




الإحصاء وتقنيات الذكاء الاصطناعي للبيانات اللغوية مُدَوَّنَةُ الْقُرْآنِ الْكَرِيمِ أَنْمُودَجًا



سلطان بن ناصر المجبول



الإحصاء وتقنيات الذكاء الاصطناعي للبيانات اللغوية مُدَوَّنَةُ الْقُرْآنِ الْكَرِيمِ أَنْمُودَجًا

سلطان بن ناصر المجبول



الإحصاء وتقنيات الذكاء الاصطناعي
للبينات اللغوية - مدونة القرآن الكريم أنموذجاً

الطبعة الأولى

١٤٤٥ هـ ٢٠٢٤ م

البريد الإلكتروني: nashr@ksaa.gov.sa

ح / مجمع الملك سلمان العالمي للغة العربية، ١٤٤٥ هـ
المجبول ، أ.د. سلطان بن ناصر
الإحصاء وتقنيات الذكاء الاصطناعي للبيانات اللغوية - مدونة
القرآن الكريم أنموذجاً. / أ.د. سلطان بن ناصر المجبول. -
الرياض، ١٤٤٥ هـ


٢٩٤ ص؛ ١٧ × ٢٤ سم

رقم الإيداع: ١٥٩٩٩/١٤٤٥

ردمك: ٩٢-٩٣-٨٤١٣-٦٠٣-٩٧٨

لا يسمح بإعادة إصدار هذا الكتاب، أو نقله في أي شكل أو وسيلة، سواء أكانت إلكترونية أم يدوية، بما في ذلك جميع أنواع تصوير المستندات بالنسخ، أو التسجيل أو التخزين، أو أنظمة الاسترجاع، دون إذن خطي من المجمع بذلك.

هذه الطبعة إهداء من المجمع ولا يُسمح بنشرها ورقياً أو تداولها تجارياً





قائمة المحتويات

الموضوع	الصفحة
قائمة الجداول	١١
قائمة الأشكال	١٣
مقدمة المجمع	٢١
المقدمة	٢٣
الباب الأول: الإحصاء اللُّغويّ	٢٩
• التمهيد	٣١
أولاً: تعريف المُدَوَّنة اللُّغويّة	٣٣
ثانياً: أهميّة المَدَوَّنات اللُّغويّة	٣٥
■ أ. اللُّغويّات التَّطبيقيّة والتَّخْطِيط اللُّغويّ والسياسة	٣٦
■ ب. العلوم الإنسانيّة والاجتماعيّة	٣٧
■ ج. تطبيقات معالجة اللغة الطَّبيعيّة	٣٨
ثالثاً: مصادر المُدَوَّنة اللُّغويّة ومعايير الجمع	٣٩
رابعاً: أدوات معالجة المَدَوَّنات اللُّغويّة العربيّة	٤٠

الموضوع	الصفحة
• الفصل الأول: الإحصاءات وأنواع تمثيل البيانات	٤٣
المبحث الأول: البيانات اللغوية	٤٣
المبحث الثاني: التكرار والتوزيع والتنوع والكثافة	٤٨
المبحث الثالث: الإحصاءات الوصفية	٥٥
المبحث الرابع: الإحصاءات الاستدلالية	٦١
المبحث الخامس: أنواع الأشكال البيانية	٦٩
• الفصل الثاني: تحليل الخطاب	٨٧
المبحث الأول: التصاحب اللفظي	٨٩
■ أولاً: معاملات مقاييس التصاحب اللفظي	٨٩
■ ثانياً: شبكات التصاحب اللفظي	٩٧
المبحث الثاني: موافقة المقدّر البيئي	١٠٠
• الفصل الثالث: الارتباط والتجميع ومقارنة المجموعات	١٠٤
المبحث الأول: الارتباط	١٠٥
المبحث الثاني: التجميع	١١٤
المبحث الثالث: مقارنة المجموعات اللغوية	١٢٠
■ القسم الأول: الاختبارات البارامترية وغير البارامترية.	١٢٠
■ القسم الثاني: تحليل التناظر	١٢٤

الموضوع	الصفحة
• الفصل الرَّابِع: الانحدار	١٢٧
المبحث الأول: الانحدار الحطِّي	١٢٧
المبحث الثاني: الانحدار اللُّوجسْتِي	١٣٣
المبحث الثالث: التَّأثيرات الممتزجة	١٤٠
• الفصل الخامس: تحليلُ البَيَّانات اللُّغَوِيَّة التَّارِيخِيَّة	١٤٥
المبحث الأول: القمم والقعور	١٤٥
المبحث الثاني: التَّأرجُّح الاستِعمالي	١٥٠
المبحث الثالث: حوسبة المعجم	١٥٥
الباب الثَّانِي:	١٥٧
تنقيب النُّصوص والبَيَّانات العَرَبِيَّة	
• التَّمهيد	١٥٩
أولاً: معالجة اللغة الطَّبِيعِيَّة (المعالجة الأساسيَّة)	١٦٦
ثانياً: تطبيقات معالجة اللغة العَرَبِيَّة الطَّبِيعِيَّة	١٧٦
• الفصل الأول: تنقيب النُّصوص	١٧٩
المبحث الأول: إعداد البَيَّانات اللُّغَوِيَّة في جدولة بيانات	١٨٦
المبحث الثاني: الإحصاءات وتكرار الكلمة - تكرار المستند العكسي	١٨٩
• الفصل الثَّانِي: حقيبة الكَلِمَات وتضمين الكَلِمَات	١٩٤
المبحث الأول: حقيبة الكَلِمَات	١٩٥

الموضوع	الصفحة
المبحث الثاني: تضمين الكلمات	٢٠٤
• الفصل الثالث: استخراج الموضوعات والكلمات المفتاحية	٢١١
المبحث الأول: نمذجة الموضوعات	٢١١
المبحث الثاني: الكلمات المفتاحية	٢١٨
• الفصل الرابع: الأنماط النحوية	٢٢٣
المبحث الأول: أنظمة الوسوم النحوية واسعة الاستخدام	٢٢٤
المبحث الثاني: نظرة عامة عن الأنظمة	٢٢٦
المبحث الثالث: أمثلة على الأنماط النحوية	٢٢٩
• الفصل الخامس: تنقيب البيانات	٢٣٣
المبحث الأول: تهيئة المتغيرات في البيانات	٢٣٦
المبحث الثاني: التصنيف	٢٣٩
المبحث الثالث: الانحدار الخطي	٢٤٥
الخاتمة	٢٥٤
■ أولاً: عن الإحصاء اللغوي في الباب الأول	٢٥٥
النتيجة	٢٥٥
الوجهة	٢٥٦
التوصيات	٢٥٦
■ ثانياً: عن تنقيب النصوص والبيانات العربية في الباب الثاني	٢٥٧

الصفحة	الموضوع
٢٥٧	النتيجة
٢٥٨	الوجهة
٢٥٩	التوصيات
٢٦١	المراجع العربية والأجنبية
٢٦٣	المراجع العربية
٢٦٦	المراجع الأجنبية
٢٧١	الملاحق
٢٧٣	الملحق (أ): إحصاءات القرآن الكريم
٢٧٧	الملحق (ب): أقسام الكلام في القرآن الكريم
٢٧٨	الملحق (ج): أكواد التحليل الإحصائي للبيانات اللغوية
٢٨٥	الملحق (د): أكواد حساب تكرار الكلمة - تكرار المستند العكسي
٢٨٦	الملحق (هـ): أول خمسين كلمة من حساب تكرار الكلمة - تكرار المستند العكسي
٢٨٩	الملحق (و): تدريب واختبار التوسيم النحوي العربي للاعتماديات الكلية
٢٩٥	نبذة عن المؤلف

قائمة الجداول

الجدول	الصفحة
جدول ١: الرَّسْمُ الْعُثْمَانِيّ وَالرَّسْمُ الْإِمْلَائِيّ قَبْلَ التَّقْطِيعِ وَبَعْدَ أُسْلُوبٍ مَعِينٍ مِنَ التَّقْطِيعِ	٤٩
جدول ٢: التَّوْزِيعُ وَالتَّسْتِثْنَاءُ لِكَلِمَةِ (الكتاب)	٥١
جدول ٣: التَّكْرَارَاتُ وَالتَّنَوُّعُ الْمَعْجَمِيُّ وَالكثافة المعجمية للرسم الإملائي قَبْلَ التَّقْطِيعِ	٥٢
جدول ٤: التَّكْرَارَاتُ وَالتَّنَوُّعُ الْمَعْجَمِيُّ وَالكثافة المعجمية للرسم الإملائي بَعْدَ التَّقْطِيعِ	٥٤
جدول ٥: التَّكْرَارَاتُ الْمَحْوَظَةُ لِلْفَعْلَيْنِ (يَخْشُونَ) وَ(يَخَافُونَ) فِي السُّورِ الْمَكِّيَّةِ وَالسُّورِ الْمَدَنِيَّةِ	٦٣
جدول ٦: التَّكْرَارَاتُ الْمَتَوَقَّعة لِلْفَعْلَيْنِ (يَخْشُونَ) وَ(يَخَافُونَ) فِي السُّورِ الْمَكِّيَّةِ وَالسُّورِ الْمَدَنِيَّةِ	٦٣
جدول ٧: توصية (كوهن) لتفسير حجم التأثير بمعامل (كريمرف)	٦٧
جدول ٨: التَّكْرَارَاتُ الْمَحْوَظَةُ	٦٨
جدول ٩: التَّكْرَارَاتُ الْمَتَوَقَّعة (نَظَرِيًّا)	٦٨
جدول ١٠: مقاييس التَّصَاخُبِ اللَّفْظِيِّ	٩١
جدول ١١: المقاييس الموصى بها لاستخراج الغريب	٩٧
جدول ١٢: حساب موافقة المقدّر البيئي	١٠١
جدول ١٣: حساب موافقة تفسير كلمة (الغداة) في بعض التفسيرات	١٠٢
جدول ١٤: معامل ارتباط بيرسون بين أقسام الكلام	١٠٨
جدول ١٥: القيم الاحتمالية	١٠٨

