

دور المكون الصرفي في بناء المعجم الإلكتروني للغة العربية

"قاعدة بيانات المصادر"

محمد الحناش و رشيدة محمد القاسمي

جامعة عجمان للعلوم والتكنولوجيا

دولة الإمارات العربية المتحدة

E-mail: elhannach@yahoo.com

ملخص

سيركز هذا البحث على دور الوزن والميزان الصرفيين في بناء المعجم الإلكتروني للغة العربية، وكيف أن إغفال هذا المكون أو سوء تطبيقه أدى إلى ضعف الكثير من البرمجيات العربية، خاصة في بناء المدخل والمولد الصرفيين، وذلك على الرغم من الجهد الكبير التي أنفقت في حوسبة اللغة العربية. لهذا السبب لا نجد اليوم ببرامج حاسوبية عربية قادرة على إنجاز مهمة الترجمة الآلية بنسبة معقولة، أو قريبة من المعقول، كما لا نجد ببرامج القراءة البصرية للمحارف العربية التي تبني بالغرض بشكل مريح، وغير هذه البرامج كثير، وما ذلك – في نظرنا – إلا لتقليل هذه البرمجيات من دور المكون الصرفي للغة الضاد.

كما سيركز على الطبيعة الانصهارية للغة العربية، خلافاً للغات الأوروبية التي توصف بكونها لغات إلساقيّة، وسترصد انتظام هذا المكون في تشكيل الكلمة توليداً وتحليلاً، وقدرته على توزيع المورفيمات الصرافية داخل بنية الجذور العربية لتجعل منها مداخل معجمية تصبح قابلة للتصنيف الدلالي، والتأليف التركيبى، والتنوع التداولى.

كما سنقوم بتعريف مفصل لمفهوم المعجم الإلكتروني وتطبيقاته في اللغات الطبيعية، مع التركيز على الخصائص الصرافية (الخوارزمية) للغة العربية من وجهة نظر الهندسة اللسانية، وإبراز أهمية هذا المكون وضرورته لبناء المدخل التركيبى الآلي للغة العربية، إذ تبين لنا أنه يصعب التقدم في بناء باقى المدخلات الآلية للغة العربية قبل الانتهاء من توصيف المكون الصرفي توصيفاً هندسياً لسانياً.

سنقترح نموذجاً لسانياً حاسوبياً يطبقه على قاعدة بيانات المصادر العربية (250.000 مدخل صرفي مشفر)، لمعالجة هذا الوضع انطلاقاً من المقاربة النظرية التي تجعل من الوزن الصرفي البنية العميقية للكلمة العربية، بينما يجعل من الميزان الصرفي بيتهما السطحية.

ستختتم البحث بتحليل إحصاءات جميع المداخل الصرافية المولدة صرفيًا في اللغة العربية، وتشمل نحو 800 جذر، بينما تجعل من الميزان الصرفي بنيتها السطحية.

صيغة صرفية، موزعة على أقسام الكلم التالية: أسماء الذوات، أفعال، مصادر، مشتقات.

مدخل تعريفي:

الهدف من هذا البحث هو التعريف بالإمكانات التي يقدمها الحاسوب لمعالجة اللغة العربية بوصفها لغة طبيعية، كما يتعرض للطريقة التي يجب اتباعها لإدماج اللغة العربية في مكونات التقانة الحديثة، بهدف إقامة الحوار بين الإنسان والآلة بلغة الصاد. وقد تبين أنه كلما تطورت تقانات الحاسوب ازداد قرباً من محاكاة دماغ الإنسان في طريقة عمله، مما يسمح للغة بالقيام بدور كبير في تطور هذه التقانة، وعندما نقول معالجة اللغة في هذا السياق فإننا نقصد الهندسة اللسانية، وهذه الأخيرة لا توقف عن التقدم والتطور نظرية ومنهجاً. وتزداد هذه العلاقة أهمية بالنسبة للغة العربية التي تفرد بخصوصيات لسانية صورية جعلت منها، لغة قابلة للاستجابة لإجراءات الهندسة اللسانية في أغلب المستويات ذات الارتباط بالجانب الصوري وخاصة في باي الصرف والتركيب.

يتطلب العمل في هندسة اللغة العربية التمكن من نوعين متكاملين من المعرفة⁽¹⁾: المعرفة اللسانية العميقه وصفاً وتصنيفاً بمختلف جزئيات النظام اللغوي على ضوء أحدث النظريات اللسانية المعاصرة، وخاصة اللسانيات الصورية، والإمام بالمعرفة الحاسوبية ذات الصلة بمعالجة اللغات الطبيعية، وخاصة في جانبها البرمجي، وهو ما يعني التأقلم مع التفكير المنطقي الذي تقوم عليه الآلة. فالحاسوب منظومة برمجية منطقية قوامها الخوارزميات الصارمة التي لا تشغله الظن أو بالنسبة، ولذلك فإن القواعد التي يجب أن تصاغ لهذه الغاية يجب أن تكون صورية وحاسمة لا تقبل أكثر من تأويل واحد لكل قضية.

إن الجمع بين هذين النوعين من المعرفة هو المثلث في التقدم الذي يحقق مجال البحث في الهندسة اللسانية، ولطالما تجاهل واضعو البرامج الحاسوبية الجانب المعرفي اللساني مكتفين بالمعرفة الحاسوبية، وهو ما أدى إلى تطوير برامج عربية يمكن أن نقول عنها إنما ما تزال في بداية الطريق، الأمر الذي انعكس سلباً على صناعة البرمجيات العربية فآخرها مقارنة بالتقدم الذي حصل في البرمجيات الأجنبية، كما أدى إلى تأخير الحوار بين الإنسان العربي بلغته العربية والآلة، هذه الآلة التي أصبحت تفرض نفسها علينا في جميع المجالات.

لقد أنفقنا زمناً طويلاً في البحث في المعالجة الآلية للغة العربية من أجل الرقي بها إلى مصاف اللغات العالمية الفاعلة في التقانة المعاصرة، وكان تركيزنا واقعاً في البداية على المستوى التركيبي، ولم نع سبب تأخرنا في تنفيذ مشروعنا إلا في السنوات العشر الأخيرة، أي عندما واجهتنا صعوبات كبيرة مصدرها أنها كانت قد بدأنا بالمركب، وكان يجب علينا البدء بالفرد من البيانات، ولذلك ترانا نعيد النظر في خطتنا الشاملة، فعدنا إلى الاهتمام بالمستوى الأصغر من التركيب، وهو المكون الصرفي، وبذلك تقدمنا خطوة إلى الأمام في عملنا. لقد ترسخت لدينا القناعة أن إهمال وصف المكونات الصرفية للغة العربية وصفاً حاسوبياً صورياً مقابل الوصف التقليدي الذي انتهى عمره الافتراضي علمياً هو السبب الرئيس في تأخر إنجاز المشروعات العلمية التي أنفقت عليها الملايين من الدولارات بدون طائل.

