة في هذا النظام ما يلي :-
٢٩-

١. برامج التحليل اللغوي : **linguistic analyzer** وهي التي تقوم بالمعالجة اللغوية لكل من استفسار البحث والكتابات المكشفة.

٢. برامج التحليل الإحصائي : **statistic analyzer** وهي تقوم فقط بتكشيف مواد المعلومات.

٣. برامج تهذيب البحث : **reformulator** وتحتخص بتوسيع سؤال البحث وإجراء البحث داخل النتائج المسترجعة.

٤. برامج الربط أو المضاهاة : **comprator** وهي تقوم بتحديد التشابه الدلالي بين سؤال البحث والوثائق المكشفة.

المبحث الثالث : البحث والاسترجاع للكتابات اليدوية

تكمّل عملية إدارة مواد الكتابات اليدوية على الويب بالوصول إلى توفير آليات البحث والاسترجاع لنصوص هذه المواد، وتنتأتى آليات البحث والاسترجاع الموافقة لكل مادة معلومات على الويب من خلال طبيعة بنية ومعالجة هذه المادة، وحيث أن بنية الكتابات اليدوية الرقمية هي النصوص المصورة كما ذكر من قبل، فإن ثمة أساليب بحث تكمن في استرجاع الكتابات اليدوية باستخدام صور الكلمات **image-to-image matching** واسترجاعها من خلال الكلمات المفتاحية النصية **word matching**. وسيتناول هذا المبحث كل ما يتعلق بعملية البحث من أساليب وبنية وواجهة البحث.

٣ / ١ أساليب البحث والاسترجاع للكتابات العربية

تبينت الدراسات التي تحدثت عن استرجاع الكتابات اليدوية على الويب حول جدوى استخدام البحث النصي والبحث بالصورة في عمليات الاسترجاع، فمن الآراء ما أكد على فاعلية استخدام الكلمات المصورة نظراً لطبيعة وبنية الكتابات اليدوية الرقمية، وتأكيداً على توافر أجهزة الكتابة اليدوية الرقمية مثل الحاسوب اللوحي والهواتف النقالة. أما تبني استخدام البحث بالكلمات النصية فيرتكن إلى طبيعة وجود آليات الإدراك والمعالجة لنصوص الكتابات اليدوية وتحويلها إلى كلمات وحروف يمكن تطبيقها للبحث بالكلمات المفتاحية. وعلى ضوء تحديد أسلوب البحث المستخدم تتحدد آلية المضاهاة والمطابقة **matching** المستخدمة داخل النظام ؛ حيث ستتم عملية المضاهاة مباشرة مع مواد الكتابات اليدوية وصور الكلمات حال الاعتماد على البحث بصورة الكلمة، أما في حالة استخدام البحث بالكلمات المفتاحية فسيتم الاعتماد على مخرجات عملية الإدراك دون الرجوع إلى صورة المخطوط أو الوثيقة.^٣

٣ / ١ / ١ البحث المبني على الكلمة المصورة word image search

تتدخل تقنيات وبرمجيات استرجاع المعلومات لتحدد تطويراً مستمراً في آليات عمل نظم استرجاع المعلومات، فمواد الكتابات اليدوية التي يتم رقمتها بواسطة OCR ترجع إلى أزمنة قديمة لم تكن الكتابة اليدوية الرقمية على الحاسوب قد ظهرت. وقد أتى الوقت الحالي ليشهد أجهزة الكتابة الرقمية اليدوية بواسطة أقلام الكترونية يستطيع المستخدم إدخال نص يدوي الكتابة دون تدخل لوحة المفاتيح ويمكن لنظم الاسترجاع معالجة هذه النصوص وإدراكيها فور كتابتها يدوياً **Real Time Recognition**. وبهذه الأجهزة المستحدثة تستطيع نظم استرجاع الكتابات اليدوية من مخطوطات ووثائق استخدام نماذج كلمات البحث المكتوبة يدوياً لمضاهاتها مباشرةً مع نصوص الكتابات اليدوية في شكل صور واسترجاع ما ينطابق أو يقترب منها بدرجات محددة. ويطلق على هذا الأسلوب البحث المبني على الكلمات المصورة أو صورة الكلمة **Word Image**، وذلك كما يعبر عنه شكل رقم (٧). ولقد اعتمد هذا الأسلوب على الدور التقني لبرمجيات تحليل الصور الرقمية وآليات تحديد أوجه وقياسات أشكال الكلمات في نصوص الكتابات اليدوية، كتقنية **Hidden Markov Model HMM** التي تستطيع التعرف على كلمات اللغة العربية وتقسيمها إلى مقاطع وحروف كنماذج مصورة ثم استخدام المعاجم الآلية لتحويل صور الحروف والكلمات وفقاً للتتابع الحروف إلى كلمات نصية ومن ثم الوصول إلى النص الكامل لمعنى الوثيقة أو المخطوطة، وتسمى هذه الآلية باكتشاف الكلمة **word spotting**^{٣١}.



Figure 1.4. An illustration of document retrieval using word image as query.

شكل رقم (٧) أسلوب استرجاع الكتابات اليدوية المبني على صورة الكلمة والنتائج المسترجعة

٣٢

يوضح شكل رقم (٧) استرجاع كلمات الكتابات اليدوية من خلال صور الكلمات البحثية المدخلة يدوياً من جانب مستخدم النظام، ثم تطبيق المضاهاة وفقاً لأشكال ونمذاج الكلمات المتطابقة بنسب مختلفة مع كلمة صورة الكلمة المدخلة، كما يربط النظام في عملية الاسترجاع بين الصور المسترجعة والوثيقة أو المخطوطة المرتبطة المنتمية لها الكلمة المسترجعة، حتى يمكن الوصول إلى النص الكامل للمادة.

٣ / ١ / ٢ البحث المبني على الكلمات النصية key word searching

يتافق البحث بالكلمات النصية مع التوجه العام لمستخدمي الويب سواءً كان بحثهم عن مواد معلوماتية مصورة أم مسموعة أم نصية، فمستخدم الويب لا يحتاج سوى كتابة كلمات نصية مدخلة بلوحة المفاتيح في فراغ البحث search box حتى يعبر عن الحاجة الموضوعية لديه في صور كلمات مفتاحية أو استفسار بحثي. وقد أدرك نظم استرجاع المعلومات هذا السلوك فعملت على تحويل البحث عن الوسائل المختلفة من صوت وصورة بكلمات بحثية تتمثل في بحث مياداناً المكونة لملف مادة المعلومات أو النصوص المصاحبة الواردة في صفحات الويب، لأن يتم البحث عن الصور والصوت بكلمات نصية أو عبارات بحثية. وعند استخدام الكلمات المفتاحية للبحث عن نصوص الكتابات اليدوية من وثائق ومخوططات، فإن النظام لن يعود إلى مواد معلومات الكتابات اليدوية ذاتها، إنما سيتم إجراء عمليات المضاهاة والمطابقة مع النصوص المستخرجة بتنقنيات الإدراك من صور الكتابات اليدوية OCR. وإن كان ذلك سيحمل نقصاً في عدم البحث في الوثيقة أو المخطوطة ذاتها نظراً لوجودها في شكل صور رقمية، فإنه سيحمل امكانات التحليل الصرفي واللغوي من خلال المرور على المعاجم الآلية المستخدمة في تحليل نصوص الوثائق والمخوططات في نظم استرجاع الكتابات اليدوية العربية. وفي هذه الحالة فإنه من الضروري التأكيد على معيارية بناء ملفات الكتابات اليدوية وما تحمله من عناصر وصف مياداناً وقدرة ضمها لعنصر Content المقترن في هذه الدراسة الذي سيحمل النص الكامل المستخرج من آليات الإدراك لنصوص الكتابات اليدوية.

وعلى هذا فإن نظام استرجاع الصور الرقمية يعمل على مضاهاة كلمات البحث مع حقول ملف مادة المخطوط أو الوثيقة كاملة إضافة إلى النص الكامل لصفحة الويب المصدرية مع حقول اللغة المعيارية HTML، ليخرج نظام استرجاع الصور بملف أو ملفات

الكتابات اليدوية التي يتوافر في أي من حقولها كلمات البحث المدخلة إلى النظام. ولعله يمكن القول أن البحث بالكلمات المفتاحية قد يعطي في كثير من عمليات البحث نتائج غير دقيقة خلاف التصفح بالتقسيم الموضوعي؛ ذلك لاحتياج أسلوب الكلمات المفتاحية إلى آليات بحث دقيقة يستخدمها غير المترسّين من مستخدمي الويب. ويرز الدور المهم لأسلوب الكلمات المفتاحية في بحث المخطوطات والوثائق إذا ما تحلى نظام الاسترجاع بحلية اللغة الطبيعية (لغة النصوص العربية الكاملة) كلغة تنظيم لنصوص ووحدات الكتابات اليدوية. ويحتاج أسلوب الكلمات المفتاحية في بحث النصوص الكاملة بلغتها الطبيعية إلى مجموعة من آليات البحث القادرة على صياغة مختلف استراتيجيات البحث بما يحقق الدرجة المرجوة من التحقيق في استرجاع المخطوطات والوثائق. وتتكامل آليات بحث اللغة العربية مع آليات البحث العامة لإجراء عمليات البحث في النظام.^{٣٣}

٣ / ٢ آليات ومعايير البحث

إن المحتوى العربي من مواد الكتابات اليدوية العربية من مخطوطات ووثائق سوف ينعكس بطبيعة الأمر على شكل نظام الاسترجاع المستهدف بناؤه، فكما سبق وأن انعكست بنية الكتابات العربية على أدوات النظام في استخدام المعاجم الآلية، وانعكاس اللغة العربية على أساليب التكشيف والبحث، فإن طبيعة محتوى الكتابات ذات اللغة العربية وطبيعتها التراثية سوف تتعكس على طبيعة آليات ومعايير البحث المستخدمة لبحث واسترجاع نصوص هذه المواد، هذا فضلاً عن بنيتها التقنية كونها صور رقمية لنصوص OCR. ويضاف إلى هذا كله طبيعة المعالجة الزمنية التي كتب فيها هذه المخطوطات والوثائق بما ينعكس على المفردات اللغوية وأساليب الكتابة المستخدمة، مما يعني إجمالاً أن المعاجم الآلية ستكون لب عمل نظام استرجاع الكتابات اليدوية على الويب، واستخدامها لأداء العديد من الوظائف الرئيسية في معالجة نصوص المواد الوثائقية ليس فقط في البحث وإنما في التحليل والإدراك والتکشیف.