الجدول	الصفحة
جدول ١٦: الارتباط الإيجابي والارتباط السلبي بين الأقسام النحوية	١١٠
جدول ١٧: معامل ارتباط سبيرمان للمتغيرات الترتيبية	١١٣
جدول ١٨: القيم الاحتمالية	١١٣
جدول ١٩: معاملات النموذج للبيانات (أ)	١٣٦
جدول ٢٠: معاملات النموذج الأفضل للبيانات (أ)	١٣٧
جدول ٢١: معاملات النموذج للبيانات (ب)	١٣٨
جدول ٢٢: معاملات النموذج الأفضل للبيانات (ب)	١٣٩
جدول ٢٣: التأثيرات الممتزجة من المتغير المتنبئ العشوائي (الطول Length)	١٤٣
جدول ٢٤: التأثيرات الممتزجة من المتغير المتنبئ العشوائي (التنوع Variety)	١٤٣
جدول ٢٥: التأثيرات الممتزجة من المتغير المتنبئ العشوائي (التركيب Syntax)	١٤٥
جدول ٢٦: جدول مصفوفة الارتباك للقيم الحقيقية والقيم التنبؤية	١٦٧
جدول ٢٧: وسوم ستانفورد النحوية للغة العربية	١٧٢
جدول ٢٨: نموذج إحصاءات كل آية من سورة الفاتحة	١٩٢
جدول ٢٩: حالات نموذج حقيقة الكلمات	١٩٩
جدول ٣٠: تمثيل مصفوفة خوارزمية الاستخراج الآلي السريع للكلمات المفتاحية	٢٢٠
جدول ٣١: مقياس درجات الكلمات مع التكرارات	٢٢١
جدول ٣٢: التنبؤ بعلامات الترقيم بين الأسماء والأفعال والضمائر	٢٣٦
جدول ٣٣: أنواع المتغيرات في البيانات بين تعلم الآلة وعلم الإحصاء	٢٣٧
جدول ٣٤: مصفوفة الارتباك لنموذج الأنحدار اللوجستي	٢٤٠
جدول ٣٥: مقاييس مصفوفة الارتباك لنماذج التصنيف	٢٤٣
جدول ٣٦: قيم الارتباط بين متغيرات بيانات نموذج الأنحدار الخطي	٢٤٨
جدول ٣٧: العينة العشوائية (تدريب-اختبار)	٢٥٠

قائمة الأشكال

الشكل	الصفحة
شكل ١: واجهة أداة غواص (أداة لمعالجة المُدَوَّنَات اللُّغَوِيَّة العَرَبِيَّة)	٣٤
شكل ٢: واجهة فوينت وواجهة بعض النُّتَاج لتحليل مُدَوَّنَة القرآن الكريم	٣٥
شكل ٣: المتغيَّرات في البَيِّنَات (اللُّغَوِيَّة)	٤٤
شكل ٤: شكل بيانات الأعمدة والصفوف لمتغيَّراتٍ لُغَوِيَّة افتراضية	٤٥
شكل ٥: بيانات المتغيَّرين اللُّغَوِيَّين (يا أيها الناس) و(يا أيها الذين آمنوا) من مُدَوَّنَة القرآن الكريم	٤٨
شكل ٦: واجهة حساب الكلِّمات	٥٣
شكل ٧: الإحصاءات الوصفية ومقاييس التَّسَنُّت للكلمة (النَّاس) في القرآن الكريم	٥٧
شكل ٨: المدى	٥٩
شكل ٩: جدولة متقاطعة للفعليين (يخشون) و(يخافون)	٦٢
شكل ١٠: واجهة مقارنة المجموعات في صندوق (النحو المعجمي)	٦٤
شكل ١١: نتاج كاي تربيع للفعليين (يخشون) و(يخافون)	٦٥
شكل ١٢: واجهة أداة تمثيل البَيِّنَات اللُّغَوِيَّة	٧٠
شكل ١٣: تكرار (الذين آمنوا) في السُّور الطوال	٧١
شكل ١٤: المَحْطَط الدَّرَجِي لتكرار (الذين آمنوا) في السُّور الطوال	٧١
شكل ١٥: سبعة وخمسون نصًّا (٥٧ سورة) في الأجزاء الثلاثة الأخيرة	٧٢
شكل ١٦: مخطَّط الصَّنَدُوق	٧٣

الشكل	الصفحة
شكل ١٧ : سبعة وخمسون نصاً (٥٧ سورة) في الأجزاء الثلاثة الأخيرة	٧٤
شكل ١٨ : أعمدة الخطأ	٧٤
شكل ١٩ : الجنة والنار بين أجزاء القرآن	٧٥
شكل ٢٠ : مخطط التَّشْتُّت	٧٦
شكل ٢١ : الجنة والنار بين أجزاء القرآن	٧٧
شكل ٢٢ : المَخَطَط الخطِّي الانحداريّ	٧٧
شكل ٢٣ : اشتقاقات الجنة والنار بين أجزاء القرآن	٧٨
شكل ٢٤ : المَخَطَط الخطّي	٧٩
شكل ٢٥ : بيانات المواقع الجغرافيّة	٧٩
شكل ٢٦ : تمثيل بيانات المواقع الجغرافيّة	٨٠
شكل ٢٧ : صيغ الجنة والنار بين السُّور المكيّة والسُّور المدنيّة	٨١
شكل ٢٨ : مَخَطَط الأعمدة المرصوفة	٨٢
شكل ٢٩ : صيغ الجنة والنار بين السُّور المكيّة والسُّور المدنيّة	٨٣
شكل ٣٠ : مَخَطَط الأعمدة المرصوفة	٨٣
شكل ٣١ : صيغ الجنة والنار بين السنوات الزمنية (٢٣-١)	٨٤
شكل ٣٢ : خطوط المؤشر	٨٥
شكل ٣٣ : صيغ الجنة والنار بين السنوات الزمنية (٢٣-١)	٨٦
شكل ٣٤ : مَخَطَط الشُّموع	٨٦
شكل ٣٥ : واجهة حساب التّصاحب اللَّفْظِيّ في (علم الدّلالة والخطاب)	٨٨

الصفحة

الشكل

شكل ٣٦ : أداة صندوق لانكستر ٩٨

شكل ٣٧ : تمثيل التَّصَاخُب من دون مقاييس مجموعة التَّصَاخُب (أ) ١٠٠
وباستخدام مقاييس مجموعة التَّصَاخُب (ب)

شكل ٣٨ : ترميزات التَّفاسير الثلاث ١٠٢

شكل ٣٩ : واجهة حساب الموافقة في (علم الدلالة والخطاب) ١٠٣

شكل ٤٠ : واجهة حساب الارتباط في (تنوع السَّجَل اللُّغَوِيّ) ١٠٤

شكل ٤١ : واجهة مقارنة المجموعات في (اللُّغَوِيَّات الاجتماعيّة) ١٠٥

شكل ٤٢ : بيانات التَّكْرَارَات النَّسْبِيَّة لأقسام الكلام الرئيسة بين خمس سور طويلة ١٠٧

شكل ٤٣ : الخريطة الحراريّة لارتباط أقسام الكلام ١٠٩

شكل ٤٤ : ارتباط الأسماء مع الصفات ١١١

شكل ٤٥ : ارتباط الأسماء مع الأفعال ١١١

شكل ٤٦ : بيانات التَّكْرَارَات النَّسْبِيَّة لخمس سور طويلة بين أقسام الكلام الرئيسة ١١٢

شكل ٤٧ : الخريطة الحراريّة لارتباط أقسام الكلام ١١٣

شكل ٤٨ : بيانات التَّكْرَارَات المطلق والتَّكْرَار النَّسْبِيّ لأسماء الأنبياء في القرآن الكريم ١١٥

شكل ٤٩ : واجهة حساب الارتباط في (تنوع السَّجَل اللُّغَوِيّ) ١١٦

شكل ٥٠ : حساب التَّكْرَارَات المطلقة والنَّسْبِيَّة المتعدّدة لأسماء الأنبياء في القرآن الكريم ١١٨