⁽¹⁾ انظر الملحق رقم (1)

المعاجم الإلكترونية:

يبي المعجم الآلي للغة العربية على وصف المفردات اللغوية من وجهة نظر تصريفها conjugaison واشتقاقها derivation مع ربط هذا الوصف بالمستوى السحوي أي بالمعجم التركيبي للغة العربية. وتحب الإشارة هنا إلى أن غرضنا من وضع هذا المعجم يتمثل أساساً في تقيس الدماغ البشري لسانياً في مستوى المعجم ، وذلك في محاولة منا استكناه الكفاية المعجمية عند الفرد العربي وتقعيد إنتاجية هذا المستوى معلوماتياً و / أو خوارزمياً . وهذا فإن بناء هذا المعجم يدخل بشكل أساسى في ما أصبح يعرف اليوم باللسانات الحاسوبية العربية .

يتتألف المعجم الآلي للغة العربية من ثلاثة مستويات متكاملة : الأول وهو مستوى الجذور، وفيه يصاحب كل جذر بالمعلومات النحوية والمorfولوجية التي تستخرج منه، المستوى الثاني يتتألف من معجم المفردات البسيطة، حيث أثبتت كل مفردة في قاعدة البيانات بناء على المعلومات النحوية والصرفية المتعلقة بكل واحدة منها . ويترفرع عن هذه القاعدة من المفردات البسيطة قاعدة أخرى تتألف من المفردات العربية. أما المستوى الثالث فيتأسس على قاعدة بيانات من المفردات المركبة. وهي بدورها تتفرع إلى مفردات مركبة تشمل العادي منها والمسكون، ومفردات مركبة معربة. يمثل هذا العمل القسم الأول من قاعدة البيانات التي أخزنناها. وهناك قاعدة بيانات أخرى تتعلق بالمعجم التركيبي الآلي للغة العربية. وسيتم الربط بين القاعدتين ببرنامج يسمح بمساءلتها للقيام بالمعالجة الآلية في المستويين معاً، وأهدف هو جعل الآلة تقوم بتركيب نصوص عربية سلية، وتعرف الجمل العربية السليم منها وغيره، والقيام بمراجعة الأخطاء الإملائية والتركيبية في النصوص العربية، وتعرف الجذور اللغوية وتقييم الزائد من الأصيل في المفردات العربية، وتوليد واشتقاق المفردات صرفيًا وتركيبيًا، الخ .

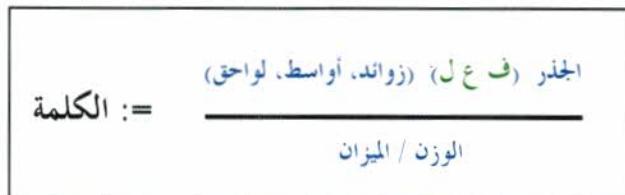
فكيف تم الربط بين مجال الهندسة واللغة ؟

الهندسة فن التحكم في النظم، والخالق بشقيه العادي والبرمجي يقوم على هذا التحكم، واللغة نظام معقد متشعب المسالك: صوتا وصواتة phonology وصرفًا وتركيبيا ومعجماً ودلالة وتدالوا pragmatics .

لقد استطاع الباحثون في لغات غربية كثيرة وضع برامج حاسوبية لسانية طبقت فيها جميع الخوارزميات الصورية التي تعرفها الآلة، وهناك برامج كثيرة تحمل الحوار بين الإنسان الغربي والآلة ميسراً بلغته الطبيعية، ذكر منها: الترجمة الآلية والتوليف الصوتي والتعرف البصري على المحرف والمدقن النحواني والإملائي ... الخ. إلا أن التطبيق على اللغة العربية ما يزال في بداية الطريق، هذا على الرغم من أن هذه اللغة لا تختلف عن أي لغة في العالم فيما يتعلق ببرنامج الكفاية اللسانية، وما تتميز به اللغة العربية عن غيرها يجب أن يدفع بها إلى مقدمة اللغات العالمية في التعامل مع الآلة، فهي تقوم على مكونين رياضيين هما **الجذر والوزن**، وهما معاً غير موجودين في أغلب لغات العالم.

- يعد الجذر المكون النموي للكلمة، أما الوزن فيتمثل هيكلها العام، يقوم الوزن بتوزيع الحركات على مختلف حروف الجذر كما يقوم بتوزيع المورفيمات التي تضاف إلى مكونات الجذر بغرض توليد الكلمات: (سوابق ولوائح وأواسط)، يقوم هذا التوزيع على قوانين صورية تجمع في عملها بين القوانين اللسانية والرياضية.

- هذا التشكيل الرياضي للغة العربية جعل منها لغة انصهارية Fusion، خلافاً للغات الأخرى التي تعدد لغات الصاقية Ensembliste فيما يتعلق بتوزيع المورفيمات داخل بنية الكلمة الأساسية. والقول بالانصهارية يؤدي حتماً إلى القول بالطبيعة الجبرية Algebra للغة العربية.
- أما الصواتات التي تعادل Voyelles في اللغات اللاتينية فتوزعها مفنن بواسطة خوارزميات التطابق بين الوزن والكلمة المنتجة، لذلك لا نضعها - نحن العرب - على الكلمات، لكننا نستطيع قراءتها بدون صعوبة، لأننا نقرأ لغتنا ونتكلّمها بالأوزان وليس بالحركات، والمقصود هنا بالحركات تلك العلامات التي يتولى الخلل الصريفي الطبيعي توزيعها على الحرفين الأول والثاني من الكلمة في حالة الجذر الثلاثي، والحرف الثالثة الأولى في حالة الجذر الرباعي، أما حركة لام الكلمة فيستند توزيعها للمحلل النحوي الذي يتعامل مع اللغة بوصفها منظومة من الوظائف الصورية التي لها نظامها الخاص بها.
هكذا يبدو أن اللغة العربية لغة رياضية في أساسها مكونة من منظومة من الخوارزميات الصورية، دخلها الجذور مروراً بالأوزان التي تتمتع بقوّة الإصهار المورفيمي المبرمج وخرجها output الكلمات والجمل، وهي كما يلي:



- تنتج الكلمة في العربية عن التفاعل بين الجذر بوصفه مكوناً متغيراً، من حيث إنه منظومة من الواقع الصوتية (الصواتية) كل صوت فيه يوجد في توزيع تكاملي مع منظومة الأصوات العربية المحدودة العدد والصفات والمخارج، والوزن (أو الميزان) بوصفه مكوناً ثابتاً، من حيث إنه يمثل البنية النظرية للكلمة، ثلاثية أو رباعية. وقيل ثنائية (بوهاس)، كما أن الوزن يمثل البنية العميقية للكلمة، أما الميزان فيمثل بنيتها السطحية (2).
- يمثل **الجذر** دخل البرنامج اللغوي في كفاية المتكلم، في البداية يتم اختيار الجذر المراد تشغيله، (ثلاثي أو رباعي)، ثم تشرع الكفاية في تطبيق خوارزميات المطابقة بين مادة الجذر اللغوي (المتغير) والمادة الصورية (ف.ع.ل.) (الثابت)، وفي مرحلة لاحقة يتم تفعيل الوزن/الميزان عن طريق خوارزميات الإقحام التي تقوم بإدراج الزوائد (سوابق ولوائح وأواسط وحركات) في البنية النظرية للجذر بهدف توليد الكلمة، أما في مرحلة التحليل فإن العملية تكون معكوسة، إذ يتم تطبيق نوع آخر من الخوارزميات تتولى إرجاع الكلمة إلى بنيتها الأساسية، أي الجذر.

² لمعرفة معانٍ هذه المصطلحات العلمية ينظر موقعنا على الإنترنت: www.ajman.ac.ae/hannach

- يشمل المخطط السابق مبني الكلمة من جهتين: البساطة (الكلمة في المفرد المذكر أو المؤنث)، والإعراب (والمقصود به تصريف الكلمة في الثنوية والجمع بجميع أنواعه)، كما يشمل توليد الكلمات ذات الاشتغال الميت دلالياً (المهمل)
- لكل صيغة صرفية مقابل دلالي مخزن في الكفاية، وهذا المكون الدلالي الصريفي هو الذي يضمن ربط المستوى الصريفي بالمعجم والدلالة، وتؤمن ظاهرة الانصهار التي تفرد بها اللغة العربية حرية حركة الكلمات داخل الجملة، أما علاقة الصرف بالمستوى الصوافي Phonologique فلا تحتاج إلى دليل، وخاصة فيما يتعلق بالأصول المعتملة. ونظراً لارتباط كل صيغة صرفية بدلالة محددة تتنظم على شكل حقول دلالية فقد أخذ الصرف نصرياً وافراً من باب الدلالة، مثل ذلك من المصادر العربية:

الجذر	وزن الفعل	المصدر الأصلي	وزنه	الهيئة	المرأة	الميم	الصناعي
ذَأْبٌ	يَفْعُلُ	ذَآبَا	فَعْلَةٌ	فَعْلَةٌ	فَعْلَةٌ	مَفْعُلٌ	+يَةٌ

من خلال معرفتنا بدلالة الوزن نستطيع ربطه بما يمكن أن يولده من المداخل المعجمية، فلا أحد يخوض في أن وزن "فَعْلَةٌ" يدل على وقوع الحدث مرة واحدة، مثل: "عظة" التي تدل على الوعظ مرة واحدة لا غير. كما نعرف أن "فَعْلَةٌ" يدل على وقوع الحدث على شكل هيئة معينة، مثل: قَعْدَة، أو جَلْسَة، إلخ. وهذا يدل على أن المكون الصريفي يعد مرشداً إلى الدلالة، إذ يكفي وضع الكلمة في وزنها الصحيح لنجاً منها إلى معناها الذي تدل عليه، وبذلك يكون الصرف محور العمليات اللسانية الحاسوبية الذي تبني عليه مستلميات أخرى كثيرة في منظومة التحليل الآلي للغة العربية.

أما في مجال تركيب الجمل فإننا ننظر إلى الفعل بوصفه دالة Fonction، وبقية العناصر فمتغيرات، وذلك كما يلي:

$$P \rightarrow V(n_1, n_2 \dots n_x)$$

وعلى الرغم من قلة عدد الأوزان الفعلية المولدة للأفعال في نظام اللغة العربية، حيث لا تتجاوز **60** وزناً أصلياً، فإنها تعد الأكثـر إنتاجـية مقارنة بـقـية الأصنـاف الصـرـفـية الأخرـى في النـظام اللـغـوي العـرـبـي، وهذا يـؤـدي إـلـى استـخـلاـص نـتيـجة لـسـانـية حـاسـوبـية تـمـثلـ في القـوـل: كـلـما قـلـ عـدـ أـوزـانـ الصـنـفـ اللـغـويـ كـلـما كـانـ أـكـثـرـ إـنـتـاجـيـةـ وـذـلـكـ كـماـ يـلـيـ:

مصدر = كتابة	اسم الفاعل = كاتب	اسم المفعول = مكتوب	مبالغة = كتاب	تفصيل = أكتب	الباب الفعلي: فعل - يفعل = كتب - يكتب

فالمصادر بأصنافها الخمسة: الأصلي، والميم، والهيئة، والمرأة، والصناعي، وكذلك جميع أصناف المشتقات، وعددها ثمانية، كلها تخضع لخوارزميات توليد الأفعال، قبل أن يطبق عليها قنونها التوليدية الخاصة، مما يجعل من هذين القسمين (المصادر والمشتقات) أصنافاً صغرى S/classes تخضع لسانياً وحاسوبياً لقوانين توليد الأفعال. وقد بني المعجم الإلكتروني لتركيب اللغة العربية على هذا الأساس.