لقد عملت التقنية العربية على تذليل مشكلات المفردات العربية من اشتراك لفظي وترادف وغيرها واستخدام المحللات الصرفية وتقنيات التحليل اللغوي في توفير قدرات البحث بالمعنى والم مقابل والبحث بجذور الكلمات ومشتقاتها. وقد تميزت شركة صخر Sakhr في مجال المعالجة اللغوية لبحث واسترجاع المحتوى العربي على الويب. ومن خلال العديد من الدراسات استخلص الباحث مجموعة من آليات ومعايير البحث التي يمكن استخدامها مع بحث واسترجاع الكتابات اليدوية العربية على الويب على النحو التالي :-^{٣٤}

جدول رقم (٣) أساليب بحث الكتابات اليدوية العربية على الويب

نوعية معيار البحث	أسلوب واتجاهات البحث	آليات ومعاملات البحث	قدرات البحث
أولاً معيار البحث المصور	الصور المعدة مسبقاً	١) صورة الكلمة	نموذج مصور متطابق
أولاً معيار البحث المصور	التصفح بين الوحدات	٢) تصفح صور الكلمات	التصفح الإرشادي
أولاً معيار البحث المصور	أجهزة الكتابة اليدوية الرقمية	٣) الكتابة اليدوية الرقمية	أجهزة الإدخال الرقمي
<u>آليات البحث بالكلمة الواحدة</u>	▪ البحث بالتطابق		بنفس شكل الكلمة
	▪ البحث غير المطابق		(البحث باللواصق)
	▪ البحث بجزر الكلمة		(حل مشكلة الاشتغال)
	▪ البحث بالتشكيل للمشترك اللغوي		استخدام قدرات الاعجم
	▪ البحث الحر		الامتدادات المختلفة
	▪ البحث بحساسية الحالة		وفقا لرسم الكلمة
	▪ البحث بالترادف		لحل مشكلة الترادف
	▪ البحث بالمتضادات		باستخدام المعاجم الآلية
	▪ البحث بالمعاني		باستخدام المعاجم الآلية
	▪ إمكانية التعرف على الأخطاء العربية		باستخدام المعاجم الآلية
<u>آليات البحث بكلمات متعددة</u>	❖ البحث في الحقول		عنصر الميئادات
	❖ البحث بالتقارب		مسح النص الكامل
	❖ استخدام المنطق البوليني		
	❖ طرح سؤال باللغة الطبيعية		
	❖ استخدام علامات التطابق " "		
	❖ البحث في الحقول		
	❖ البحث بالتقارب		

٣ / بنية نظم استرجاع الكتابات اليدوية على الويب

تحتاج الكتابات اليدوية العربية على الويب تكامل مجموعة من البرامج أو النظم الفرعية حتى يصاغ النظام المتكامل لاسترجاع وبحث المخطوطات والوثائق، وقد مر البحث حتى الآن بعناصر شتى يختص كل منها بأداء مهام محددة في عملية معالجة واسترجاع الكتابات العربية على اختلاف أشكالها. ويركز الباحث هنا على محاولة توصيف نموذج مقترن لبنية نظم تنظيم وبحث الكتابات اليدوية يتالف من مجموعة من النظم الفرعية، مع توضيح اختصاصات كل نظام في البنية العامة ككل. وقد أورد الدراسات التي تناولت الكتابات اليدوية عامة والعربية خاصة على الويب مقترنات لنظم بحث الكتابات اليدوية على الويب، غير أنها قد اتسمت بمحدودية العمل، واختار الباحث منها أقربها في شكل رقم (٨) للبنية المقترنة في هذا البحث مع إضافة وتوسيع التوصيف العام لأدوات بحث الويب.




Figure 4.3. Flowchart of the search engine.

شكل رقم (٨) محرك بحث الكتابات اليدوية المبني على المحتوى^{٢٥}

يوضح شكل رقم (٨) شكل البنية العامة التي يكون عليها نظام بحث الكتابات اليدوية، مضاف إليها ما تقرره الدراسة، وتتحصر النظم الفرعية المقترنة فيما يلي :-

١ / ٣ / ٣ نظام الوصول والإضافة

تتناثر مواد الكتابات اليدوية في فضاء الويب غير محددة بحدود موقع أو قاعدة بيانات، وتتشابه مختلف الكتابات اليدوية على اختلاف لغاتها في بنيتها الرقمية التي تستمدتها إما من صفحة ويب HTML أو من معيارية قاعدة بيانات مختصة بهذه المواد. وتعد عملية الوصول والاضافة لمادة المعلومات هي المكون الأول والإجراء المبدئي داخل نظم استرجاع المعلومات؛ وهي تقابل عملية التزويد في المكتبات. ونظراً لاختلاف أنواع النظم العاملة مع الكتابات اليدوية الرقمية بين محركات البحث وقواعد البيانات، فإن الوصول إلى مواد الكتابات اليدوية الرقمية يختلف بين المحركات وقواعد البيانات؛ حيث تعتمد محركات البحث على برامج الزاحف والعنكبوت التي تختص بعمليات الاضافة والتزويد لملفات المعلومات، غير أنها تتواصل بشكل أساسي مع موقع وصفحات HTML دون قدرة الولوج إلى داخل قواعد بيانات الويب، ومن ثم فإن بنية ملفات الكتابات اليدوية التي تضيفها محركات البحث لا تخضع لمعايير واحد أو بنية رقمية ذات ضبط مقنن. وهو ما عالجة البحث في الحديث عن أهمية بنية رقمية معيارية موحدة لملفات الكتابات اليدوية. أما قواعد البيانات فإن بناء مجموعاتها وإضافة ملفات المخطوطات والوثائق بها يتم غالباً من خلال الضبط المقنن ومعايير بناء الملفات الرقمية بواسطة العامل البشري، بما يعطي تقنيات أكبر لشكل وعناصر البيانات المصاحبة لملف المخطوطة أو الوثيقة في قاعدة البيانات. وفي الحالتين يعمل نظام الوصول على تكوين مجموعات الكتابات اليدوية داخل نظام البحث وتحديد ملامح مقتنة لكل ملف يتم إضافته إلى نظام البحث وفقاً لاشتراطات وأسلوب معالجة وتنظيم محددين.

كَانَ ابْنُ جَامِعٍ مِّنْ أَنْقَطْ خَلْقَ اللَّهِ كُلَّ تَابِعِ اللَّهِ وَأَعْلَمُهُ بِمَا يَحْتَاجُ إِلَيْهِ، كَانَ يَرْجِعُ مِنْ مَنْزِلَهُ مَعَ الْغَرِبَوْمِ الْجَمِيعَ فَيَهْلِي الصَّبَعَ ثُمَّ يَهْفَّ قَدْمِيهِ هَنَى تَطْلُعَ الشَّمْسِ، وَلَدِيَهُ لِي النَّاسُ الْجَمِيعُ هَنَى يَكْتُمُ
الْقُرْآنَ ثُمَّ يَنْصُرُ إِلَى مَنْزِلَهِ.

Fig. 9. A sample of Arabic manuscript.

شكل رقم (٩) أحد ملفات الكتابات اليدوية على الويب في شكل مخطوطة ^{٣٦}
وبحسب نوعية نظام البحث بين محرك وقاعدة بيانات، يحتاج نظام الوصول والإضافة المتمثل في برنامج العنكبوت لتوصيف العديد من المحددات مثل كيفية التعرف على مواد

الكتابات اليدوية، وكيفية قراءة الملف، وكيفية نسخه وضمه إلى باقي المجموعات، فضلاً عن المعلومات التعريفية التي تسهل عمليات المعالجة والتنظيم فيما بعد.