الشكل	الصفحة
شكل ٥١: نتائج التجميع بالمسافة الإقليدية	١١٩
شكل ٥٢: نتائج التجميع بمسافة منهاتن	١١٩
شكل ٥٣: بيانات اختبارات المجموعة البارامترية وغير البارامترية	١٢٢
شكل ٥٤: بيانات أقسام الكلام الرئيسة بين السُّور الطويلة	١٢٥
شكل ٥٥: تحليل التناظر	١٢٥
شكل ٥٦: بيانات الانحدار الخطي	١٣١
شكل ٥٧: تمثيل الارتباط والنموذج الخطي	١٣٢
شكل ٥٨: مخطط الربعيات Normal Q-Q والتمثيل الخطي للمتبقيات residuals مقابل القيم الموفقة للنموذج	١٣٣
شكل ٥٩: الانحدار اللوجستي	١٣٥
شكل ٦٠: واجهة الانحدار اللوجستي في (النحو المعجمي)	١٣٦
شكل ٦١: بيانات الانحدار اللوجستي	١٤١
شكل ٦٢: واجهة الانحدار اللوجستي للتأثير الممتزج في (اللغويات الاجتماعية)	١٤٢
شكل ٦٣: بيانات (رحمة) و(عذاب)	١٤٧
شكل ٦٤: واجهة القمم والقعور في (التغير عبر الزمن)	١٤٨
شكل ٦٥: تمثيل نتيجة استعمال (رحمة) عبر الزمن في سور القرآن الكريم	١٤٨
شكل ٦٦: تمثيل نتيجة استعمال (عذاب) عبر الزمن في سور القرآن الكريم	١٤٩
شكل ٦٧: تمثيل نتيجة استعمال تصاحبات (رحمة) عبر الزمن في سور القرآن الكريم	١٥١

الصفحة

الشكل

١٥٢	شكل ٦٨ : تمثيل نتيجة استعمال تصاحبات (عذاب) عبر الزمن في سور القرآن الكريم
١٥٣	شكل ٦٩ : بيانات استخدام منهج تحليل التآرجح الاستعمالي
١٥٤	شكل ٧٠ : واجهة تحليل التآرجح الاستعمالي UFA في (التغير عبر الزمن)
١٧٤	شكل ٧١ : نتيجة تشجير النحو الاعتمادي
١٧٥	شكل ٧٢ : قائمة كلمات الإيقاف في مكتبة nltk
١٧٦	شكل ٧٣ : أكثر كلمات الإيقاف تكراراً
١٨١	شكل ٧٤ : واجهة أداة (أورانج) وخيارات ونافذة تنصيب مكتبة Text
١٨١	شكل ٧٥ : أمثلة لأساليب ربط مسارات العمل للتحليل
١٨٢	شكل ٧٦ : مثال ترابط الأدوات وتمثيل خُرجها داخل أداة (أورانج) للمعالجة القبلية
١٨٣	شكل ٧٧ : مثال ترابط الأدوات وتمثيل خُرجها داخل أداة (أورانج) لتصدير البيانات واستعراض هيكلتها
١٨٧	شكل ٧٨ : شكل هيكلية البيانات لمعالجتها في أداة أورانج
١٨٧	شكل ٧٩ : شكل هيكلية البيانات لمعالجتها في أداة أورانج
١٨٨	شكل ٨٠ : شكل هيكلية البيانات لمعالجتها في أداة أورانج
١٨٨	شكل ٨١ : شكل هيكلية البيانات لمعالجتها في أداة أورانج
١٩٠	شكل ٨٢ : مسار العمل للإحصاءات وتجزئة التشابه
١٩١	شكل ٨٣ : تجزئة التشابه
١٩٧	شكل ٨٤ : مسار عمل ربط الأدوات لمعالجة البيانات وحقيبة الكلمات والاختبار والقياس والتمثيل

الشكل	الصفحة
شكل ٨٥ : نافذة أداة حقيبة الكلمات	١٩٨
شكل ٨٦ : تكرار الكلمات (count)؛ تكرار المستند العكسي (لا شيء)	٢٠٠
شكل ٨٧ : تكرار الكلمات (count)؛ تكرار المستند (تكرار المستند العكسي IDF)	٢٠١
شكل ٨٨ : إثراء الكلمات	٢٠٣
شكل ٨٩ : مسار العمل لتضمين المستندات	٢٠٦
شكل ٩٠ : اختيار اللغة وأسلوب الجامع Aggregator لتضمين المستندات	٢٠٧
شكل ٩١ : نتيجة تضمين المستندات	٢٠٨
شكل ٩٢ : مسار عمل استخراج الموضوعات وتمثيلها	٢١٢
شكل ٩٣ : نتائج الموضوعات باستخدام الفهرسة الدلالية الكامنة	٢١٤
شكل ٩٤ : نتائج الموضوعات باستخدام تخصيص دركليه الكامن	٢١٦
شكل ٩٥ : نتائج الموضوعات باستخدام معالجة دركليه الهرمية	٢١٨
شكل ٩٦ : مسار عمل استخراج الكلمات المفتاحية	٢٢١
شكل ٩٧ : الكلمات المفتاحية باستخدام خوارزمية الاستخراج الآلي السريع لللغات المفتاحية	٢٢٢
شكل ٩٨ : نتائج تحليل النظام الآلي للمعالجة الأساسية لبادت ومداмира وفراسة وستانفور	٢٢٨
شكل ٩٩ : تداخلات المجالات التطبيقية لعلم البيانات	٢٣٣
شكل ١٠٠ : بيانات تحليل للتصنيف	٢٣٧
شكل ١٠١ : بيانات تحليل للتصنيف	٢٣٨
شكل ١٠٢ : بيانات تحليل الانحدار	٢٣٨

الشكل	الصفحة
شكل ١٠٣: مسار العمل لتحليل التصنيف بالانحدار اللوجستي	٢٣٩
شكل ١٠٤: مخطط التَشَتُّت لحجم السُّور المَكِّيَّة والمدنيَّة بين السَّجْدَة والزمن	٢٤٠
شكل ١٠٥: مخطط التَشَتُّت لحجم السُّور المَكِّيَّة والمدنيَّة بين السَّجْدَة والطول	٢٤٠
شكل ١٠٦: مسار التَّحْلِيل لنماذج التصنيف وتمثيل النتائج	٢٤١
شكل ١٠٧: مسار العمل لتحليل بيانات الأنبياء التصنيفية	٢٤٣
شكل ١٠٨: قياس المسافات بين الصنف class (نعم ولا)	٢٤٤
شكل ١٠٩: تمثيل الإقحام الخطي	٢٤٥
شكل ١١٠: مثال لبيانات تحليل الانحدار الخطي	٢٤٧
شكل ١١١: مسار العمل لتحليل الانحدار الخطي	٢٤٧
شكل ١١٢: خط الانحدار البسيط (متغير مستقل واحد مقابل متغير تابع واحد)	٢٥١
شكل ١١٣: مخطط التَشَتُّت بخط الانحدار بين الترتيب الزمني وعدد الآيات	٢٥٢
شكل ١١٤: الانحدار المتعدد الحدود بين الترتيب الزمني وعدد الآيات	٢٥٣

مقدمة المجمع

ينشط مجمع الملك سلمان العالمي للغة العربية في مسارات عمل متنوعة، ويتولى مهاماً متعددة تتصل بنشر اللغة العربية، ودعمها، وتعزيز مكانتها، والمحافظة على سلامتها نطقاً وكتابةً، والنظر في فصاحتها، وأصولها، وأساليبها، وأقيستها، ومفرداتها، وقواعدها، وتيسير تعلمها بداخل المملكة العربية السعودية وخارجها؛ لتواكب المتغيرات في جميع المجالات، ويتمثل طموح المجمع في أن يصبح مجمعاً متميزاً يخدم اللغة العربية، وينطلق من قلب العالم الإسلامي والعربي، ومن مهد العروبة الأول، وأن يصبح رائداً ومرجعياً عالميةً في مجال اللغة العربية وتطبيقاتها المتنوعة.

وضمن توجيهات سمو وزير الثقافة، رئيس مجلس الأمناء الأمير بدر بن عبد الله بن فرحان آل سعود - حفظه الله - في دعم أعمال المجمع، وبرامجه: العلمية، والثقافية، والبحثية، أطلق المجمع مشروع (المسار البحثي العالمي المتخصص)؛ لتلبية الحاجات العلمية، ومواجهة المشكلات اللغوية، وسدّ الفجوات المتعلقة بالبحث والنشر العلمي، وفتح الآفاق العلمية والمعرفية المتنوعة، واستكمال مسارات النشر اللغوية المتخصصة.

ويهدف المشروع إلى تعزيز دور المجمع، وإيصال رسالته؛ بتغطية مساحات متنوعة من التخصصات، والفنون المتعلقة باللغة العربية، وإثراء المحتوى العلمي ذي العلاقة بمجالات اهتمام المجمع، ودعم الإنتاج العلمي المتميز وتشجيعه، وفتح المجال أمام الباحثين والمختصين، وتوثيق صلتهم بالمجمع؛ وذلك بإشراكهم في أعمال هذا المشروع.

ويضمُّ المشروع مجالاتٍ بحثيةً متنوعة، ويغطي الموضوعات التي تعرّز موقع العربية ضمن اللُّغات الحضارية العالمية، ومن أبرزها: (دراسات التّراث اللُّغوي العربي وتحقيقه، والدراسات حول المعجم، وقضايا المصطلح، وقضايا الهوية اللُّغوية، ومكانة العربية وتعزيزها، واللّسانيّات التّطبيقية، والتّخطيط اللُّغوي، والسياسة اللُّغوية، واللّسانيّات الحاسوبية، والتّرجمة، والتّعريب، وتعليم اللُّغة العربية للناطقين بها وبغيرها، والدراسات البينية).