- ونظرا للطبيعة الجبرية algebra لنظام اللغة العربية المتمثلة في منظومة الخوارزميات اللسانية التي تجمع بين مختلف مكونات النظام، فإن الرابط بين هذه المستويات أمر بالغ التعقيد لا يمكن أن تقوم به الآلة إلا إذا تم تزويدها بالقواعد اللسانية الصورية، أي بالخوارزميات اللغوية، بنوعيها التوليد والتحليل..
- إذا قارنا هذا العمل بمكونات الآلة نجد بينهما تشابها كبيرا في خطوات العمل وفي طبيعة النتائج التي يتوصل إليها البحث في كلا المجالين، وهي تسير وفق ما يلي:

بيانات مشفرة ← ترجمة الخوارزميات ← اللغة الطبيعية

تشمل الخطوة الأولى لغة صورية (=: الجذر) تتبع تركيبا معينا في بناء الموضوع، وفي الخطوة الثانية يتم ترجمة خوارزميات البرمجة إلى مقدمة لبناء النص باللغة الطبيعية (=: الوزن)، ثم تأتي في المرحلة الثالثة اللغة الطبيعية (=: الكلمة) التي تعد النتيجة التي يتم من خلالها التأكد من صحة البرنامج من عدمه.

التطبيق:

يقوم تصورنا للعمل في المكون الصرفي على أن الكلمة تولد بإضافة الزوائد والحركات (الثوابت Constant) بشكل انصهاري إلى الجذر (المتغير Variable)، أما الوزن فيعد الهيكل الذي تستظم فيه الثوابت والمتغيرات، ويتم ذلك بوجوب تفعيل ثلاثة أنواع من الخوارزميات ⁽³⁾:

أولا: خوارزميات المطابقة، وتقوم بالمقابلة بين المكون الصوتي (الجذر) وأحد الهياكل الصرفية التي تجمع في (ف ع ل) أو (ف ع ل ل) استعدادا لإدراج الزوائد والحركات في بنية الصرفية حسب ما تسمح به القوانين الصواتية phonological rules للجذر root، ويتم ذلك وفق نظام تطريزي prosodic محكم توظف فيه كافة الخوارزميات الصورية التي تراعي التكوين الداخلي للجذر، تقوم هذه الخوارزميات بمهمة الاستبدال والمطابقة بين الجذر بوصفه متغيرا، ومكونات الوزن بوصفه ثابتة، وذلك وفق مقتضيات المحتوى الصوتي والصواني للجذر، مثال ذلك ⁽⁴⁾:

الخرج =: الكلمة	خوارزميات المطابقة	الدخل =: الجذر
كتب	/ك/ =: ف، /ث/ =: ع، /ب/ =: ل	كت ب

ثانيا: خوارزميات الاشتغال، وتتولى توزيع الحركات والزوائد (سوابق ولواحق وأواسط) داخل الهيكل الصوتي (الجذر الثلاثي أو الرباعي) باستخدام الهيكل الصرفي (ف ع ل (ل)), وتم عملية التوزيع وفق مبادئ

³ اللغة العربية والتقنيات العلمانية المتقدمة، د/ محمد الحناش، 1996

⁴) Traitement automatique du mot: Etat de l'art, Eric Laporte, IGM, 2001

الانصهار التي تغير النظام الصرفي للغة العربية عن غيره من أنظمة العديد من اللغات وخاصة اللغات الأوروبية⁵.

وقد تبين لنا أن توليد أقسام الكلم الأساسية من الجذر تقوم على منظومات من الخوارزميات تراعي التعدد المقولي للغة، فلكل مقولة خوبية مولدة من الهيكل الصوتي (الجذر) منظومتها الخوارزمية الخاصة بها، مع اتفاق في بنية الهيكل الصرفي الأساسية.

فللأسماء البسيطة خوارزمياتها الخاصة بها التي تولدتها من الجذر، ولالأفعال البسيطة خوارزميات أخرى خاصة بها. تميز خوارزميات أسماء الذوات بكونها تولد بنيات اسمية مغلقة، حيث لا تتفرع عنها إلا بعض البناءات الاسمية الداخلية التي تعد من صميم التكوين الإعرابي للاسم، بينما تميز خوارزميات الأفعال بالافتتاح على نفسها أولاً (أزمنة الأفعال وتصريفها مع مختلف الضمائر)، ثم على بنيات أخرى متعلقة بها اشتتاقياً، والمقصود بها المصادر والمشتقات بجميع أنواعها.

ثالثاً: خوارزميات التوليد، والمقصود بها العمليات الصورية التي تولد البناءات المُعَرَّبة، والمقصود بالإعراب هنا مختلف التغيرات الاشتتاقيّة التي تعرفها الكلمة داخل مجدها التصريفي، فالاسم يتفرع إلى مفرد ومشيّ وجمع تكسير (قلة وكثرة)، وتعريف وتنكير وتضييف ونسب، ... إلخ، ولكل مقوله فرعية نظامها الخاص بها فيما يخص توزيع الزوائد والخرارات بشكل انصهاري. أما الفعل فيعد أكثر إنتاجية من حيث التصريف، إذ تتفرع عنه مجموعة من البناءات التصريفية يكون أغلبها على مستوى الزمن، وقد ضاعف وجود الزمن في الفعل من تعقيد مهمة الخوارزميات، فيه الفعل المضارع والماضي والأمر، ولكل منها نظامه الاشتتاقي الخاص به، كما أن لكل منها جدولًا خاصًا يتوزع فيه الفعل مع مختلف الضمائر. أما اشتتاقي المصادر والمشتقات فتعد أعباء إضافية يتحملها الفعل الذي يفتح الطريق أمام توليدها، إذ بدون الفعل لن نتمكن من الوصول إليها بحال وفق فرضيتنا العلمية التي نشتغل بها⁶.

بناء على هذه الفرضية:

يمكن القول إن الوزن والميزان يمثلان أحد تجليات النظام الخوارزمي في شقيه الاشتتاقي والتوليدي، فالوزن يوصفه الهيكل الصرفي الذي يخطط لبناء الكلمة قبل أن تخرج إلى الوجود بعد ادخال الحقيقي لبناء المفردات، وبدونه لا يمكن أن نصل إلى المفردة أبداً، وهذا حرصنا على تحويل أغلب البيانات بالأوزان في قاعدة البيانات التي سنتحدث عنها لاحقاً.

الوزن هو العمدة في بناء الكلمات، فهو الحامل لمادة الجذر وفيه تنصهر الصوات القصيرة والطويلة مع مكونات الجذر الصامتة، وهو الذي يسمح بتطبيق جميع القوانين الصواتية للغة العربية، وهو الذي يسمح لنا أيضًا

⁵ Les bases de données du LADL, Analyse automatique des langues naturelles, Aspects technologiques, Paris, 1989

⁶ تختلف نظرية الاشتتاقي التي نعمل بها عن نظرية القدماء في الموضوع نفسه.