٣ / ٣ / ٢ نظام المعالجة والإدراك

يختص نظام المعالجة والإدراك بعملية التنظيم القبلية لعملية التكشيف والمعالجة المعلوماتية الفعلية داخل نظام الاسترجاع المتكامل، وتتم عملية الإدراك بشكل تقني خالص ينطوي على استخراج وانتقاد نصوص الكتابات اليدوية من هيئتها المضورة. وعلى الرغم من أن نظام الإدراك هنا هو نظام فرعي لبحث الكتابات اليدوية، إلا أنه ينطوي بذاته على ثلاثة مراحل لعملية الإدراك هي ما قبل المعالجة ثم الإدراك ثم ما بعد الإدراك، وتمر كل مرحلة بعدة إجراءات تبدأ في أول مراحلها بتهيئة الكتابات اليدوية الرقمية للإدراك ثم تنتهي آخر إجراءاتها بالرجوع إلى المعاجم الآلية لتحديد المقاطع والحراف والكلمات غير المتعارف عليها التي يصنفها نظام الإدراك على أنها غير معالجة **unprocessed**. ويفرد شكل رقم () عدة خطوات واضحة تتعلق بتجزئة الصفحات إلى أسطر ثم إلى كلمات ومنها إلى مقاطع وحروف حتى يتم تحليلها والتعرف عليها باستخدام تقنيات وبرمجيات مثل نموذج ماروكوف غير المرئي **HMM** وتقنيات الخط البياني **Baseline** التي تستطيع إدراك وقراءة نصوص **OCR**. وفي هذه المعالجة يتم حساب **(TF)** term frequency وربطه بمجموعة الوثائق التي جاء بها ثم حساب توارده في مجموعات الكتابات الرقمية في كل قاعدة البيانات وفقاً لمعاملات تردد الوثائق **(IDF)** document frequency، وكما يتم استخدام هذه التقنية في إدراك النصوص، فإنه يتم استخدامها أيضاً أثناء تحليل صور الكلمات المفتاحية المدخلة إلى النظام أثناء عملية البحث، ومن ثم تحليلها ومضاهاتها مع ما يطابقها من كلمات ونصوص في مجموعات الكتابات اليدوية. وعلى الرغم من أن بعض دراسات علوم الحاسوب قد نعتت هذه المرحلة بمرحلة التكشيف، إلا أنها تختلف تماماً عن عملية التكشيف من وجهة النظر المعلوماتية تتطوّي على استخراج الكلمات الدالة المعبرة عن محتوى الكتابات اليدوية.^{٣٧}

٣ / ٣ / ٣ نظام التكشيف والتحليل

أفردت الدراسة العنصر الرابع في المبحث الثاني للحديث عن عمليات التكشيف التي تم داخل نظام بحث واسترجاع الكتابات اليدوية على الويب بشكل مفصل وبمختلف زواياه؛ حيث تناول الباحث أسلوب التكشيف المبني على صورة الكلمات والحراف، والتلخيص المبني على تحليل الكلمات النصية المستخرجة من عملية إدراك صور الكتابات اليدوية،

إضافة إلى مقومات عملية التكشيف وخصائص تكشف الكتابات اليدوية على الويب. وكل ما ورد في هذا العنصر يمثل توصيفاً للنظام الفرعي القائم على التكشيف والتحليل الموضوعي لكتابات اليدوية.

٣ / ٤ نظام الإدارة والتفعيل

يتخطى مفهوم نظام الإدارة هنا حدود العمل التقني في معالجة وبحث الكتابات اليدوية ليصل إلى حد إدارة مجموعات المعلومات من حيث أداء النظام وتفاعلاته مع البيئة الخارجية من قواعد بيانات ومستخدمي الويب. فتتماك الكتابات اليدوية من مخطوطات ووثائق قيمة تاريخية تراثية وقانونية تختلف في طبيعتها عن مواد المعلومات الرقمية الأخرى، ومن ثم فالوصول إليها ورقمتها وإتاحتها على الويب يحتاج بدوره إلى سياسات أداء مقننة، كذلك المستخدمة معها من الناحية المعلوماتية فيما يتعلق بتكشفها وبحثها. وسيكون هذا النظام عبارة عن سياسة عمل شاملة تضبط عمل النظام ككل مما يتربّط عليه المتابعة والتقييم التي تمثل أحد أسس بناء نظم استرجاع المعلومات، وستصبح جلياً استخدام هذه السياسة وأهميتها إذا ما وضع في الاعتبار الأشكال المختلفة التي ستكون عليها بنية النظام، فإذا ما كانت البنية متمثلة في محرك بحث يتصل بقواعد البيانات المتاحف والهيئات الوثائقية فثمة اعتبارات وتقانين لا بد من تحديدها، فضلاً عن التوافق التقني اللازم لتواءل محرك البحث مع نماذج بحث قواعد البيانات وتبادل ملفات المعلومات على اختلاف بنية النظمين.

٣ / ٥ نظام البحث والاسترجاع

تناولت الدراسة البحث والاسترجاع بشيء من التفصيل في المبحث الثالث كاملاً لتوضيح الأساليب والآليات وتقنيات البحث المستخدمة مع الكتابات اليدوية، بما يمثل تحليلاً كاملاً للنظام الفرعي المختص بالبحث والاسترجاع. أما الحديث هنا فسيكون مخصصاً عن جزء لا يتجزأ من عملية البحث وهو واجهة البحث *search interface*، التي تمثل انعكاساً لكل معايير وأدوات وأساليب البحث المستخدمة في نظام الكتابات اليدوية. فعلى واجهة النظام تتضح آليات البحث بصور ونماذج الكتابات اليدوية من خلال توفير مساحة لإدخال صورة الكلمة المطلوبة، أيضاً تتضح آليات البحث بخصائص اللغة العربية واستخدام المعاجم الآلية في تطوير الكلمات المسترجعة من خلال البحث بجذر الكلمة وتصريفاتها اللغوية. وإذا كانت واجهة البحث تختص بهذا المسمى الوارد فيه الكلمة البحث، فإن الشق الثاني من واجهة النظام هو قدرات عرض النتائج المستدعاة ومدى التوافق مع طبيعة

مواد المعلومات خاصة إذا ما كانت في الوسيط المصور، أو بتقنية الفلاش وغيرها من مستحدثات عرض الصور الثابتة والمتحركة.

المبحث الرابع : واقع وموقع الكتابات اليدوية العربية على الويب

ترصد الدراسة التطبيقية هنا واقع مواد الكتابات اليدوية في بيئة الويب، وتوضيح واقع المنظومة المتكاملة التي تعمل على تنظيم واسترجاع الكتابات اليدوية على الويب. وثمة ملاحظة أولية استقرأها الباحث في الإعداد للدراسة التطبيقية تتمثل في غياب أهم أشكال نظم استرجاع الويب من محركات وأدلة بحث ولم يوجد عند اختيار عينة الدراسة سوى قواعد بيانات تتبع مكتبات أو مؤسسات علمية وثقافية، بما يعكس واقع الويب في تأخرها عن مجازة هذا الشكل تنظيميا واسترجاعا. وستركز الدراسة التطبيقية هنا على مجموعة العناصر الفرعية المتكاملة المستخلصة من جملة ما سبق من تظير حول الكتابات اليدوية، وهي العناصر التي تمثل مختلف جوانب بنية وإدارة ومعالجة واسترجاع الكتابات اليدوية في بيئة الويب، بما سيعكس اخضاعها لقياس التجريبي قراءة لواقعها واستشرافا لما ينبغي أن يكون عليه مستقبل الكتابات اليدوية وأدوات بحثها على الويب. وستنقسم الدراسة التجريبية لمحاور رئيسة تضم منظومة العناصر الفرعية كما يلي :-

٤ / ١ محور البنية والشكل

يستهدف هذا المحور قياس وجود وطبيعة العناصر الأولية الأساسية لمنظومة استرجاع الكتابات اليدوية، فحتى تكتمل هذه المنظومة ويحكم على واقعها تحتاج إلى عناصر وجودية تتمثل في شكل محدد تتوارد عليه الكتابات اليدوية، التي تختلف طبيعتها وإدرتها وفقاً لطبيعة نظام الاسترجاع. فضلاً عن طبيعة أشكال الكتابات اليدوية التي اهتمت بها عينة الدراسة، ويمثل جدول رقم (٤) قياس محور البنية والشكل وفق للعناصر الفرعية المكون منها.

جدول رقم (٤) قياس عناصر محور البنية والشكل في معالجة واسترجاع الكتابات اليدوية

موقع قواعد بيانات المخطوطات						محور البنية والشكل عناصر المحور وتوصيفها	
الأجنبية			العربية				
AUB	westafrican	fihrist	almajid	idsc	bibalex		
---	---	---	---	---	---	محركات بحث	بنية
✓	✓	✓	✓	✓	✓	قواعد أداة	أداة

						بيانات	البحث
---	---	---	---	---	---	OCR	بنية ملف المادة
✓	---	---	---	✓	✓	صورة	
✓	✓	✓	✓	✓	✓	مخطوطات	تعدد الأشكال
✓	---	---	---	✓	✓	وثائق	
---	---			✓	✓	كتب	تراثية
مختصرة	✓	✓	✓	✓	✓	بيانات	
✓	---	---	---	بعض	✓	المادة الأصلية	مستوى الاتاحة

يتضح من جدول رقم (٤) مجموعة من المشاهدات واللاحظات وفقا للعناصر التالية :-

٤ / ١ بنية أداة البحث

أولاً : لم يجد الباحث بين كل موقع تنظيم واسترجاع المخطوطات محركا واحدا لبحث المخطوطات كما يتواافق ومفاهيم محركات بحث مواد الويب. وعلى الرغم من اطلاق قاعدة بيانات افريقيا الغربية على نظام إدارتها محرك بحث مخطوطات، إلا أنه فعلياً نظام إدارة قاعدة بيانات المخطوطات، ويعزى الباحث الاقتصاد على قواعد البيانات كبنية لموقع الكتابات اليدوية لخاصية التجميع والحفظ التي تمارس مع الكتابات اليدوية عامة والمخطوطات خاصة في مؤسسات ثقافية وتاريخية محددة، بما لا يدع مجالاً لهذه المواد في انتشارها كمفردات سابحة في فضاء الويب مقل النصوص والصور وغيرها من مواد الويب.