وقد بدأ المشروع باستقبال الدّراسات النّوعية الجادة، وتواصل مع: (المختصين، والباحثين، والمؤسسات العلمية داخل المملكة العربية السعودية وخارجها)، ودعاهم إلى المشاركة في المشروع، واتخذ الإجراءات المتصلة بتحكيم الأعمال والنظر في جديتها وأصالتها ومدى إضافتها للمكتبة العربية واستنادها إلى المعايير المتعارف عليها في البحث والمنهج والتوثيق قبل طباعتها ونشرها.

ويهدف هذا الكتاب (الإحصاء وتقنيات الذكاء الاصطناعي للبيانات اللُّغوية، مدوّنة القرآن الكريم أنموذجاً) إلى إثراء المكتبة العربية بالكتب العلمية في مجال اللّسانيّات الحاسوبية، ويسلّط الضّوء على العديد من القضايا المتعلّقة بالإحصاء اللُّغوي للبيانات اللُّغوية، وتقنيات الذكاء الاصطناعي المرتبطة بتنقيب البيانات اللُّغوية.

ويجتهد المجمع في انتقاء الكتب التي يكون في نشرها إضافة معرفية نوعية، ويأمل أن يكون هذا الكتاب مفتاحاً لمشروعات علمية وعملية ويحقق إثراء معرفياً لافتاً.

ويشكر المجمع مؤلف الكتاب سعادة الأستاذ الدكتور سلطان بن ناصر المكيول؛ لما تفضل به من عمل علمي جاد، ويدعو الباحثين إلى التواصل مع مشروعات المجمع، ومنها: مسار البحوث والنشر العلمي؛ للمشاركة فيه والمساهمة في إثرائه.

الأمين العام للمجمع

أ.د. عبد الله بن صالح الوشمي

المقدمة

قبل أن أُشير إلى الهدف من هذا الكتاب وإلى محتوياته المتعلقة بالإحصاء اللغوي للبيانات اللغوية في الباب الأول، وبتقنيات الذكاء الاصطناعي المرتبطة بتنقيب البيانات اللغوية في الباب الثاني؛ أود أن ألفت القارئ إلى نقطة مهمّة، أجدها غامضةً عند كثيرين في العالم العربيّ، تتعلّق بطبيعة تخصّص علم الإحصاء من جهة أولى، وتخصّص معالجة اللغة الطّبيعيّة وعلم البيانات من جهة ثانية، وهي طبيعةٌ تجري في الجامعات الرائدة، والمراكز العلميّة والبحثيّة المميّزة عالمياً في هذين المجالين. ما يجري في هذين الاختصاصين هو أنّ علم الإحصاء مجالٌ تطبيقيٌّ، إن استخدمه اللّغويّ أو الطّبيب أو الاقتصاديّ، إلى آخره؛ فإنّه يُجرّبه بالتّطبيق في مجاله، وأنّ معالجة اللغة الطّبيعيّة وعلم البيانات مجالٌ تطبيقيّ، إن دخل فيه غير المتخصّص في علوم الحاسب؛ فإنّه يُجرّبه بالتّطبيق في مجاله، سواء كان لّغويّاً، أم اقتصاديّاً، أم خبير تسويق، إلى آخره. ومن مهمّة المتخصّصين في علم الإحصاء، أو المتخصّصين في علوم الحاسب (المجال الفرعي: علم البيانات أو معالجة اللغة الطّبيعيّة)؛ أن يطوروا، وابتكروا، ويوجدوا المفاهيم البنائيّة المتقدّمة والمستجدّة في هذين المجالين، ولغيرهم ممّن هم ليسوا متخصّصين في علوم الحاسب تعلّم تطبيقات هذين المجالين، وإجرائها فيما يخدم اختصاصاتهم ومشاريعهم.

يستهدف هذا الكتاب المتخصّصين والباحثين في العلوم اللّغويّة والإنسانيّة والاجتماعيّة، ما دامت المادّة محلّ التّحليل لديهم هي اللّغة ونصوصها المكتوبة والمنطوقة. ظهرت دوافع تأليف هذا الكتاب من عدم وجود مصدرٍ عربيّ في مجال الإحصاء اللّغويّ أوّلاً، ثم مجال تنقيب النصوص والبيانات العربيّة ومعالجتها ثانياً،

وكلا المجالين مكملٌ للآخر، فالممارسات الدقيقة في الإحصاء اللُّغويّ بدءاً من إعداد البيانات؛ تعتمد اعتماداً كبيراً على الممارسات الدقيقة في تنقيب النصوص العربيّة ومعالجتها معالجةً أساسيّةً دقيقةً. ومن دوافع تأليف هذا الكتاب -أيضاً- الرّغبة في تسهيل موضوعات هذين المجالين، وفي فتح أبواب الممارسات العلميّة الرّقميّة التي باتت اليوم محوراً لمشاريع البحثيّة في العلوم اللُّغويّة والإنسانيّة والاجتماعيّة في الجامعات والهيئات والمؤسّسات العالميّة.

وينقسم هذا الكتاب إلى بابين أساسيين؛ الباب الأوّل: الإحصاء اللُّغويّ، والباب الثّاني: تنقيب النصوص والبيانات العربيّة. وفي كلّ بابٍ فصولٌ ومباحثٌ تتناول خطوات التّحليل بأدوات قائمة بذاتها، لا تتطلّب من القارئ معرفةً بلغة البرمجة (آر) للإحصاء اللُّغويّ (الباب الأوّل)، أو بلغة البرمجة (البايثون) لتنقيب البيانات العربيّة ومعالجة اللغة العربيّة الطّبيعيّة (الباب الثّاني).

والمصادر العربيّة تخلو من الفائدة للقارئ العربيّ، فضلاً عن المتخصّص في العلوم الإنسانيّة والاجتماعيّة؛ بتطبيقات هذين المجالين على نصوصٍ عربيّة. وعلى الرّغم من المحاولات في ترجمة بعض الكتب أو المقالات عن الممارسات البحثيّة والأساليب التّحليليّة التّطبيقيّة في هذين المجالين من الإنجليزيّة إلى العربيّة؛ لا يزال المحتوى يكتنفه الغموض؛ بسبب الجوانب النظريّة المعقّدة، والشُّروحات الرياضيّة للمعادلات أو الخوارزميّات، كحال كتاب (علم الإحصاء في لُغويّات المدونة الحاسوبية: دليل عمليّ، المؤلّف: Vaclav Brezina)، الذي ترجمته ونشرته في عام ٢٠٢١م. ولن يتناول هذا الكتاب شروحاتٍ نظريّة، بل سيتناول خطوات الأساليب التّطبيقيّة الإحصائيّة بأدوات (لانكستر) الإحصائيّة في فصول الباب الأوّل، وخطوات تنقيب النصوص ومعالجة البيانات للغة العربيّة بأدوات (أورانج) في فصول الباب الثّاني، وذلك باستخدام مدوّنة القرآن الكريم. إذن؛ هذا الكتاب هو مدخلٌ علميٌّ وتطبيقيٌّ أساسيّ، إيماناً منّي بأنّ البدء بالكتب التّطبيقيّة يفتح مغاليق الكتب النظريّة والعلميّة أسرع من لو كان الحال

على عكس ذلك. ولقد ضمنتُ أكوادَ لغة البرمجة (آر) للإحصاءات اللُّغويّة في ملحق الكتاب، تحسباً لتوقف أدوات (لانكستر) الإحصائيّة (الشبكية) عن العمل، أما أكواد تنقيب النُصوص العربيّة ومعالجة اللغة العربيّة الطّبيعيّة المدمجة في أدوات (أورانج)؛ فيمكنُ الوصولُ إليها عبر <https://github.com/biolab/orange3>، أو في موقعِ الأداة نفسها <https://orangedatamining.com> في خياراتِ الوثائقي (Docs). وفي ظهور هذه الأدوات القائمة بذاتها مزيّة، كونها تخدم الباحثين في العلوم ممّن ليس لهم معرفةُ برُمجيّة.

وقد اخترتُ القرآنَ الكريمَ؛ ليكون مادّة التّطبيقِ لهذين المجالين لسببين؛ الأوّل: كونه مُدَوّنةً معلومةً لكلِّ قارئٍ عربيٍّ، يعرفُ عددَ سورها، ويعرفُ آياتها وكلماتها، وكونه نصّاً مُبيّناً وتنزيلاً حكيماً من عند الله - عزّ وجلّ - تألّفه ألسنتنا منذ نعومة أظافرنا بالتعبّد والتّلاوة. والثّاني: لأنّ التّركيزَ على أساليب الإحصاء اللُّغويّ وأدوات تنقيب النُصوص والبيّانات هو الغاية؛ حتّى تسهل معرفتها، ويتّعيّن القارئُ نيلَ تطبيقاتها على أيّ مُدَوّنة لُغويّة يريد جمعها وتحليلها مستقبلاً وفق اهتماماته، وما ذلك إلا لأجل تطوير البحث اللُّغويّ العربيّ باستخدام البيّانات اللُّغويّة الرّقميّة، التي صارت محور الحياة المستقبليّة اليوم، وستكون كذلك في العقود القادمة.