بكتابه اللغة العربية وقراءتها وهي بدون حركات. نخلص من هذا إلى أننا نكتب اللغة العربية ونقرأها بالأوزان، نكتفي بكتابه الصوامت مع الصوانت الطويلة، ولكننا نقرأ الكلمة بصوامتها وصواتها (بنوعيها)، فلما تختفي الصوانت القصيرة إذن في كتابتنا العربية؟، وما الذي يجعلنا نلحظها بالصوامت؟ إنه الوزن، والوزن فقط، وهذا الأخير يقوم على منظومة من الخوارزميات التي تسمح له بالتعامل مع الهيكل الصوتي، أي الجذر. أما من حيث الدلاللة فإن الوزن وحده يحمل دلاللة صرفية تعدد لوحدها بمثابة القالب العام الذي تفرغ فيه الدلاللة المعجمية. ويتم ذلك على مراحل كما في هذا المثال:

1) الجذر (ثلاثي) = ك ت ب (الفراغات الموجودة بين الحروف الأصلية لإدخال الحركات القصيرة والطويلة)

2) الوزن (المصدر) = ف ع ال (الفراغات مخصصة لحركات الوزن المعروفة سلفا)

3) تطبيق الوزن على الجذر = ك ت ب ة : كتابة

لا يمكن الوصول إلى الخرج (كتابة) إلا عبر المراحل الثلاث الأولى التي تسقى الخرج، وبذوهما يستحصل على أي متكلم عربي أن يصل إلى هذه النتيجة في اللغة العربية بشكل صحيح.

وقد احتجنا في هذه العملية البسيطة إلى البرامج الطبيعية التالية:

1. منظومة من القواعد الفونولوجية التي تسمح بتأليف الصوامت مع بعضها في بنية الجذر، وبدونه لا يمكن أن يستقيم الدخول ويسمح بإدراجه في المنظومة اللسانية العربية.

2. مولد صرفي طبيعي للكلمات يربط بين الجذر وتوجه التوليد Orientation de generation (هنا المصدر الأصلي)، وهو مختلف عن أنواع أخرى من المصادر العربية: الميمي، الصناعي، المرة، والهيئية.

3. مشكل طبيعي يضع الحركات المناسبة على الصوامت التي تتالف منها المتواالية اللسانية (الكلمة = المصدر).

4. محلل دلالي يسمح بالتأكد من المحتوى الخبري للخرج.

فإذا انتقلنا من الكفاية الطبيعية إلى الكفاية الحاسوبية المراد نسخها على الحاسوب، سنرى أن الأمور تعقد أكثر، لأننا سنكون في حاجة إلى الانتهاء أولاً من الأمور الآتية:

1. بناء قاعدة بيانات الجذور العربية التي تقبل أن تكون دخالات لتوليد المصادر العربية الصحيحة، أي بناء معجم إلكتروني يحتوي على جميع الجذور المستعملة في اللغة العربية وتشفيتها بشكل صحيح، وهو ما يمكن أن يترجم بمصطلح الاستقراء التام، درءاً للوقوع في الأخطاء التي يؤدي إليها أسلوب الاستدلال القائم على منطق الفرضيات والاحتمالات.

2. ربط كل جذر بشبكة الأفعال التي تولد عنه، لأن الفعل يعد دخالاً سابقاً لكل مصدر، وما ذلك إلا للانضباطية التي يتميز بها الفعل، فلكل فعل مصدر (تستثنى الأفعال الجامدة وبعض الأفعال الناقصة).

3. بناء قاعدة بيانات الأوزان والموازنين الصرفية التي تولد بها المصادر في اللغة العربية، وهو ما يمكن أن يترجم بالمولد الصرفي العربي الخاص بالمصادر.

4. ضبط منظومة القواعد الصواتية التي تحكم في الصوامت المعتلة (ا و ي) عند الانتقال من مرحلة توليد الفعل إلى مرحلة توليد المصدر.

5. تطوير مشكل آلي يتولى توزيع الحركات المناسبة على الصوامت داخل الوزن، وهذا قد يكون ميسراً نظراً لأن الوزن نفسه يتضمن الحركات.

ومن الجدير بالذكر أن الوزن في اللغة العربية يعد الحجر الأساس في تطوير أي برنامج للتشكيل الآلي للنصوص، لأن تشكيل الكلمة يخضع لتعريف بيتهما الداخلية التي تنتج عن معرفة الوزن الصرفي، إلا أن دور الوزن لا يتتجاوز تشكيل الصوامت الأولى للوزن، لأنه لا يتحكم في الحركة الأخيرة، فهذه من اختصاص المولد التحوي، ولا أظن أننا سنطلب في المرحلة الأولى من أي برنامج صرفي، سواء كان مولداً أو محللاً، أن يهتم بالحركة الأخيرة، وهذا السبب ترانا أهميتها في المثال الذي قدمناه سابقاً.

تجدر الإشارة إلى أن الوزن الصرفي يشكل العمود الفقري البرامج الحاسوبية التالية:

1. التشكيل الآلي للنصوص، سواء كان تماماً أو ناقصاً.

2. التعرف البصري على الأحرف العربية، إذ لا يعقل أن يستغل برنامج OCR خارج نطاق الصرف

3. الترجمة الآلية، إذ بدون ضبط الوزن لا يمكن أن تقوم أي ترجمة آلية

4. برامج النطق الآلي للنصوص، بدون معرفة الوزن يتذرع تطوير برامج التوليف الصوتي وتحليل الكلام.

وغيرها من البرامج المتعلقة بمعالجة اللغات الطبيعية في عصر تقانة المعلومات.

قسمت قاعدة بيانات المصادر إلى مكونين لغوين أساسيين:

الأول: البيانات المشتركة التي تمثل دخل المعجم، أي الأدوات الأساسية التي نظمت على شكل معاجم فرعية:

- معجم الجذور (الوحدات الذرية) والأفعال التي تعد المرحلة الوسيطة في توليد المصادر بجميع أصنافها.

- معجم الأوزان (الخوارزميات) التي تولد المصادر عن طريقها، إذ إن الكلمة التي ليس لها وزن تصنف خارج بنية النظام الصرفي العربي، وتكون إما معربة أو دخيلة.

الثاني الحصيلة اللغوية التي توصلنا إليها، التي تشكل العداد اللساني الذي نشير إليه عادة بمصطلح قاعدة البيانات اللغوية، ومجموعها 2.50.000 مدخل مصدر موصوف ومشفر ومصنف فيخمسة أصناف صغرى.