ثانياً : نظراً لما للكتابات اليدوية من قيم تاريخية وثقافية، فإن مؤسسات رعاية الثقافة والتراث تعمل على حفظها واخترانها في قاعدة بيانات محسنة وفقاً لمستوى الرقمنة المستخدم مع هذه المواد. ومن ثم لا يتواافق ذلك وأداء محركات البحث التي تعمل في بيئه النظم المفتوحة إضافة وتحكماً وضبطاً لمختلف مواد معلومات الويب.

٤ / ٢ بنية ملف مادة الكتابات اليدوية

أولاً : اقتصرت عمليات الرقمنة في أعلى مستوياتها في عينة الدراسة على تحويل صفحات الكتابات إلى صور رقمية للنصوص دون الارتفاع لمستوى القراءة الآلية لتلك النصوص **OCR**. ويرجع الباحث ذلك لأن عمليات المعالجة والبحث المستهدف توقف عند حدود استخدام بيانات محدودة ووصف فني مختصر يمكن من التعريف بالمخطوط دون الطموح في التعامل مع نصوص الكتابات اليدوية بحثاً واسترجاع وتحليل.

ثانياً : يمثل استخدام الصور في بعض قواعد بيانات العينة وليس جميعها، سواء إدارة لمواد الكتابات اليدوية وخاصة المخطوطات في وقف استخدامها على قاعدة البيانات دون طرح النص للإتاحة والوصول من جانب الباحثين على مستوى العالم المهتمين بالنصوص المخطوطة. وقد يكون ذلك مبرراً في حالة الوثائق القانونية، غير أنه لا يمكن القبول به في حالة المخطوطات والكتب التراثية، كما في حالة موقع مركز جمعه الماجد والفهرست وأفريقيا الغربية التي لم تضع من الأصل صوراً لمجموعاتها.

٤ / ١ / ٣ تعدد الأشكال

لم تهتم مواقع العينة جميعها بكل أشكال الكتابات اليدوية سوى مكتبة الإسكندرية **bibalex** وشبكة المخطوطات العربية **idsc** بجمع المخطوطات والوثائق وكتب التراث، وهذا يرجع إلى تمثيل هذه الموقع لهيئات مثل مكتبة الإسكندرية وشبكة المخطوطات لمحاولات بناء فهارس رقمية لمجموعات المخطوطات التي توجد على المستوى الإقليمي بالنسبة لمكتبة الإسكندرية وعلى المستوى الوطني لشبكة المخطوطات العربية التي طورها مركز معلومات دعم واتخاذ القرار بمصر. فيما ركزت باقي قواعد بيانات عينة الدراسة على المخطوطات كأشكل الكتابات اليدوية المخطوطة. وما تستهدفه هذه الدراسة هو طرح تصور لأداة بحث لا تقتصر على شكل مخطوط بعينه، إنما تتعامل وكل الكتابات اليدوية الرقمية على الويب. فيما انفردت مكتبة الجامعة الأمريكية بيروت بعرض مجموعة من الوثائق التاريخية التي تخص قضايا بعينها، وهو ما يعود إلى اهتمامها الإقليمي فيما يتعلق بتاريخ لبنان تحديداً.

٤ / ١ / ٤ مستوى الإتاحة

أولاً : انعكس الواقع التقليدي الذي عجز عن اتاحة نص المخطوط الكامل ضمن عمليات المعالجة والضبط على واقع عينة الدراسة التي لم تصل بمستوى الإتاحة لعرض النصوص الكاملة لكتابات اليدوية على مستخدميها. فقد ركزت قواعد بيانات العينة جميعها على التعامل مع بيانات الضبط البليوجرافى دون التعامل مع متون مجموعاتها

المخطوطة، واقتصر جهد موقع مكتبة الإسكندرية والشبكة العربية للمخطوطات ومكتبة الجامعة الأمريكية بيروت AUB على عرض صوراً لنصوص المخطوطات للقراءة من خلال الصور وليس لتحليل النصوص المضمنة داخلها.

ثانياً : إن مستوى الإتاحة المستهدف لهذه الدراسة هو قدرة مستخدمي الويب في الوصول إلى نصوص المخطوطات العربية وتحقيق إتاحة النص الكامل من خلال توفير آليات البحث والمعالجة والإدراك الازمة لذلك . وهو ما لم تقدمه أيّاً من مواقع عينة الدراسة، فأدوات بحث الكتابات اليدوية المأمولة هي نظم لإدارة المحتوى أكثر من كونها نظام لإدارة البيانات والمعلومات البيلوجرافية . وهي بذلك تمثل درجة أكثر تندماً في التعامل مع الكتابات اليدوية العربية، وتحقيق آفاق أوسع لرقمنة هذا التراث القومي.

٤ / ٢ محور القراءة والإدراك

يتناول هذا المحور واقع عمليات القراءة الآلية والإدراك للكلمات والحراف في نصوص مواد الكتابات اليدوية الرقمية ؛ حيث تمثل المرحلة التمهيدية لعملية التكشيف والمعالجة المعلوماتية داخل أدوات بحث الويب . فما لم تتم مرحلة الإدراك للنصوص لا يمكن إجراء مختلف العمليات المعلوماتية المستهدفة من هذه الدراسة . ويوضح جدول رقم (٥) واقع القراءة والإدراك للكتابات اليدوية على الويب .

جدول رقم (٥) قياس عناصر محور القراءة والإدراك للكتابات اليدوية

موقع قواعد بيانات المخطوطات						محور القراءة والإدراك عناصر المحور وتوصيفها	
الأجنبية			العربية			HMM	آليات قراءة النص
AUB	westafrican	fihrist	almajid	idsc	bibalex		
---	---	---	---	---	---		
---	---	---	---	---	---	Base-line	
---	---	---	---	---	---	المعاجم الآلية	

							عرض نصوص المخطوطات
---	---	---	---	---	---	نصي	
✓	---	---	---	✓	✓	مصور	

يتضح من جدول رقم (٥) مجموعة من المشاهدات واللاحظات وفقاً للعناصر التالية:-

٤ / ٢ / ١ آليات قراءة النص

أولاً : لم تأت أي من قواعد بيانات عينة الدراسة بما يدل على استخدام تقنيات التحليل والإدراك لنصوص الكتابات اليدوية حتى في قواعد البيانات التي تستخدم صوراً رقمية لعرض محتوى المادة. وهذا يؤكد النهج البدائي لموقع إدارة الكتابات اليدوية في استخدام الصور الجامدة للنصوص المخطوطة وعدم صبها في قوالب التحليل والإدراك الرقمي لمحتوها النصي، وهو ما تعكّف الدراسة على تحقيقه في أدوات البحث المطروحة.

ثانياً : تستخدم نظم استرجاع الكتابات اليدوية آليات ماركوف غير المرئية والخط الرئيس **HMM, Base-line OCR** في الوصول إلى تحليل رسومات الكلمات والحراف المصورة بتقنية **OCR**، وكونها غير موجودة في هذه القواعد يعني انتفاء نية اتاحة النصوص الكاملة لمواد الكتابات اليدوية في هذه القواعد والاقتصار على التعامل مع البيانات البليوجرافية وعناصر الميتادات، كاستمرار لما بدأت عليه عمليات الرقمنة الثابتة عند حدود رقمنة فهارس المخطوطات وليس المخطوطات أو الكتابات ذاتها.

٤ / ٢ / ٢ المعاجم الآلية

تمثل المعاجم امتداداً طبيعياً لآليات التحليل والإدراك المذكورة في العنصر السابق، لما لهما من تكامل في تحقيق القراءة والإدراك لنصوص وكلمات الكتابات اليدوية. وغياب أي من هاتين الأداتين يعني غياب الأخرى بالتبعدية. ويرى الباحث أن ما تقدمه عينة الدراسة وقواعد بياناتها يمثل اختلافاً نوعياً مما يحق لنظم استرجاع الكتابات اليدوية العربية أن تكون عليه في تقديم النصوص الكاملة قابلة للإدراك والمعالجة والبحث من جانب مستخدمي الويب.

٤ / ٢ / ٣ عرض نصوص المخطوطات

استمرار لعنصر التوافق بين قواعد بيانات العينة في محور القراءة والإدراك، فقد انتفى عرض النصوص الكاملة لمتن الكتابات اليدوية في قواعد بيانات عينة الدراسة. وذلك لما لاحتياج التعامل مع النص من الخروج من ضيق رقمنة البيانات إلى أفق رقمنة النصوص

ذاتها. وقد اقتصر التعامل مع نصوص المجموعات المختزنة في بعض قواعد البيانات على استخدام الصور الرقمية لنصوص الكتابات اليدوية وعرض النص كصورة أمام مستخدمي قاعدة البيانات. واستخدمت قواعد مكتبة الإسكندرية وشبكة المخطوطات العربية ومكتبة الجامعة الأمريكية ببيروت ملفات الصور الرقمية لعرض نصوص مجموعاتها.

٤ / ٣ محور المعالجة والتكميف

يمثل هذا المحور قلب إدارة نظم استرجاع المعلومات لما له من انعكاس على بنية النظام ككل من حيث المعايير المطلوب توفيرها للعمل داخل النظام، فضلاً عن أساليب وبنية التكميف والتنظيم ومن ثم واقع أساليب البحث والاسترجاع التي تتوافق ومستخدمي الويب في استرجاع الكتابات اليدوي. ويوضح جدول رقم (٦) واقع التكميف والتنظيم لكتابات اليدوية على الويب من حيث معايير الوصف وأدوات التكميف والتنظيم المتبعة حالياً.