عرّضتُ في الباب الأوّل (الإحصاء اللُّغويّ) تمهيداً تعريف أهمّيّة المُدَوّنات اللُّغويّة والبيّانات اللُّغويّة؛ بوصفها علماً، وبوصفها منهجاً وتطبيقاتٍ وأساليب صارت تُمارس دوراً محورياً في فروع اللُّغويّات واللُّغويّات التّطبيقيّة والعلوم الاجتماعيّة والإنسانيّة، ثم لتعريف مصادر المُدَوّنة ومعايير الجمع والأدوات. تلا التّمهيد فصولُ تطبيقات علم الإحصاء على مُدَوّنة القرآن الكريم وفق ما يأتي:

الفصل الأوّل: البيّانات اللُّغويّة (أنواع الإحصاءات وأنواع تمثيل البيّانات).

الفصل الثّاني: تحليل الخطاب (مُعاملات وشبكات تحليل التّصاحب وحساب موافقة المقدّر البيّني).

الفصل الثالث: الارتباط والتّجميع ومقارنة المجموعات.

الفصل الرابع: الانحدار الخطّي والانحدار اللّوجسّتيّ

الفصل الخامس: تحليل البيانات اللّغويّة التّاريخيّة.

وعرضتُ في الباب الثّاني (تنقيب النّصوص والبيانات العربيّة) تمهيداً للمعالجات الأساسيّة للغة العربيّة الطّبيعيّة، وقياس أدائها بمصفوفة الارتباك، وتطبيقات معالجة اللغة العربيّة الطّبيعيّة المتعدّدة كاستخراج النّصوص، وتلخيص النّصوص، والتّعرّف إلى الكيانات، وتصنيف النّصوص، وتحليل المشاعر، وكشف النّيّة والأخبار الزّائفة، وروبوتات المحادثة، والدّعم الافتراضيّ، والتّصحيح الآليّ، والتّشكيل الآليّ، والتّعرّف إلى الكلام، والترجمة الآليّة. تلا ذلك فصول الباب التّطبيقيّة على مدوّنة القرآن الكريم، وذلك وفق السّلسل الآتي:

الفصل الأوّل: تنقيب النّصوص (إعداد البيانات اللّغويّة، ثم الإحصاءات، ثم تكرار الكلمة - تكرار المستند العكسيّ).

الفصل الثّاني: حقيبة الكلمات، وتضمين الكلمات.

الفصل الثّالث: استخراج الموضوعات، واستخراج الكلمات المفتاحيّة.

الفصل الرابع: الأنماط النّحويّة.

الفصل الخامس: تنقيب البيانات للنّصوص، ونماذج التّصنيف، والانحدار الخطّي.

ونظراً إلى عدم إمكانيّة تمثيل الكلمات العربيّة في البيانات باستخدام لغة (آر)؛ فقد نُقحرت بالحروف الأجنبيّة أو تُرجمت، على عكس لغة (البايثون). ولذلك ستجد أن اللغة العربيّة منقحرة في بيانات (الآر)، وغير منقحرة في بيانات (البايثون).

وللاطلاع على البيانات التي أعدتها للتحليل في الباب الأول (الإحصاء اللغوي) وفي الباب الثاني: (تنقيب النصوص والبيانات العريضة)، ومن أجل استخدامها للتدريب العملي وللتنتاج (تطابق النتائج)؛ يمكن العودة إلى الرابطين الآتيين:

بيانات الباب الأول : www.kaggle.com/datasets/sultanalmujaiwel/statistics-in-quran

بيانات الباب الثاني : www.kaggle.com/datasets/sultanalmujaiwel/quran-mining

وأخيراً؛ أرجو أن أكون قد وفقت في التسهيل، فإن وفقت، فذاك خيرٌ من الله.

المؤلف

الباب الأول

الإحصاء اللُّغَوِيّ^(١)

(١) يُمكنُ للقارئِ تطبيقُ كُلِّ الإحصاءاتِ اللُّغَوِيَّةِ الواردةِ في فصولِ هذا البابِ، باستخدامِ أدواتِ لانكسترا الإحصائيَّةِ وباستخدامِ البياناتِ اللُّغَوِيَّةِ التي أعدها المؤلفُ، من أجلِ تكرارِ التحليلِ والتَّدريبِ والتَّأكُّدِ من تطابقِ النَّتيجةِ. ولتسهيلِ العُودةِ إلى بَيَّاناتِ كُلِّ مُعالجةٍ آليَّةٍ في فصولِ هذا البابِ، فقد جُمِعَتْها في ملفٍ واحدٍ (إكسل Excel)، وسَمِّيتُ كُلُّ ورقةٍ sheet داخلَ هذا الملفِ برقمِ الشَّكلِ الواردِ في فصولِ هذا البابِ. موقعِ البياناتِ اللُّغَوِيَّةِ:

www.kaggle.com/datasets/sultanalmujaiwel/statistics-in-quran



الإحصاء وتقنيات الذِّكاء الاصطناعي
للبياناتِ اللُّغَوِيَّةِ

التمهيد

تعددت مصطلحات (corpus) في العَرَبِيَّة، فظهرت الذَّخيرة والمكنز والمُدونة، ثم استقرَّ المصطلح الأخير في مشاريع المُدونة اللُّغويَّة التي ظهرت في السَّنوات الماضية، وظهرت أبحاثٌ في مصادرها وبنائها وأساليب توظيفها في البحث اللُّغويِّ والتَّعليم. وشاع مفهوم المُدونة اللُّغويَّة بمجرد ظهور أدوات سهلة الاستخدام، تقوم على إظهار تكرارات الكلمات والكشافات السياقيَّة، وبمجرد إنشاء مُدونات شبكية تحتوي على النُّصوص الخاصة بها، فظُنَّ بذلك كلُّه أن هذا المجال يرتبط بأدوات محدودة فقط؛ كأداة غواص^(١) في العالم العَرَبِيّ، أو أدوات (وورد سميث^(٢) WordSmith Tools) في العالم العَرَبِيّ، أو بالمُدونات اللُّغويَّة الشبكيَّة الموجودة والقائمة بذاتها؛ مثل المُدونة اللُّغويَّة العَرَبِيَّة لمدينة الملك عبدالعزيز للعلوم والتقنيَّة^(٣)، والمُدونة اللُّغويَّة العَرَبِيَّة الدوليَّة^(٤)، ومُدونة عربي^(٥) (arabiCorpus). كما شاع -أيضاً- اعتقادٌ آخر، وهو أن لُغويَّات المُدونات مقتصرةٌ على معالجة المُدونة اللُّغويَّة من أجل بناء المعاجم، وهو اعتقادٌ متوقَّعٌ، نتج عن طبيعة ما تقوم به المُدونات وأدواتها من استخراج للكلمات والعبارات والتكرارات والكشافات السياقيَّة، إلّا أنَّ واقع أبحاث المُدونات اللُّغويَّة ولُغويَّات المُدونات في المشاريع العالميَّة قد تطوَّر كثيراً بحكم التَّطوُّر الحاصل في مشاريع معالجة اللغة الطَّبيعيَّة والإنسانيَّات

(١) غواص: أداة لمعالجة المُدونات اللُّغويَّة العَرَبِيَّة (النسخة ٦، ٤). تاريخ الاسترداد ٢٤ أكتوبر، ٢٠٢٢، من: <https://sourceforge.net/ghawwasv4>.

(2) Scott, M. (2020). WordSmith Tools version 8 [Lexical Analysis Software]. Retrieved October 24, 2022, from <https://lexically.net/wordsmith>

(٣) مدينة الملك عبدالعزيز للعلوم والتقنيَّة. المُدونة اللُّغويَّة العَرَبِيَّة. تاريخ الاسترداد ٢٤ أكتوبر، ٢٠٢٢، من: <https://corpus.kacst.edu.sa>

(٤) مكتبة الإسكندرية. المُدونة اللُّغويَّة العَرَبِيَّة الدوليَّة. تاريخ الاسترداد ٢٤ أكتوبر، ٢٠٢٢، من: <https://www.bibalex.org/ica/ar/login.aspx>

(5) Parkinson, D. (2001). arabiCorpus. Retrieved October 24, 2022, from <https://arabicorpus.byu.edu>.

الرَّقْمِيَّة في السَّنات الأخيرة، فصارت المُدَوَّنات اللُّغَوِيَّة، والبيانات اللُّغَوِيَّة، وتطبيقات معالجة اللغة الطَّبِيعِيَّة؛ أدواتٌ بحثيةٌ حاسوبيةٌ، يُستفاد منها في كلِّ العلوم اللُّغَوِيَّة والإنسانيَّة والاجتماعيَّة.

لا غرابة من اقتصار مجال المُدَوَّنَة اللُّغَوِيَّة في هذه الأيام على أدواتٍ معيَّنة دون غيرها، أو على مُدَوَّنَة لُّغَوِيَّة شَبَكِيَّة دون مُدَوَّنَة أُخرى، أو على المقاييس الأولى لتكرارات الكلمات ومقاييس التَّصاحب؛ لأنَّ معظم الأبحاث العربيَّة إلى يومنا هذا مقيدةٌ بهذه الحدود، وهو قيدٌ يعود سببه بالدرجة الأولى إلى عدم وجود مصادر عربيَّة تُفيد المهتمِّين بتطبيقات لُّغَوِيَّات المُدَوَّنات ومعالجة اللغة الطَّبِيعِيَّة.