يلخص الشكل (2) مختلف المراحل التي يمر بها اشتغال المفردات العربية مع إحصاء يكاد يكون دقيقاً لمختلف المداخل المعجمية المولدة بمن الدين النوعين من الخوارزميات، كما يبين العلاقة الاشتراكية والترابطات المشتبعة بين المدخل (7):

Dictionnaires électroniques et analyse automatique de textes, Max Silberstein, Masson, Paris, 1993)⁷

طريقة بناء قاعدة البيانات

صممت قاعدة البيانات بطريقة تسمح للمبرمجين بقراءتها بشكل ميسر، فقد وضعت على شكل جداول يمكن قراءتها بأي برنامج متخصص في قواعد البيانات، مثل Excel أو Access. وتقوم على أعمدة وصفوف، بحيث تضبط المعلومة المطلوبة عند نقطة الالقاء بينهما. أما عدد الأعمدة فهو كما يلي:

- 1 حقل الجذر التي تتفرع عنها الأفعال والمصادر (مثبتة معجميا).
- 2 حقل وزن الفعل (فعل - يفعل) الذي يشتق منه المصدر.
- 3 حقل المصدر الأصلي (مثبت معجميا).
- 4 حقل وزن المصدر الأصلي.
- 5 حقل وزن مصدر الهيئة.
- 6 حقل وزن مصدر المرة.
- 7 حقل وزن المصدر الميمي.
- 8 حقل وزن المصدر الصناعي.

لقد ركزنا في جمع البيانات وتصنيفها على الجانب الصوري دون الجانب الصوتي المفعول معجميا، ولم نثبت معجميا في قاعدة البيانات إلا الجذر والمصدر الأصلي موضوع هذا البحث، أما بقية الاشتراكات التي تم من الجذر فقد أكفيت بإثبات أوزانها يقيناً أن الوزن هو العمدة التي تبني عليها البيانات اللغوية في جميع المراحل الحاسوبية اللاحقة. ونظراً لأهمية التشكيل في بناء قاعدة البيانات فقد ضبطنا جميع المواد التي تشكل من المعجم الإلكتروني للمصادر العربية، وذلك خمساً لإمكانية استغلاله في تطوير برامج الترجمة الآلية والاتصال الصوتي بين الإنسان والآلة، وبرامج القراءة الآلية للنصوص العربية، إلخ.

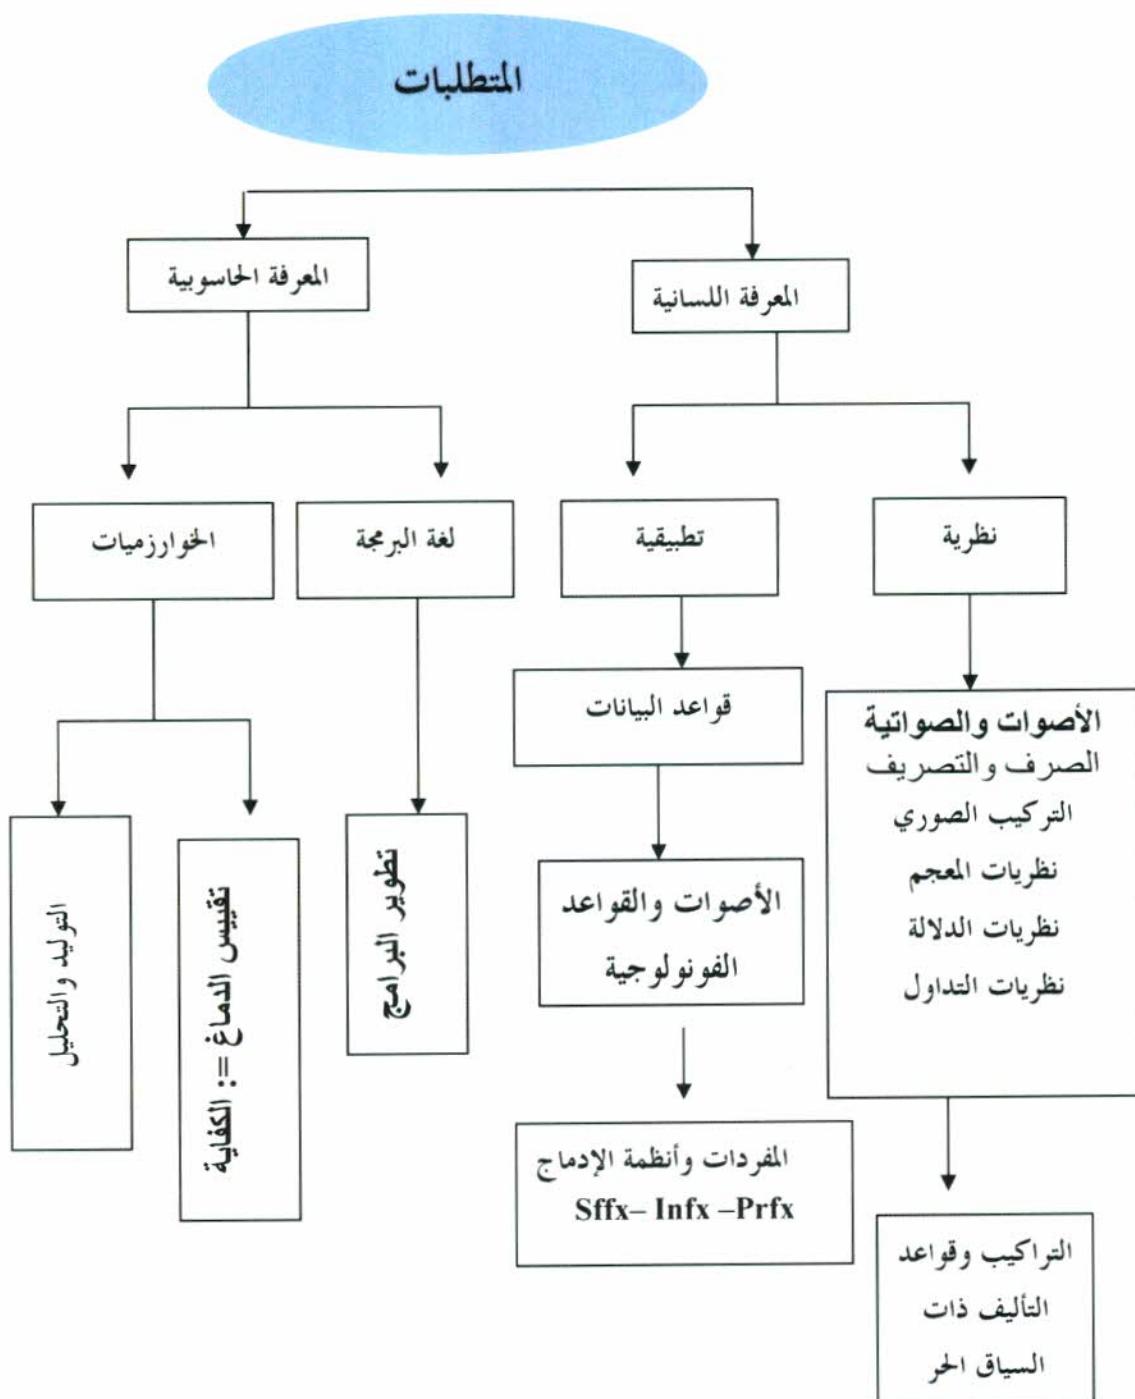
خلاصة:

لقد تبين لنا من خلال هذا العرض السريع لبني الكلمة العربية أن الوزن الصوري يعد العمدة في بيئتها اللسانية، كما تبين لنا أن معرفة الوزن آلياً تحتاج إلى ضبط عدد من المكونات اللسانية التي تنضبط في قواعد مطردة على شكل خوارزميات صورية تتولى توليد الكلمة في المعجم. كما تبين لنا أن سبب إيماناً للحركات في الكتابة هو كوننا نقرأ العربية صرفاً، إذ يمرد أن تقع أعيننا على الكلمة نرسلها إلى المدخل الصوري الطبيعي الذي يتولى وضعها في صيغتها الصحفية المناسبة، وبذلك يتم تعرّفها آلياً وقراءتها بشكل سليم، بعد أن نسند إليها المحتوى الخبري الذي يناسبها.

كما عرفنا أن أي برنامج حاسوبي يتعامل مع اللغة العربية بوصفها لغة طبيعية لا يمكن أن ينجح إلا إذا فهم آلية بناء الكلمات صرفيًا، ومن هنا كان المكون الصوري عمدة في معظم البرمجيات العربية الناجحة، منها الترجمة الآلية، والتعرف البصري على المحرف، والنطق الآلي للنصوص، والاتصال الآلي بين أنظمة الإرسال المتقدمة، والاتصال بين البشر والآلة. كما طبقنا هذا المفهوم على المصادر العربية، وقد تبين أن هذا المكون الصوري في اللغة العربية يعتمد كلّياً على خوارزميات صورية تولده من الأفعال، ولذلك قمنا بربط كل مصدر بالفعل الذي يشتق منه تيسيراً لعملية الحوسنة التي نعتمدها في مشروع فيها مستقبلاً.

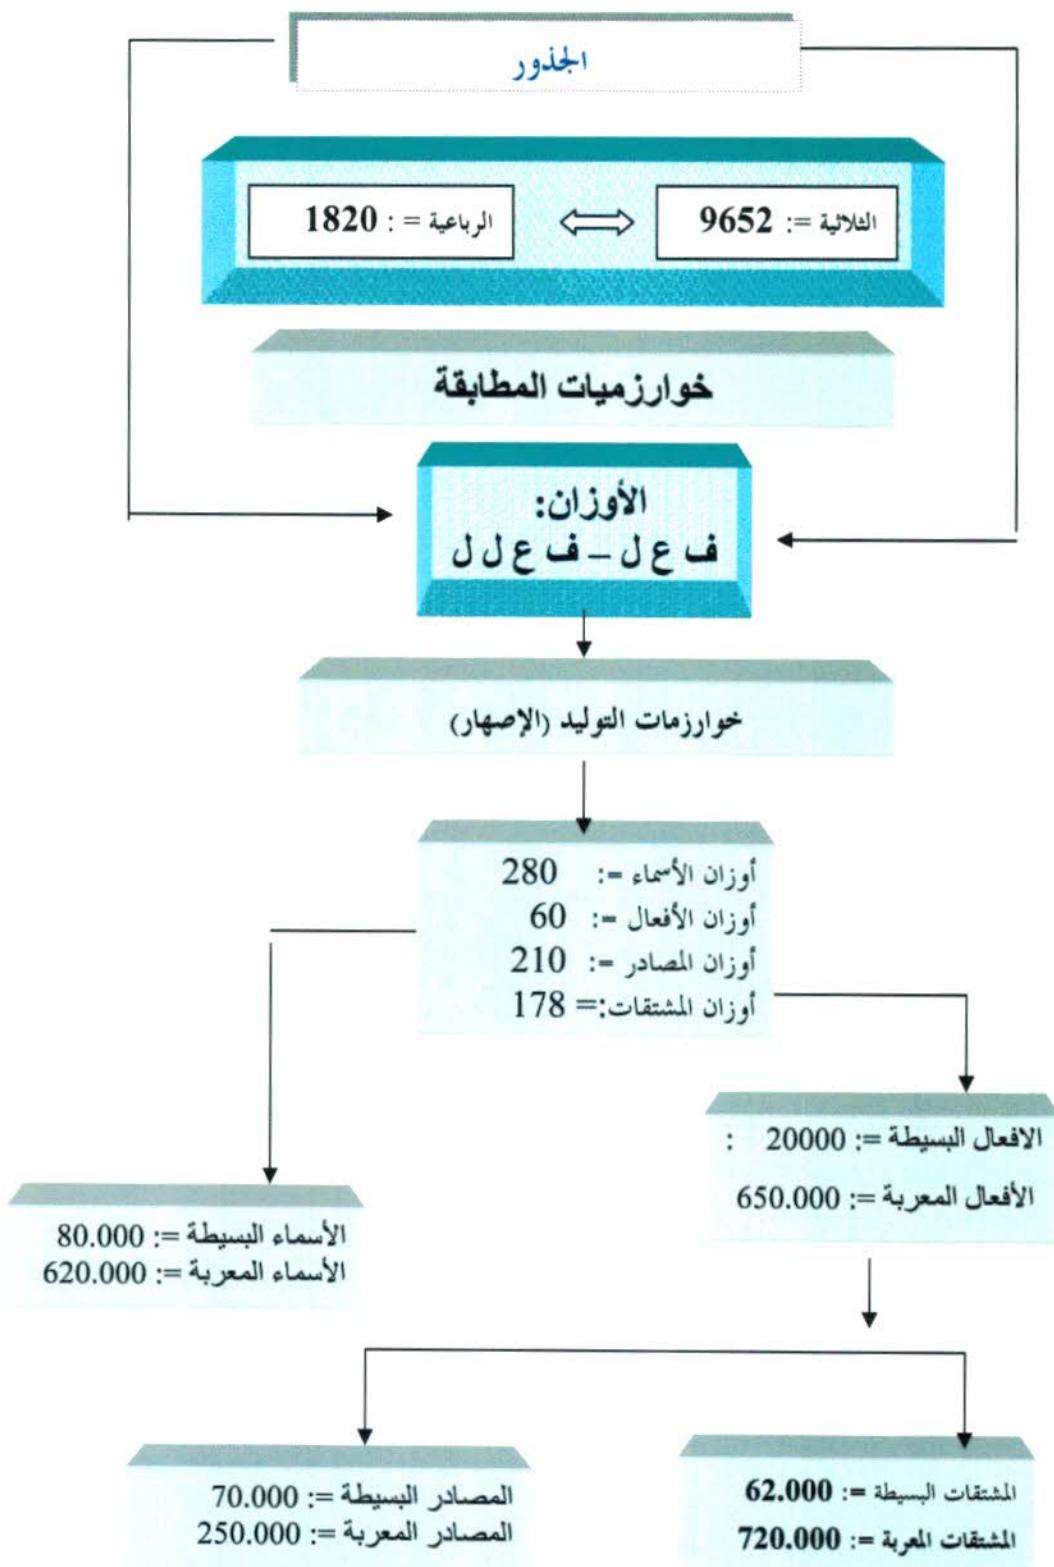
ملحق (١)