جدول رقم (٦) قياس عناصر محور المعالجة والتكميف لكتابات اليدوية

موقع قواعد بيانات المخطوطات						محور المعالجة والتكميف	
الأجنبية			العربية			عناصر المحور وتصنيفها	
AUB	westafrican	fihrist	almajid	idsc	bibalex		
---	---	---	---	--	✓	رقمي	معايير الوصف
---	✓	---	---	✓	✓	AACR	
✓	✓	✓	✓	✓	✓	العنوان	
✓	✓	✓	✓	✓	✓	المؤلف	
ملخص	✓	✓	✓	✓	✓	الموضوع	
---	---	---	---	--	✓	تاريخ الصورة	
---	---	---	---	--	✓	تاريخ المسح	
---	---	---	---	--	✓	تاريخ التسجيلة	
---	---	---	---	--	✓	الناشر	
---	---	✓	---	--	✓	شكل	نهاية لمواد

							المخطوطات والمقترحة في الدراسة
---	---	---	---	---	✓	حجم الملف	
---	---	---	---	---	✓	حقوق النشر	
---	✓	---	---	✓	✓	الناسخ	
---	✓	---	---	✓	✓	النوع	
صور	---	---	---	صور	صور	النص الكامل	
✓	✓	✓	✓	✓	✓	الهيئة المسئولة	
---	ID	ID	ID	ID	ID	URL	
---	---	---	---	---	---	محتوى	
---	✓	✓	✓	✓	✓	نصي	أسلوب التكشف
---	---	---	---	---	---	نص المادة	
---	✓	✓	✓	✓	✓	الميتاداتا	آلية التكشف

يتضح من جدول رقم (٦) مجموعة من المشاهدات واللاحظات وفقاً للعناصر التالية:-

٤ / ٣ / ١ معيار الوصف الفني

تدلل نوعية معيار الوصف الفني المستخدم في قاعدة البيانات على توجه النظام في التعامل مع الكتابات اليدوية من حيث المعالجة والتنظيم والبحث ؛ فالقواعد التي تحافظ على استخدام قواعد AACR ينظر إليها على أنها قواعد الرقمنة المحدودة التي تتوقف عند تحويل التسجيلات البليوجرافية من شكلها التقليدي إلى الشكل الرقمي دون التطرق إلى نص المادة المخطوط. وقد تمثل ذلك في جل عينة الدراسة، ناهيك عن تلك التي اعتمدت على بيانات مختصرة لا ترقى وقواعد الضبط البليوجرافي. أما قاعدة بيانات مكتبة الإسكندرية bibalex فهي الوحيدة بين قواعد بيانات العينة التي طبقت مفهوم الميتاداتا ورقمنة المخطوطات من حيث الوصف الفني المطول والمقسم إلى أجزاء مصنفة تخص الشكل والبيانات الأساسية والمحتوى. وقد وصل الأمر إلى أدنى في مكتبة الجامعة الأمريكية بيروت AUB التي لم تأت بشكل يذكر لمعايير الوصف، بل اعتمدت على ذكر العنوان والمؤلف مع شرح مختصر ثم صورة رقمية للمخطوطة.

٤ / ٣ / عناصر الوصف المستخدمة

أولاً : تتناسب نوعية وعدد العناصر المستخدمة لوصف الكتابات اليدوية الرقمية تتناسباً طردياً مع مستوى الرقمنة المتبع داخل النظام ؛ حيث تتتنوع العناصر المطلوبة لوصف ملفات الكتابات اليدوية كلما زادت عمليات المعالجة بذكر خصائص المادة التقليدية وخصائصها الرقمية وبيانات ملف حمل المادة المصورة مع البيانات الببليوجرافية التي تتوافق المخطوط كمادة معلومات. وقد حدّدت الدراسة مجموعة عناصر الوصف المقترحة لمعالجة الكتابات اليدوية كمقياس لعينة الدراسة، حيث شملت العناصر المقترحة مزجاً بين تلك التي تتوافق ومصادر الكتابات اليدوية العربية وبين العناصر المستخدمة لمعالجتها في البيئة الرقمية.

ثانياً : اتفقت مختلف قواعد بيانات عينة الدراسة في عناصر الوصف التي أخذت بها والعناصر التي لم تستخدمها، إلا مكتبة الإسكندرية التي نحت منحاً رقمياً لا يقارن مع باقي قواعد بيانات العينة ؛ حيث أخذت قواعد البيانات جميعها بعناصر المؤلف والعنوان والموضوع وزادت قاعدة بيانات إفريقيا الغربية في عنصرين عن الناشر ونوع المادة، بينما حققت مكتبة الإسكندرية bibalex كل عناصر الوصف المقترحة. ويعزي الباحث ذلك إلى دعم قاعدة بيانات مكتبة الإسكندرية للمفهوم الحقيقى للميادىات، فضلاً عن استمرارية العمل والتحديث التقنى والفنى والمستمرتين لقاعدة بياناتها، في حين تشير الواقع باقى عينة الدراسة إلى توقف التحديث عند أعوام ٢٠٠٦ و ٢٠١٢ في بعض قواعد البيانات الأخرى.

ثالثاً : تتمثل عناصر الوصف البنية الأساسية لملفات الكتابات اليدوية المقترح بناؤها رقمياً، التي ستعامل مع بيئة الويب المفتوحة وأدواتها تنظيمياً وبحثاً بما سيجعل مادة المعلومات المخطوطة تنتشر سابحة بين قواعد بيانات محركات البحث حاملة مختلف عناصر الوصف الفنى التي تحكى قصة المادة التاريخية بما في ذلك حقل content لحمل النص الكامل في شكل نصي. وليس في شكل ملف صورة كما تعاملت معه قواعد بيانات عينة الدراسة التي أتاحت نصوص الكتابات المصورة.

٤ / ٣ / أسلوب التكشيف

أولاً : لم تتحقق كل قواعد بيانات عينة الدراسة مفهوم التكشيف في بيئة الويب داخل مجموعاتها، حيث استخدمت عينة الدراسة جميعها مفهوم رؤوس الموضوعات للإشارة إلى الموضوعات والأفكار الرئيسية الواردة داخل مجموعات المخطوطات. وقد زادت عن

ذلك مكتبة الإسكندرية **bibalex** فقط في عرض قائمة محتويات المخطوطات بما يمكن أن يمثل تكشيفاً عاماً وليس على مستوى النص الكامل. في حين لم تقترب مكتبة الجامعة الأمريكية بيروت **AUB** من مفهوم التحليل الموضوعي إلا في عرض شرح مختصر لمحفوظة.

ثانياً : ترتبط آلية تكشيف النص الكامل المستهدف في هذه الدراسة والمؤدي إلى تحليل مختلف الكلمات والفراءات اعتماداً على فدرات المسح الرقمية وآليات الاستيقاف لجعل مختلف كلمات النص داخل كشفية يمكن من خلالها بحث واسترجاع نصوص الكتابات اليدوية. ولم تستخدم آليات الإدراك **Recognition** في الوصول إلى نصية الكتابات اليدوية ومن ثم التمكن من تكشيفها بأسلوب التكشيف الاستيفادي.

ثالثاً : لم تتحقق عينة الدراسة أسلوب التكشيف المبني على المحتوى المعتمد على التعامل مع ملفات الصور الرقمية وقراءة عناصرها الرسمية وأشكال الكلمات باستخدام آليات اللون والبنية والأبعاد في كتابات حروف اللغة العربية، وهو ما يمثل نوعاً متقدماً من التقنيات والبرمجيات التي مازالت قيد الدراسة والتجريب في العالم الغربي.

٤ / ٣ / ٤ آلية التكشيف

اعتمدت قواعد عينة الدراسة على التحليل والتلخيص من خلال التمثيل المكثف باستخدام الميتادات التي تصاحب المادة المخطوطة وليس النص الكامل للمادة، وهو ما يعكس مدى البعد عن الموضوعات والمحفوظة الموضوعي الوارد في نصوص الكتابات اليدوية بما ينعكس نهاية بالسلب على تنظيم وبحث الكتابات اليدوية على الويب.

٤ / ٤ محور البحث والاسترجاع

تركز الدراسة في هذا المحور على النظر لواقع آليات وأساليب البحث والاسترجاع المستخدمة مع مواد الكتابات اليدوية حيث يمكن من خلالها الحكم على أسلوب بنية وعمل نظام استرجاع الكتابات ككل. فتوفير البحث الحر يعكس القراءة والإدراك للنص الكامل لمادة الكتابات اليدوية من مخطوطات ووثائق، أيضاً استخدام الحقول في البحث يعكس معيارية الوصف الفني للكتابات اليدوية. ويوضح جدول (٧) شكل وواقع البحث والاسترجاع للكتابات اليدوية.