سأعرِّف المُدَوَّنَة اللُّغَوِيَّة، وسأذكرُ مصادرها المتعدِّدة، وطرائقَ بنائها المختلفة باختلاف أنواع المُدَوَّنات، وسأعرِّج إلى أفضل أدوات معالجة المُدَوَّنات اللُّغَوِيَّة العربيَّة، وسأكتفي في التطبيقات التحليليَّة في هذا الباب بأداة واحدة^(١)؛ وهي أدوات لانكستر الإحصائيَّة على الشبكة (Lancaster Stats Tools Online)، إلى جانب أداة غَوَّاص في قليلٍ من المواضع.

وفضِّلْتُ هذه الأدوات دون غيرها؛ لأنَّنا لو نظرنا إلى جميع أدوات معالجة المُدَوَّنات اللُّغَوِيَّة؛ لألفيناها أقلَّ من هذه الأدوات من ناحية تنوع خيارات المعالجة، كأن تكون أقلَّ من حيث مُعاملات الإحصاء للتَّصاحب اللَّفْظِي، أو من حيث التَّحليل العام للمدونة اللُّغَوِيَّة لتكرار الكلمات والتكرارات النَّسَبِيَّة لها، ونسبة الكلمات النَّوعِيَّة إلى الكلمات الفِعْلِيَّة (type-token ratio)، أو من حيث عدم إتاحة خاصيَّة حفظ نتائج كلِّ وظائف وخيارات المعالجة في الأداة. وستُستخدم في عرض جُلِّ أساليب التَّحليل الإحصائي في فصول

(١) حول أدوات معالجة المُدَوَّنَة اللُّغَوِيَّة العربيَّة الأخرى، انظر: المجيلول، سلطان. البحث اللُّغَوِي في المُدَوَّنات العربيَّة الحاسوبية بين الممكن والمحتمل والمأمول. في: المُدَوَّنات اللُّغَوِيَّة العربيَّة بناؤها وطرق الإفادة منها. مركز الملك عبدالله الدولي لخدمة اللغة العربيَّة (مركز الملك عبدالله بن عبدالعزيز للتخطيط والسياسات اللُّغَوِيَّة حاليًّا)، الرياض، الطبعة الأولى، ٢٠١٥، الصفحات ٢٤٣-٢٥٥.

هذا الباب أدوات لانكستر الإحصائية (Lancaster Stats Tools) دون بقية الأدوات؛ لأنَّ الهدف -كما أسلفت القول في المقدمة- هو إفادة القارئ بأفضل إجراءات التحليل وأيسرها ممارسةً، وأدوات لانكستر الإحصائية من أكثر الأدوات شموليةً، ولا حاجةً إلى استعراض استخدامات كلِّ الأدوات التي تنقُصها الإمكانات الإحصائية المهمة لمعالجة المُدَوَّنات اللُّغَوِيَّة.

أَوَّلًا: تعريف المُدَوَّنَة اللُّغَوِيَّة

ليس هناك اختلاف في تعريف المُدَوَّنَة اللُّغَوِيَّة^(١). هي ببساطة نصوصٌ لُغَوِيَّةٌ مكتوبةٌ أو منطوقةٌ مُحوسَّبةٌ، وكلمة (محوسبة) هي أساس المُدَوَّنَة اللُّغَوِيَّة. أما لُغَوِيَّات المُدَوَّنَة (الحَاسُوبِيَّة)؛ فهي العلم الذي يدرس ويحلُّ اللغة الطَّبِيعِيَّة. وقد مرَّت المُدَوَّنات اللُّغَوِيَّة بثلاث مراحل منذ ظهور أول مُدَوَّنَة لُغَوِيَّة في عام ١٩٦١م، وهي مُدَوَّنَة (براون) المتاحة في اللغة الإنجليزِيَّة، التي احتوت على مليون كلمة^(٢).

المرحلة الأولى: مرحلة التأسيس التي قامت على جمع النُصوص اللُّغَوِيَّة كعيناتٍ لُغَوِيَّة. وأقرب مثال لهذه المرحلة للغة العَرَبِيَّة هو مُدَوَّنَة^(٣) (arabiCorpus).

المرحلة الثَّانِيَّة: مرحلة تطوير أدوات المعالجة، إمَّا في المُدَوَّنات اللُّغَوِيَّة أو للمدوَّنات اللُّغَوِيَّة. والفرق بينهما هو أنَّ الأدوات في المُدَوَّنات اللُّغَوِيَّة تكون مدمجة داخل المُدَوَّنَة الشبكيَّة، وهي أدوات لا تُتيح إلا البحث في عيِّنات نصوص تلك المُدَوَّنَة؛ مثل المُدَوَّنَة

(١) حول هذه التعريفات، انظر: صالح، محمود إسماعيل. (٢٠١٥). المُدَوَّنات اللُّغَوِيَّة وكيفية الإفادة منها. في: المُدَوَّنات اللُّغَوِيَّة العَرَبِيَّة بناؤها وطرق الإفادة منها. مركز الملك عبدالله الدولي لخدمة اللغة العَرَبِيَّة (مركز الملك عبدالله بن عبدالعزيز للتخطيط والسياسات اللُّغَوِيَّة حاليًّا)، الرياض، الطبعة الأولى، ٢٠١٥، الصفحات ١٩-٢١.

(٢) مكانري، توني، وأندرو هاردي. لُغَوِيَّات المُدَوَّنَة الحَاسُوبِيَّة: المنهج والنظرية والتطبيق. ترجمة: سلطان المجبول. الرياض: دار جامعة الملك سعود للنشر، ٢٠١٦، صفحة ١٨٢.

(3) Parkinson, D. (2001). arabiCorpus. Retrieved October 24, 2022, from <https://arabicorpus.byu.edu>.

اللُّغَوِيَّة العَرَبِيَّة لمدينة الملك عبدالعزيز للعلوم والتقنية^(١). أما الأدوات للمُدَوَّنات اللُّغَوِيَّة؛ فهي تطبيقات قائمة بذاتها، وقد بُنيت فيها أدوات معالجة المُدَوَّنَة دون نصوص، وتحتاج إلى أن يجمع المحللون تلك النُصُوص لغرض التحليل، وتُسمّى هذه المُدَوَّنات التي تُجمع من قبل المستخدمين بمدونة الاكتفاء الذاتي (do-it-yourself corpus)، وتُختصر غالباً بـ (DIY corpus)، ومثل هذه الأدوات أداة غواص^(٢) (الشكل ١). ونجد في أدوات هذه المرحلة خاصية الاستعلام والبحث عن الكلمة وحدها، أو عن الكلمة ومتصاحباتها، وعن تكراراتها الحقيقية والنسبية، وعن إظهار الكشافات السياقية (أسطر تتضمّن الكلمة المراد كشفها والكلمات السابقة واللاحقة لها)، وعن إحصاءات التصاحبات اللَّفْظِيَّة.



شكل ١: واجهة أداة غواص (أداة لمعالجة المُدَوَّنات اللُّغَوِيَّة العَرَبِيَّة)

(١) مدينة الملك عبدالعزيز للعلوم والتقنية. المُدَوَّنَة العَرَبِيَّة (المُدَوَّنَة اللُّغَوِيَّة العَرَبِيَّة لمدينة الملك عبدالعزيز للعلوم والتقنية). تاريخ الاسترداد ٢٤ أكتوبر، ٢٠٢٢، من: <https://corpus.kacst.edu.sa>.
(٢) غواص: أداة لمعالجة المُدَوَّنات اللُّغَوِيَّة العَرَبِيَّة (النسخة ٤,٦). تاريخ الاسترداد ٢٤ أكتوبر، ٢٠٢٢، من: <https://sourceforge.net/ghawasv4>.

المرحلة الثالثة: مرحلة البَيَّانات اللُّغَوِيَّة واللُّوحات التَّفَاعِلِيَّة، وهي مرحلة تعتمدُ على ما يزيدُ على أدوات المعالجة في المرحلة الثانية. من أمثلة أدوات معالجة البَيَّانات اللُّغَوِيَّة أدوات (لانكستر) الإِحصائيَّة^(١)، التي اعتمدت على لغة البرمجة (R) في التَّحليل اللُّغَوِيّ الإِحصائيّ، ووُفِّرت كأداة شبكية جاهزة لا تتطلب معرفةً أو استخداماً لأكواد (R). أما من أمثلة اللُّوحات التَّفَاعِلِيَّة فأدوات (فويانت^(٢)) (Voyant Tools) (الشكل ٢)، فبمجرد تحميل أو لصق النّص في هذه الأداة والبدء بمعالجتها، تُظهر معلوماتٍ عديدةً عن النّص الخام، مثل الارتباطات بين الكَلِمات، واستخراج الموضوعات، وسحابة الكَلِمات.