متطلبات بناء المعجم الإلكتروني للغة العربية



ملحق (2)

إحصائيات التوليد الصرف في العربية



ملحق (3): ثوذج قاعدة بيانات المصادر العربية:

الصناعي	الميمي	المزة	المينة	وزنه	المصدر الأصلي	وزن الفعل	الجذر
+ية	مُفْعَل	فُعْلَة	فُعْلَة	فعل	ذَابَا	فعل - يُفْعَل	ذَاب
+ية	مُفْعَل	فُعْلَة	فُعْلَة	فعل	ذَابَا	فعل - يُفْعَل	
+ية	مُفْعَل	فُعْلَة	فُعْلَة	فعالة	ذَآبَة	فعل - يُفْعَل	
+ية	مُفْعَل	ة+	-	إِفْعَال	إِذَابَا	أَفْعَل	
+ية	مُفْعَل	ة+	-	تَفْعِيل	تَدْبِيَا	فَعَل	
+ية	مُتَفَعِّل	ة+	-	تَفْعُل	تَذَوِّبَا	تَفَعَل	
+ية	مُتَفَاعِل	ة+	-	تَفَاعُل	تَذَاوِبَا	تَفَاعَل	
+ية	مُسْتَفْعِل	ة+	-	اسْتَفْعَال	اسْتَدْبَابَا	اسْتَفْعَل	
+ية	مُفْعَل	فُعْلَة	فُعْلَة	فعل	ذَاتَا	فعل - يُفْعَل	ذَات
+ية	مُفْعَل	فُعْلَة	فُعْلَة	فعل	ذَاجَا	فعل - يُفْعَل	ذَاج
+ية	مُفْعَل	فُعْلَة	فُعْلَة	فعل	ذَاجَا	فعل - يُفْعَل	
+ية	مُتَفَعِّل	ة+	-	الْفَعَال	الْذَنَاجَا	الْفَعَل	
+ية	مُفْعَل	فُعْلَة	فُعْلَة	فعل	ذَاحَا	فعل - يُفْعَل	ذَاح
+ية	مُفْعَل	واحدة	-	فُعْلَة	ذَادَة	فَعَل	ذَادَا
+ية	مُتَفَعِّل	ة+	-	تَفَعُل	تَذَادُرَا	تَفَعَل	
+ية	مُفْعَل	فُعْلَة	فُعْلَة	فعل	ذَارَا	فعل - يُفْعَل	ذَار
+ية	مُفْعَل	فُعْلَة	فُعْلَة	فعل	ذَارَا	فعل - يُفْعَل	
+ية	مُفْعَل	ة+	-	إِفْعَال	إِذَارَا	أَفْعَل	
+ية	مُفَاعِل	واحدة	-	مُفَاعَلَة	مُذَآرَة	فَاعَل	
+ية	مُفْعَل	فُعْلَة	فُعْلَة	فعل	ذَاطَا	فعل - يُفْعَل	ذَاط
+ية	مُفْعَل	فُعْلَة	فُعْلَة	فعل - فَعَل - فَعَلَان - فَعَال	ذَافَا - ذَافَا - ذَافَانَا - ذَفَافَا	فعل - يُفْعَل	ذَاف
+ية	مُفْعَل	ة+	-	إِفْعَال	إِذَافَا	أَفْعَل	
+ية	مُتَفَعِّل	ة+	-	الْفَعَال	الْذَنَافَا	الْفَعَل	

ملحق (4)
فوذج تردد أوزان المصدر في اللغة العربية Frequency of the source weight in Arabic

وزن المصدر	مجموع المصادر الأصلية المولدة	النسبة المئوية
فعل	5976	17.997
فعل	3381	10.182
إفعال	1817	5.472
فعول	1738	5.234
تَفْعِيل	1664	5.011
تَفْعُل	1533	4.616
افتعال	1149	3.460
فعلة	965	2.906
فعالة	916	2.758
مُفاعلة	818	2.463
ثفاغل	673	2.026
فعيل	660	1.987
فعال	656	1.975
فعولة	582	1.752
فعال	579	1.743
استفعال	533	1.605
أفعال	408	1.228
فعلان	357	1.075
فعلة	317	0.954
فعال	299	0.900
فعالة	274	0.825
فعلة	273	0.822
المجموع	33205	100

مصادر البحث ومراجعه:

- اللغة العربية والتقنيات المعلوماتية المتقدمة، د/ محمد الحناش، 1996
- اللغة العربية والحواسوب: الهندسة اللسانية العربية، مجلة أقرأ، العدد السادس، الشارقة، 2004
- Traitement automatique du mot: Etat de l'art, Eric Laporte, IGM, 2001
- Les bases de données du LADL, Analyse automatique des langues naturelles, Aspects technologiques, Paris, 1989
- Dictionnaires électroniques et analyse automatique de textes, Max Silberstein, Masson, Paris, 1993