جدول رقم (٧) قياس عناصر محور بحث والاسترجاع للكتابات اليدوية

موقع قواعد بيانات المخطوطات	محور البحث والاسترجاع	
	الأجنبية	العربية

AUB	westafrican	fihrist	almajid	idsc	bibalex	عناصر المحور وتصنيفها	
---	---	---	---	--	---	النص	البحث عن المادة
---	✓	✓	✓	✓	✓	الميتابوبيات	
---	✓	✓	✓	✓	✓	النصي	أسلوب الاسترجاع
---	---	---	---	✓	---	المحتوى	
---	✓	✓	✓	✓	✓	الحر	أساليب البحث
✓	---	✓	---	✓	✓	التصفح	
---	✓	✓	✓	✓	✓	العنوان	البحث بالحقول
---	✓	✓	✓	✓	✓	المؤلف	
---	✓	✓	✓	✓	✓	الموضوع	
---	---	---	---	✓	✓	الناشر	
---	---	---	✓	--	✓	رقم الطلب	
---	✓	---	---	--	✓	التاريخ	
---	---	✓	✓	✓	---	محددات	
---	---	---	---	---	---	البحث	
---	✓	---	✓	✓	✓	البوليفاني	آليات البحث
---	✓	✓	✓	✓	✓	التطابق	
---	---	---	✓	✓	✓	المقاطع	
---	---	---	---	--	---	جذر الكلمة	آليات بحث اللغة العربية
---	---	---	---	--	---	المقابل	
---	---	---	---	--	---	المعنى	
---	---	---	---	--	---	المترادفات	

يتضح من جدول رقم (٧) مجموعة من الملاحظات المستخلصة وفقاً للعناصر التالية :-
٤ / ١ البحث في نص المادة

هدفت الدراسة من خلال تحرى واقع هذا العنصر معرفة التوجه العام لدى عينة الدراسة في بحثها لمواد الكتابات اليدوية ؛ حيث تختار نظم الكتابات اليدوية أحد خيارين ؛ فإذاً استخدام البحث في النص الكامل شأن محركات البحث مع صفحات الويب، وهو ما يدل على تطوير النص الكامل للكتابات اليدوية لعملية البحث والاسترجاع، بما يعكس قدرات التحليل والمعالجة الكاملة للكتابات اليدوية. وإنما أن تتجه النظم إلى البحث باستخدام الميتاداتا بمعزل عن نص ومحفوظ الكتابات اليدوية، وهو ما يدل على بعد التام عن حماولات المعالجة والبحث لنصوص الكتابات اليدوية. وقد أكد واقع عينة الدراسة ما تتجهه قواعد الكتابات اليدوية في التركيز على المعالجة والبحث باستخدام الميتاداتا وبعد التام عن معالجة واسترجاع المحتوى والنصوص الكاملة للكتابات اليدوية، نظراً لما تحتاجه من قدرات إدراك وتحليل للنصوص المخطوطة. وقد ظهر ذلك جلياً في مكتبة الجامعة الأمريكية بيروت التي اعتمدت على تصفح موادها فقط دون الاعتماد على خيارات البحث.

٤ / ٤ / ٢ أسلوب الاسترجاع

أولاً : يعتمد بحث مواد المعلومات المصورة عامة على استخدام أسلوب البحث بالنص والبحث بالمحفوظ، ونظراً لطبيعة الكتابات اليدوية التي تمثل في شكل نصوص مصورة بتقنية **OCR** فإن البحث بالمحفوظ يعد أساسياً لنظم إدارة الكتابات اليدوية على الويب. واستمرار للمعالجة المحدودة غير المتعمرة للكتابات اليدوية ونحوها بشكل مباشر، فقد اعتمدت عينة الدراسة على استخدام البحث بالنص من خلال حقول الميتاداتا لبحث واسترجاع الكتابات اليدوية. وانفردت شبكة المخطوطات العربية **idsc** وحدتها ببني أسلوب التصفح بصور المخطوطات كأحد أشكال البحث بالمحفوظ من خلال عرض المجموعات للتتصفح المرئي من جانب المستفيدين تحت مسمى **ألبوم المخطوطات**، على الرغم من كونه يشمل مجموعة محدودة فقط.

ثانياً : عكس واقع عينة الدراسة جميعها غياب آليات المعالجة والإدراك اللازمين لنصوص الكتابات اليدوية المصورة، فالكلمات والحرروف في الكتابات اليدوية الرقمية تمثل رسوماً وأشكالاً غير مقرؤة من أدوات بحث الويب. ومن ثم فإن بحث واسترجاع نصوص الكتابات المخطوطة على طبيعتها المصورة يتطلب استخدام آليات بحث الصور الرقمية وتحليل محتواها الشكلي. وباستخدام آليات تحليل صور محتوى الكتابات اليدوية

ستتمكن أدوات البحث من استخدام آليات البحث بشكل الكلمة والبحث بنماذج الحروف وصور الكلمات، فضلاً عن البحث بتصفح صور النصوص المخطوطة.

٤ / ٤ / ٣ أساليب البحث

تنوع أشكال بحث الكتابات اليدوية لتصب في أسلوبين أساسين هما البحث الحر باستخدام الكلمات المفتاحية، والبحث بالتصفح باستخدام التوزيع الهرمي للمصطلحات أو للأشكال في حالة المواد المرئية. وقد أكدت عينة الدراسة على ثابت استخدام البحث بالكلمات المفتاحية في عينة الدراسة مع الاستعانة بأسلوب البحث بالتصفح في بعض قواعد بيانات الكتابات اليدوية. وقد اختلفت قواعد بيانات البيانات فيما بينها في شكل التصفح المستخدم مع الكتابات اليدوية؛ حيث تبنت مكتبة الاسكندرية والفهرست استخدام التصفح بالمصطلحات التي تتتنوع بين التصفح بالمؤلفين أو التصفح بتواريخ المخطوطات أو التصفح بالحروف الهجائية لعناوين الكتابات اليدوية، أما قاعدة الشبكة العربية للمخطوطات ومكتبة الجامعة الأمريكية بيروت فقد استخدمنا التصفح بصور المخطوطات في شكل لقطات مصورة. ولعل غياب الاهتمام بجانب تحليل وبنية ومعالجة ملفات الكتابات اليدوية ذاتها ونصوصها المصورة هو تفسير غياب التصفح والبحث بمحتوى مواد المعلومات المخطوطة.

٤ / ٤ / ٤ البحث بحقول الوصف

أولاً : مثل البحث بالحقول في عينة الدراسة انعكساً لمدى الاعتماد على عناصر الميتادات في وصف الكتابات اليدوية وتنظيمها، وتزداد قدرات البحث بالحقول في قواعد البيانات وفقاً لعدد الحقول النشطة للبحث والاسترجاع من جملة حقول الوصف المكونة للتسجيلة النهائية لمادة المعلومات. وقد توافقت قواعد بيانات العينة على البحث استخدام حقول العنوان والمؤلف والموضوع في البحث عن الكتابات اليدوية، في حين زاد بعضها باستخدام حقول الناشر والتاريخ ورقم الطلب ID مثل قاعدة بيانات مكتبة الاسكندرية الأكثر عدداً لحقول البحث، ثم افريقيا الغربية وشبكة المخطوطات العربية

ثانياً : يرتبط باستخدام البحث بالحقول آلية محددات البحث، وذلك لضبط وتدقيق هذا استراتيجية البحث والتحكم التام في النتائج المسترجعة. وتمثل محددات البحث في طبيعتها حقولاً إضافية للبحث لم تترك للمستخدم بوضع الكلمات المفتاحية بها، إنما بختار النظام اتحاتها من خلال قائمة محددة من خيارات البحث تساعد على ضبط النتائج المسترجعة، مثل محدد اللغة لاختيار لغة المجموعات المسترجعة دون غيرها أو محدد التاريخ أو

محدد الموضوع والفتة العامة لنوعية الكتابات اليدوية. وقد عكس واقع الدراسة أن قواعد البيانات التي لم تستخدم حقوقاً للبحث كثير قد استعاضت عن ذلك بإتحاد محددات البحث باللغة وغيرها محقولاً بحث إضافية.

٤ / ٤ / ٥ آليات البحث المستخدمة

استخدمت قواعد البيانات العربية من عينة الدراسة آليات البحث مثل البحث بالتطابق والبحث بمقاطع الكلمات أكثر من نظيرتها الأجنبية. وذلك يرجع إلى وضع طبيعة البحث بالكلمات العربية التي تتسم بالميل إلى اللغة الطبيعية أكثر من البحث باللغة المقيدة، ومن ثم كانت آليات البحث للضبط والتحكم في الكلمات المفتاحية المدخلة في البحث. وترتبط آليات البحث بأساليب البحث المستخدمة لصياغة استراتيجيات وشكل البحث المعبر عن الحاجات المعلومات المستفيدين، حيث يمكن من خلال هذه الآليات التحكم باستبعاد واستدعاء وتوسيع نتائج البحث وفقاً للحاجة.

٤ / ٤ / ٦ آليات بحث اللغة العربية

خلت عينة الدراسة بقواعد بياناتها العربية والأجنبية من آليات البحث الدالة على معالجة النصوص العربية في مجموعات الكتابات اليدوية، وعلى الرغم من أن مجموعات المعلومات المخطوطة باللغة العربية، غير أنه لم تظهر في صفحات البحث لهذه النظم أي استخدام للبحث باللغة العربية مثل البحث بالمعنى أو بجزر الكلمة أو بالترادف. ويرجع الباحث ذلك إلى غياب تام لأدوات تحليل اللغة العربية في قواعد بيانات العينة من المعاجم الآلية والمحللات الصرفية. وهذا بدوره يعود إلى غياب مبدأ تحليل وإدراك نصوص الكتابات العربية التي يجب أن تعتمد في معالجتها وبحثها على أدوات اللغة للتواافق والبنية اللغوية التي أنت عليها هذه الكتابات. هذا فضلاً عن استخدام قواميس لغوية تتوافق وطبيعة العصر والمكان اللذين شهدما هذا الانتاج الفكري من المخطوطات والوثائق.