شكل ٢: واجهة فويانت وواجهة بعض النّتائج لتحليل مُدَوَّنَةِ الْقُرْآن الكريم

ثانياً: أهميّة المُدَوَّنات اللُّغَوِيَّة

للمدوّانات اللُّغَوِيَّة أهميّةٌ للدراسات التَّجريبِيَّة (experimental)، والعملِيَّة (empirical)، كيف لا ومادّتها اللغة التي تُعدّ الوسيط الأساس للمعارف، سأوجزُ في الآتي الاتجاهات

(١) أدوات (لانكستر) الإِحصائيَّة الشبكية. تاريخ الاسترداد ٢٤ أكتوبر، ٢٠٢٢، من: <http://corpora.lancs.ac.uk/stats/toolbox.php>. شُرحَت التَّطبيقات الإِحصائيَّة لهذه الأدوات في كتاب ألفه (Vaclav Brezina)، وقد تُرجم إلى العَرَبِيَّة. انظر: بريزينا، فاكلاف. علم الإحصاء في لُغَوِيَّات المُدَوَّنَةِ الحَاسُوبِيَّة. ترجمة: سلطان المجيلول. دارجامعة الملك سعود للنشر، الرياض، الطبعة الأولى، ٢٠٢١.

(2) Sinclair, S. & Rockwell, G. (2022). Voyant Tools [v. 2.5.3]. Retrieved October 24, 2022, from <https://voyant-tools.org>.

الحديثة منذ مطلع القرن الحادي والعشرين للدور الأساس الذي تؤديه المدونات اللغوية في العلوم.

أ. اللغويات التطبيقية والتخطيط اللغوي والسياسة

للغويات التطبيقية فروعٌ تتمثل في اللغويات التعليمية، وتعليمية اللغات، وما يتعلق بها من مواد التعليم وفعل التعليم، وفي اللغويات النفسية، وما يتعلق بها من دراسات للجوانب العقلية، ولجوانب معالجة الدماغ عند تمثيل اللغة وتهئية الكلام، وفي اللغويات الاجتماعية، وما يتعلق بها من دراسات عن اللغة في المجتمع، وفي التخطيط اللغوي، وما يتعلق به من دراسات في تخطيط الوضع اللغوي، وتخطيط المدونة اللغوية، وتخطيط الاكتساب اللغوي، وتخطيط المعجم، وما يتضمن هذه الأنواع من التخطيط من عنصرين أساسيين يتمثلان في التنفيذ والقبول^(١).

هل تفيّد المدونات اللغوية في هذه المجالات؟ الجواب: نعم، ودليل ذلك بيّن في الحجم الهائل من الدراسات، في تلك الفروع التي اعتمدت على تطبيقات معالجة المدونة اللغوية. وحصرُ كل هذه الدراسات ليس مجالنا هنا، لأن عدد الأدوات يزيد عن ٢٦٠ أداة^(٢)، ناهيك عن تلك الدراسات التي اعتمدت على لغات البرمجة مثل (البايثون)،

(١) تأخذ المؤسسات حيز التنفيذ (implementation) لسياسات الدولة في أعمال التخطيط. أما القبول (acceptance)؛ فهو يعتمد على قبول المجتمع لما خطط له. تُعدّ عوامل التنفيذ والقبول أساسية، بل حاسمة، عند إعادة تقييم أي وضع لغوي في التخطيط اللغوي والسياسة. نوقشت هذه العوامل قديماً، وعُرفت بنظرية (هوجين Haugen's Theory)، ولن يرغب في الاطلاع على أمثلتها الواقعية النظر إلى الدراسات الآتية:

Haugen, E. (1966). Dialect, language, nation. American Anthropologist, 68, 922–935.
Haugen, E. (1972). Language planning, theory and practice. In E. Haugen (Ed.), The ecology of language: Essays (pp. 287–295). Stanford: Stanford University Press.
Haugen, E. (1987). Blessings of Babel. Bilingualism and language planning. Problems and pleasures. Berlin, New York: Mouton de Gruyter.

(٢) للاطلاع على هذه الأدوات انظر في الرابط الآتي: <https://corpus-analysis.com/> (تاريخ الاسترداد ٢٤ أكتوبر، ٢٠٢٢).

و(الآر)، وغيرهما. لكن يكفي أن أشير إلى العدد الذي تناول أداة واحدة فقط، وهي أدوات (وورد سميث WordSmith Tools)، والتي بلغت ما يقارب ٦٠٠ دراسة؛ من مقالاتٍ علميّة، وأطروحات جامعيّة في اللُّغويّات التّعليميّة، واللُّغويّات النفسيّة، واللُّغويّات الاجتماعيّة، والتّخطيطات اللُّغويّة والسياسيّة^(١). وصار العمل البحثي في هذه الفروع يعتمد كثيراً على الدّراسات التّجريبية والدّراسات العمليّة، التي تحوّلت من البيانات التّناظريّة (analogical data) إلى البيانات الرّقميّة^(٢) (digital data). لم يعد من الجدوى -على سبيل المثال- العمل على التّخطيط اللُّغويّ من دون أدوات ومناهج وتطبيقات المدوّنة اللُّغويّة، فالعمل فيه من دونها مثل العمل على التّخطيط في الاستثمار والمضاربة في السوق الماليّة من دون أدوات تحليليّة عن اتجاهات السوق، والتّنبؤ بأدائها.

ب. العلوم الإنسانيّة والاجتماعيّة

بدأت بدايات ارتباط المدوّنة اللُّغويّة في العلوم الإنسانيّة والاجتماعيّة مع ظهور الاهتمام بما يُسمّى بالإنسانيّات الرّقميّة (digital humanities)، وبالبحث الاجتماعيّ الرّقميّ على وجه الخصوص^(٣). كانت البداية الأكثر تأثيراً في عام ٢٠١٤م، عندما نشر باحثون ورقة علميّة عنوانها: (البرهنة التّجريبية الواسعة النّطاق في شبكات التّواصل الاجتماعيّ)^(٤)، شملت تحليل مئآت آلاف المستخدمين في شبكة التّواصل (فيسبوك)، وحظيت باهتمام الباحثين، وتضمّن هذا النّوع من التّحليل أساليب تحليليّة غير

(١) موقع حصر الدّراسات التي اعتمدت على أدوات وورد سميث. تاريخ الاسترداد ٢٤ أكتوبر، ٢٠٢٢، من: <https://lexically.net/wordsmith/research>.

(٢) الفرق بين البيانات التّناظريّة والبيانات الرّقميّة في العلوم الاجتماعيّة هو أنّ الأولى لا تعتمد على أي أداة من أدوات الذّكاء الاصطناعيّ في الجمع والتّحليل، بينما تعتمد الثانية على ذلك. من أمثلة البيانات التّناظريّة: الاستبانات.

(3) Veltri, G. A. (2020). Digital Social Research. Medford, MA: Polity Press.

(4) Kramer, A. D. I., Guillory, J. E., & Hancock, J. T. (2014). Experimental evidence of massive-scale emotional contagion through social networks. Proceedings of the National Academy of Sciences, 111(24), 8788-8790.

مسبوقه؛ أولاً: أُجرى التَّحْلِيل على مئات آلاف المستخدمين. ثانياً: جرى التَّحْلِيل على بياناتٍ لُغَوِيَّةٍ ضخمة. ثالثاً: جرى التَّحْلِيل دون علم المستخدمين. وقد يكون هذا النوع من البيانات إما بياناتٍ خفيةً (unobtrusive)، لا يُعرف أصحابها أو لا يُهتم بتحليلهم، كون الاهتمام منصباً على النصّ دون غيره، وإما بياناتٍ ظاهرةً (obtrusive) تتضمن بيانات منتجي تلك النصوص من أسماء، وأعمار، وخلفيات تعليمية، وثقافية، وعرقية، إلى آخره. ولا تقتصر معالجة المُدَوَّنة اللُّغَوِيَّة في العلوم الإنسانيَّة والاجتماعية على اللغة في الويب والتواصل الاجتماعي، بل على كُلِّ مَدَوَّنة رَقْمِيَّة مرقمنة في كلِّ مجالات هذه العلوم؛ كالدين والأدب والثقافة والتاريخ والأنثروبولوجيا. أما أدوات المعالجة؛ فتكون إما باستخدام أدوات معالجة المُدَوَّنة اللُّغَوِيَّة؛ مثل غواص وغيره، أو بتطبيقات معالجة اللغة الطَّبِيعِيَّة.

ج. تطبيقات معالجة اللغة الطَّبِيعِيَّة

ظهرت هذه التَّطْبِيقَات من مشاريع معالجة اللغة الطَّبِيعِيَّة، التي تقوم على تدريب الآلة على فهم النصّ اللُّغَوِيّ مثل فهم الإنسان، وتُعتبر معالجة اللغة الطَّبِيعِيَّة حقلاً من حقول الذكاء الاصطناعي، وتعتمد على ثلاثة مناهج لخوارزميات معالجة اللغة الطَّبِيعِيَّة، وهي منهج القواعد الذي تعتمد عليه الآلة في التحليل، ومنهج التَّعْلُم الآلي الذي تعتمد فيه الآلة على احتمالات رياضية تُساعد في تأدية مهام المعالجة لبياناتٍ جديدة، ومنهج التَّعْلُم العميق الذي تتعلَّم به الآلة فهم المكونات الدقيقة؛ مثل الشبكات العصبية في دماغ الإنسان.