المبحث الخامس : الرؤى والنتائج والتوصيات

٥ / ٢ رؤى ونتائج الدراسة

(١) أن العالم العربي كوحدة ثقافية واحدة مشتركة الهوية لم تكن على قدر الاهتمام المطلوب في التعامل مع المواد التراثية العربية من مخطوطات وكتب تراثية ووثائق تاريخية كونها مواد معلومات تحمل قيمة معرفية وتاريخية وحضارية،

وتحتاج هذه المواد المخطوطة إلى التقانين والمعايير المتواقة وبنيتها الرقمية وإختلاف تنظيمها ومعالجتها وبحثها في بيئه الويب عن البيئة التقليدية التي لبنت فيها عمرا سابقا. ويأت التقييد والتقنين من خلال مجموعات علمية تاريخية تقافية مشتركة عبر المؤسسات القومية العربية.

(٢) أن الكتابات اليدوية مواد معلومات تقليدية النشأة ورقمية الإدارة والتنظيم بما يجعلها تحتاج إلى آليات تكشف وبحث واسترجاع تختلف عن طبيعة أدوات بحث الويب الآنية، بما يدفع القائمين على الويب W3C لتحديث أنماط وآليات أدوات بحث الويب في تعاملها مع مواد معلومات كالكتابات اليدوية – بالإضافة لاتخاذ التدابير التقنية والدراسات المكثفة في ضبط معالجة واسترجاع نصوص الكتابات اليدوية على الويب.

(٣) أن الكتابات اليدوية العربية هي مواد تختلف بين العلمية والقانونية والاجتماعية، ومن ثم فإن طبيعة التكشف المطلوب لتحليل هذه يتعامل مع مفردات وأساليب تعكس هوية وثقافة محددة. ولا يمكن الاعتماد هنا على استخدام تقنيات التحليل الرقمية وحسب، وإنما متابعة مخرجات النصوص الناتجة عن عملية التحليل لاقامة بنية المادة العلمية والسياق النصي كما أراد له كاتبها.

(٤) أن إدارة محتوى مواد الكتابات اليدوية العربية مازالت ترتكن إلى الباحثين والمتخصصين غير العرب لإجراء عمليات إدراك النصوص وتحليل المحتوى الفكري، مما أثر بطبيعته على معالجة وتكشف النصوص العربية التراثية، فجعل حدود المعالجة لهذه المواد التراثية تقف عند حدود النواحي التقنية الرقمية والتعامل مع النصوص كصور وأشكال رسومية دون التعمق في فهم وإدراك المحتوى الفكري والتراث المعرفي بين سطور هذه الكتابات.

(٥) أن مواد الكتابات اليدوية كمصادر معلومات لا تتوقف فقط عند المجموعات التاريخية ذات النشأة التقليدية، إنما تتعذر ذلك إلى المجموعات ذات النشأة الرقمية المنتجة بواسطة أدوات الكتابة اليدوية الرقمية الحالية. مما يعكس تنامي حجم وأشكال الكتابات اليدوية الرقمية ووقوف محركات وأدوات بحث الويب عند هذه المواد بالدراسة والمعالجة لضبط بحثها واسترجاعها على الويب. مما يجعل هذه الأدوات متأخرة في ملاحقة تداول وانتشار هذه المواد في بيئه الويب.

(٦) أن مختلف محاولات الضبط والتنظيم لمواد الكتابات اليدوية التي ركزت على المخطوطات دون الوثائق قد عملت على استخدام أساليب العرض الرقمية المبسطة دون تكوين قواعد بيانات معيارية مهيكلة لمعالجة وإدراك محتوى الكتابات اليدوية. بما انعكس على مجموعات قواعد البيانات على الويب بعدم وجود آليات بحث للنصوص والمحتوى الفكري لها. ويتتيح لأدوات بحث الويب فيما بعد التوافق وبفحص هذه المواد.

(٧) أن مواد الكتابات اليدوية مواد معلومات تعود في كتابتها وتتأليف إلى عصور زمنية تختلف اجتماعياً وعلمياً عن عصر الويب، مما جعلها تختلف في أسلوب الكتابة والصياغة والبناء اللغوي لمحتوى المخطوطات والوثائق. ومن ثم فإن عمليات تكشف وتحليل محتوى نصوص هذه المواد يحتاج بناء معاجم لغوية ومحللات صرفية لا تتم فقط بالقدرة على تحليل الكلمات لغوية، وإنما القدرة على فهم المفردات والمصطلحات التاريخية التي تنتهي لعصور زمنية راجعة. وذلك حتى يمكن الوقوف على محتواها الفكري والتراثي المستهدف إيصاله لقارئيه. وقد خلت عينة الدراسة من أساليب بحث اللغة العربية بما يدل على غياب أدوات معالجتها.

(٨) أن موقع المخطوطات المعتمدة على قواعد بيانات تقدم معالجة وآليات بحث مواد الكتابات اليدوية أكثر معيارية من تلك التي تتبعها محركات البحث التي تكاد على تقديم معالجة أو بحث يدعم الكتابات اليدوية. وذلك لكون محركات البحث تعامل مع فضاء الويب غير المحدود وما ينتشر فيه من مواد معلومات غير معيارية البناء الرقمي، بما انعكس على عدم وجود آليات بحث الكتابات اليدوية، فضلاً عن معياريتها وقدرتها على التعامل مع هذه النوعية من مواد المعلومات.

(٩) أن عملية الإدراك **Recognition** هي لب بناء نظم استرجاع الكتابات اليدوية؛ فبدونها لا يمكن لعمليات التكشيف والتحليل أن تتم، فالتكشيف لا يتم إلا على الكلمات النصية التي تعطي مفاهيم ومعانٍ محددة يتم اختيارها واعتبارها مداخل كشفية أو مصطلحات دالة على المضمون الفكري للنص. ولا يمكن للنص أن يولد في شكل كلمات وحروف نصية إلا من خلال عملية الإدراك التي تحول الكلمات والحوروف المصورة إلى كلمات وحروف نصية تتوافق وعمليات التكشيف الآلي للنصوص.

(١) أن بيئه الويب هي بيئه ديناميكية سريعة الدمج والتحول، وقد أفرز ذلك خروج مواد الكتابات اليدوية الرقمية على الويب التي جمعت في بنائها الرقمي بين خصائص المعلومات النصية والمعلومات المchorة في مادة معلومات واحدة. يمكن أن يطلق على توصيفها المعلومات نصوص مchorة أو صور نصية تحتاج بدورها إلى آليات وأساليب معالجة وبحث ذات طبيعة مختلفة عن تلك التي اعتادت عليها أدوات بحث الويب.

(٢) أثبتت الدراسة التجريبية أن مختلف قواعد بيانات عينة الدراسة يرجع إلى بنية مؤسسية ذات صبغة علمية أو تقافية، مما يعكس دوره غياب الاتجاه العام للويب وأدوات بحثها وتأخيرها في معالجة وبخث واسترجاع مجموعات الكتابات اليدوية على الويب بشكل عام. وهو ما يؤكد على أن الاهتمام بممواد الكتابات اليدوية الرقمية على الويب مازال جزئياً أو مبتوراً لا يتوافق وانتشار هذا الشكل الجديد من مواد حمل المعلومات الرقمية على الويب.

٥ / ٣ توصيات الدراسة

١. يجب على المؤسسات القومية العربية الاهتمام برقمنة ومعالجة التراث العربي ومواده المعلوماتية من الكتابات اليدوية في بيئه الويب، وذلك من خلال الهيئات الثقافية مثل المنظمة العربية للتربية والثقافة والعلوم أو المؤسسات المتخصصة في حفظ التراث العربي. ويتجلّى هذا الاهتمام في طرح مشروعات قومية لرقمنة الكتابات اليدوية العربية والاشراف على بناء نظم استرجاع قومية تجمع التراث العربي الرقمي من الكتابات اليدوية.
٢. يجب أن يتضطلع مؤسسات الويب مثل W3C بدورها في متابعة مستحدثات مواد المعلومات في بيئه الويب، والدأب على ابتكار أدوات وآليات بحث تتوافق ومواد المعلومات الرقمية ذات الخصائص المختلفة بما عليه بيئه الويب مثل مواد الكتابات اليدوية العربية.
٣. يجب على المؤسسات البحثية وأقسام علوم المعلومات الاهتمام بالتغييرات السريعة المتواالية في شكل ونوعية مواد المعلومات في بيئه الويب، ومن ثم ملاحقة هذه التطورات بتجهيزات الدراسة والبحث والتقييد. وقد لمست دراستنا الحالية هذه الحاجة في حالة مواد الكتابات اليدوية العربية التي افتقدت إلى معايير ومقاييس علمية مقننة.

٤. يجب على القائمين على تشريعات المعلومات وحماية التراث القومي العربي خاصة المضي في صياغة حزمة قوانين وتشريعات تتوافق واتاحة مواد الكتابات اليدوية العربية في بيئة الويب، وذلك لضبط تداولها واستخدامها وفي بيئة مفتوحة التعامل مع مواد المعلومات وأدوات بحثها.

مصادر الدراسة :

- 1 Khodadadzadeh , Iman. Recognition of Handwritten Arabic Characters, The University of Windsor, Canada, phd, 2010, UMI dissertation abstracts, 2011, Cited at 28/8/2014, cited at <http://search.proquest.com/pqdtglobal/docview/753900059/fulltextPDF?source=fedsrc&accountid=37552>
- 2 Boukharouba , Abdelhak and Bennia , Abdelhak. Recognition of Handwritten Arabic Literal Amounts Using a Hybrid Approach, Springer Science+Business Media, LLC 2010, cited at 28/8/2014, cited at <http://link.springer.com/article/10.1007/s12559-010-9088-6>
- 3 Zaher al aghbari and Salama brook. HAH : A holistic paradigm for classifying and retrieving historical Arabic handwritten documents, expert systems and applications, ELSEVIER, 2009, cited at 21/10/2014, cited at http://www.sciencedirect.com/science?_ob=ArticleListURL&_method=list&_ArticleListID=630377253&_sort=r&_st=13&view=c&md5=ed939358c10c0d84af2f9e52664db0f3&searchtype=a
- 4 Ziaratban, Majid and Faez, Karim. Nona-uniform slant estimation and correction for Farsi/Arabic handwritten word, Springer-Verlag 2009, cited at 25/8/2014, cited at <http://link.springer.com/article/10.1007/s10032-009-0092-x>
- 5 Srihari, Sargur & Srinivasan, Harish & Pavithra Babu and Bhole, Chetan. Handwritten Arabic Word Spotting using the CEDARABIC Document Analysis System, State University of New York , 2010, cite at 25/8/2014, cited at <http://www.sciencedirect.com/science/article/pii/S0890540185711054>
- 6 Alkhateeb, Jawad H and Ren, jinchang. Offline handwritten Arabic cursive text recognition using hidden markov models and re-ranking, Elsevier B.V., 2011, cited at 1/9/2011, cited at <http://www.sciencedirect.com/science/article/pii/S0167865511000432>

- 7 Akinwonmi, A.E. Adewale, M.Tech., O.S. Design of a Neural Network Based Optical Character Recognition System for Musical Notes, The Pacific Journal of Science and Technology, 2008, cited at 20/10/2014, cited at http://link.springer.com/chapter/10.1007/978-3-540-77226-2_45
- 8 Stoliński, Sebastian. Application of OCR systems to processing and digitization of paper documents, Computer Engineering Department, Technical University of Łódź, Poland, 2006, cited at 20/10/2014, cited at http://www.google.com.eg/url?sa=t&rct=j&q=&esrc=s&source=web&cd=2&cad=rja&uact=8&ved=0CCsQFjAB&url=http%3A%2F%2Fsstolin.kis.p.lodz.pl%2Fdane%2Fpub%2F10_isim_ocr.pdf&ei=f3oFVKLJHqX5yQPi3oCYAw&usg=AFQjCNGhTzYvivpt_sQG1uJALWfc9UsCgA
- 9 Bhatia, Neetu. Optical Character Recognition Techniques: A Review, International Journal of Advanced Research in Computer Science and Software Engineering, 2014, cited at 20/10/2014, cited at http://scholar.google.com.eg/scholar?q=arabic+handwritten+retrieval&hl=ar&as_sdt=0,5&as_vis=1
- 10 Hu, Zhijuan and Wu, Lu. Research on OCR Post-processing Applications for Handwritten Recognition Based on Analysis of Scientific Materials, Springer, 2011, cited at 30/9/2014, cited at http://link.springer.com/chapter/10.1007/978-3-642-23777-5_22
- 11 سيد ربيع سيد ابراهيم. محركات بحث الصور الثابتة على الانترنت : دراسة تحليلية. الرياض : مكتبة الملك فهد الوطنية ، ٢٠٠٧ .
- 12 نفس المصدر السابق.
- 13 Li, Yi & Zheng, Yefeng and David Doermann. Script-Independent Text Line Segmentation in Freestyle Handwritten Document, transactions on pattern analysis and machine intelligence, 2008, cited at 10/10/2014, cited at <http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=4359385>
- 14 Alma'adeed, Somaya and Higgins, Colin. Off-line recognition of handwritten Arabic words using multiple hidden Markov models, University of Nottingham, Nottingham NG8 1BB, UK, 2004, cited at 1/9/2014, cited at http://db5.eulc.edu.eg/eulc_v5/libraries/start.aspx?ScopeID=1.&fn=portal&DefaultLang=

- 15 Tagougui, Najiba , Kherallah, Monji and Alim, Adel M. Online Arabic handwriting recognition: a survey, Springer-Verlag 2012, cited at 12/10/2014, cited at <http://link.springer.com/article/10.1007/s10032-012-0186-8>
- 16 Alma'adeed, Somaya and Higgins, Colin.OP. CT.
- 17 Mozaffari, Saeed and Faez, Karim. Two-stage lexicon reduction for offline arabic handwritten word recognition, International Journal of Pattern Recognition, World Scientific Publishing Company, 2008, cited at 30/9/2014, cited at http://db5.eulc.edu.eg/eulc_v5/libraries/start.aspx?ScopeID=1.&fn=portal&DefaultLang=
- 18 Bernard, Bianne and Laure, Annev and Menasri, Fare `s and Mohamad, Rami Al-Hajj. Dynamic and Contextual Information in HMM Modeling for Handwritten Word Recognition, the IEEE Computer Societ, 2011, cited at 20/11/20134, cited at <http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=5708152>
- 19 Abandah, Gheith A. And Khedher, Mohammed Z. Analysis of Handwritten Arabic Letters Using Selected Feature Extraction Techniques, International Journal of Computer Processing of Languages, World Scientific Publishing Company, 2009, cited at 14/10/2014, cited at http://db5.eulc.edu.eg/eulc_v5/libraries/start.aspx?ScopeID=1.&fn=portal&DefaultLang=
- 20 ~a-Boquera, Salvador Espan and Castro-Bleda , Maria Jose. Improving Offline Handwritten Text Recognition with Hybrid HMM/ANN Model, IEEE transactions on pattern analysis and machine intelligence, 2011, cited at 30/9/2014, cited at <http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=5551147>
- 21 Abandah, Gheith A. and Jamour, Fuad T. A Word Matching Algorithm in Handwritten Arabic Recognition Using Multiple-Sequence Weighted Edit Distances
IJCSI International Journal of Computer Science , 2014, cited at 13/10/2014, cited at <http://link.springer.com/article/10.1007/s10032-013-0201-8>

- 22 Ouwayed, Nazih and Abdel Belaïd. Separation of Overlapping and Touching Lines within Handwritten Arabic Documents, Springer-Verlag Berlin Heidelberg, 2009, cited at 20/10/2014, cited at http://link.springer.com/chapter/10.1007/978-3-642-03767-2_29
- 23 Huang, Chen. Content-based handwritten document indexing and retrieval, the State University of New York, phd, UMI ProQuest Information and Learning Company, 2008, cited at 25/10/2014, cited at <http://search.proquest.com/pqdtglobal/docview/304373118/fulltextPDF?source=fedsrch&accountid=37552>
- نظام استرجاع المعلومات الكوني.- الرياض : مكتبة الملك فهد الوطنية ، ٢٠٠٩ . : سيد ربیع سید ابراهیم. الويب²⁴
- . الرياض : مكتبة الملك فهد : سيد ربیع سید ابراهیم. نظام استرجاع قواعد بيانات الويب غير المرئية 25 الوطنية، ٢٠١٠.
- 26 Mattison, david. Images of History on the Web. informataion today,inc, 2002, cited at: 15/10/2014, cited at <http://www.infotoday.com/searcher/may02/mattison.htm>
- نظام استرجاع المعلومات الكوني. مصدر سابق. : سيد ربیع سید ابراهیم. الويب²⁷
- 28 AL-BADR , Badr H. Using the Internet in Arabic: Problems and Solutions , King Abdul aziz City for Science and Technology , [2009] , cited at 22/11/2014 , cited at http://www.isoc.org/inet98/proceedings/5f/5f_1.htm
- 29 Semmar, naserdine. A cross language information retrieval system, laboratory of multilanguage multimedia, 2005, cited at 11/11/2014, cited at www-list.cea.fr/.../gb/Alger2005_semmar_a_cross_language_information_retrieval_system.pdf
- 30 Srihari, Sargur & Huang, Chen and Srinivasan, Harish. Content-based Information Retrieval from Handwritten Documents, National Institute of Justice grant 2002, cited at 29/10/2014, cited at <http://link.springer.com/article/10.1007/s10032-010-0124-6>
- 31 Rodríguez-Serranoa, José A. And Perronnin , Florent. Handwritten word-spotting using hidden Markov model sand universal vocabularies, Elsevier Ltd. 2009, cited at 25/10/2014, cited at http://www.sciencedirect.com/science?_ob=ArticleListURL&_method=list&_ArticleListID=-

- 634286345&_sort=r&_st=13&view=c&md5=a9263c353414c46f7e0f68a7b77
3f681&searchtype=a
- 32 Jain , Anil K. and Namboodiri, Anoop M. Indexing and Retrieval of On-line Handwritten Documents , Michigan State University, IEEE, 2003, cited at 20/9/2014, cited at <http://www.sciencedirect.com/science/article/pii/0167865595000941>
- 33 Sarkar, Sayantan. Word Spotting in Cursive Handwritten Documents using Modified Character Shape Codes, Department of Electrical Engineering, NIT Rourkela, 2010, cited at 10/10/2014, cited at <http://www.sciencedirect.com/science/article/pii/S0957417409001511>
- ³⁴ سيد ربيع سيد ابراهيم. محركات بحث الصور الثابتة على الانترنت. مصدر سابق.
- 35 Cao, Huigu. Indexing and retrieval of low quality handwritten documents, University of New York at Buffalo, PHD, author, UMI ProQuest LLC, 2008, cited at 24/10/2014, cited at <http://search.proquest.com/pqdtglobal/docview/305521651/fulltextPDF?accoun tid=37552>
- 36 Zaher al aghbari and Salama brook. HAH : A holistic paradigm for classifying and retrieving historical Arabic handwritten documents. OP. CT.
- 37 Srihari, Sargur & Srinivasan, Harish & Pavithra Babu and Bhole, Chetan. Content-based Information Retrieval from Handwritten Documents. OP.CT.