هناك مرحلتان في معالجة اللغة الطَّبِيعِيَّة؛ الأولى: مرحلة التَّحْلِيل التي فيها يدرب الحاسوبيون الآلة على تحليل اللغة وفهم خصائصها. والثانية: مرحلة التَّوْلِيد التي فيها يُنتج الحاسوبيون المخرجات، ودقّة أداء الآلة في المعالجة، وهي المرحلة التي تُنتج تطبيقات معالجة اللغة الطَّبِيعِيَّة. وتتطوّر المرحلة الثانية بتطوّر المرحلة الأولى في كلِّ مدّة زمنيَّة، معتمدةً في الآونة الأخيرة على منهج تعلّم الآلة ومنهج التَّعْلُم العميق. من

أكثر تطبيقات معالجة اللغة الطَّبِيعِيَّة انتشاراً في أيامنا هذه هي أدوات تنقيب النُّصوص والبيانات اللُّغَوِيَّة، وتحليل المشاعر، واستخراج النُّصوص، واستخراج الموضوعات، ونمذجة الموضوعات، وتصنيف النُّصوص، وتلخيص النُّصوص، والترجمة الآليَّة، والكتابة الآليَّة، وفلترة الرِّسائل البريدِيَّة غير المهمَّة، والتَّصحیح الإملائي، والتعرُّف إلى الكلام، وروبوتات المحادثة والدعم الافتراضي، وذكاء الأعمال في التَّسويق (فهم السلوك اللُّغَوِي للمستهلكين). وما يهمُّ الباحثين في العلوم اللُّغَوِيَّة والإنسانيَّة والاجتماعيَّة هنا هو فهم آليَّات المعالجة الأساسيَّة للغة العَرَبِيَّة الطَّبِيعِيَّة؛ من أجل تحقيق ممارسات متقدِّمة في معالجة المُدوَّنة اللُّغَوِيَّة، حيث لا يُستغنى عنها في تطبيقات المعالجة الآليَّة للغة وتنقيب النصوص والبيانات اللُّغَوِيَّة (موضوع فصول الباب الثَّاني من هذا الكتاب).

ثالثاً: مصادر المُدوَّنة اللُّغَوِيَّة ومعايير الجمع^(١)

يمكن جمعُ كلِّ مصدرٍ يتضمَّن لغةً، سواءً كانت نصوصُ هذه اللغة من مصادر رَقَمِيَّة، أم من صفحات الشبكة العنكبوتيَّة (الويب)، أم من اللغة الشفهية المنطوقة. أما معايير الجمع فتتحدَّد من ثلاثة أهداف رئيسية:

الهدف الأول: الرصد (monitor)، وبه يُجمعُ كلُّ ما أمكن ويُمكن وسيُمكن جمعه رَقَمِيًّا من النُّصوص اللُّغَوِيَّة، وتُمثِّل واقع النمو اللُّغَوِي في جميع الأزمنة والأوعية والمجالات والموضوعات.

الهدف الثَّاني: المرجعية، وبه تُجمعُ مُدوَّنة مرجعيَّة (reference)، تُستخدم بوصفها المعيار أو المقياس لاستخدامها في بناء تطبيقات تقنيَّات اللغة، ويتحدَّد معيارها بحسب التَّطبيقات التي يحتاجها المجتمع اللُّغَوِي.

(١) لا حاجة إلى ذكر تفاصيل أنواع المُدوَّنة اللُّغَوِيَّة ومعايير جمعها، وقد أكتفي بالخطوط العريضة. للاطلاع على التفاصيل: مكانري، توني، وأندرو هاردي. لُغَوِيَّات المُدوَّنة الحَاسُوبِيَّة: المنهج والنظريَّة والتَّطبيق. ترجمة: سلطان المجيلول. دار جامعة الملك سعود للنشر، الرياض، ٢٠١٦، الصفحات ٣٨-١٠.

الهدف الثالث: الاستناد إلى عيّنة أو عيّنات، وبه تُجمع مُدَوّنة لغويّة محدودة النُصوص، وقد تُجمع هذه النُصوص بعناية فائقة لتحقيق الأغراض من مضمونها في الأبحاث، ولتعميمها على المجموع اللغوي، أو قد تُجمع دون عناية؛ فينتهز فيها بالجمع رصد كل ما يُمكن رصده.

يقوم الإحصاء على البيانات اللغويّة التي تُهيأ من النُصوص اللغويّة الخام، وتُتضمّن هذه البيانات اللغويّة معلومات تُقاس. يُطلب من كل باحث أن يعرف طرق إعداد البيانات اللغويّة، وعلام تحتوي من مُتغيّرات، مادامت المادة التي ستُحلّل هي اللغة ونصوصها سواء المكتوبة أم المنطوقة.

رابعاً: أدوات معالجة المُدَوّنات اللغويّة العربيّة

تتعدّد الأدوات، وتتفاوت خصائص معالجتها للنصّ العربيّ تفاوتاً نسبياً، لكنها تشترك في معظم وظائف تلك الخصائص؛ كاستخراج تكرار الكلمات النوعيّة، وتكرار الكلمات الفعلية، والتكرار النسبي للكلمات الفعلية، وبعض الإحصاءات المتعلقة بالتصاحب اللفظي. ومن أهمّ هذه الأدوات نظراً لتعدد خصائص ووظائف المعالجة فيها؛ ما يأتي:

١. محرّك التّخطيط^(١) (Sketch Engine)، هو أداة شبكيّة ضخمة، تتضمّن مُدَوّنات لغويّة شبكيّة وغير شبكيّة للغات عديدة، ويهتمنا فيها وظائف معالجة اللغة للمدونة اللغويّة الخاصة بالمستخدم.

(١) محرّك التّخطيط. تاريخ الاسترداد ٢٤ أكتوبر، ٢٠٢٢، من: <https://www.sketchengine.eu>. شهدت هذه الأداة مراحل عديدة من التطوير والبناء، ويُمكن الاطلاع على الأوراق العلميّة في كلّ مراحل التطوير، بالإضافة إلى كلّ خصائص البناء وأدواتها، في الرابط الآتي: <https://www.sketchengine.eu/bibliography-of-sketch-engine/#toggle-id-1>

٢. أدوات معالجة اللغة العربية الطَّبِيعِيَّة (غواص) والمشذَّب العَرَبِيّ لتنظيف النُّصُوص العَرَبِيَّة^(١).

٣. أدوات (لانكستر) الإِحصَائِيَّة^(٢) (Lancaster Stats Tools)، وهي أدواتٌ شبكِيَّةٌ تتميز بسهولة الاستخدام للغويين أو المهتمين بالتحليل الإِحصَائِيّ للمدونة اللُّغَوِيَّة.

يُتيح محرِّك التَّخْطِيط الاشتراك المجانيّ مدَّة شهرٍ، وهو أداةٌ شبكِيَّةٌ تَتَضَمَّنُ مُدَوَّنَاتٍ ويب لأكثر من سبعين لغة، منها مُدَوَّنَةُ الويب للغة العَرَبِيَّة التي تُعرَفُ باسم (arTenTen12)، وتُتيح الأداة إنشاء مُدَوَّنَةٍ لكلِّ مستخدمٍ، عن طريق تحميل المُلَفَّات النَّصِّيَّة التي يرغبُ المستخدم في تحليلها ومعالجتها، وبعد إتمام الإنشاء؛ يُمكن للمستخدم أن يستكشف هذا النصَّ بإظهار قوائم الألفاظ (الكَلِمَات وتكراراتها)، والكشافات السياقيَّة، وإحصاءات التَّصاحِب اللَّفْظِيّ المشهورة. وما يُميِّز هذه الأداة هو أن نتائج كشافاتها السياقيَّة تُظهر المتتابعات اللَّفْظِيَّة^(٣) مَقْطُوعَةً، فتجد في النِّتَاج مثلاً ظهور حرف العطف (الواو) أو حرف الجر (الباء) منفصلاً عن الكلمة التَّالِيَةِ له. وكل هذه الخصائص موجودةٌ في أداة غواص عدا التَّقْطِيع الآليّ. أما أدوات (لانكستر) الإِحصَائِيَّة فتتَضَمَّنُ كُلَّ خصائص وخيارات التحليل المدوَّنيّ، بالإضافة إلى معاملات

(١) غواص: أداة لمعالجة المُدَوَّنَات اللَّغَوِيَّة العَرَبِيَّة (النسخة ٤,٦). تاريخ الاسترداد ٢٤ أكتوبر، ٢٠٢٢، من: <https://sourceforge.net/ghawwasv4>؛ المشذَّب العَرَبِيّ، تاريخ الاسترداد ٢٤ أكتوبر، ٢٠٢٢، من: https://sourceforge.net/Almoshatheb_Alarabi.

(٢) أدوات (لانكستر) الإِحصَائِيَّة الشبكية. تاريخ الاسترداد ٢٤ أكتوبر، ٢٠٢٢، من: <http://corpora.lancs.ac.uk/stats/toolbox.php>. شُرِحت التَّطْبِيقَات الإِحصَائِيَّة لهذه الأدوات في كتاب ألفه (Vaclav Brezina)، وقد ترجمته إلى العَرَبِيَّة. انظر: بريزينا، فاكلاف. علم الإحصاء في لُغَوِيَّات المُدَوَّنَةِ الحَاسُوبِيَّة. ترجمة: سلطان المجيلول. دار جامعة الملك سعود للنشر، الرياض، ٢٠٢١.

(٣) «المتتابعات اللَّفْظِيَّة» مصطلح يُشير إلى سلسلة من الكَلِمَات المتتابعة، ويدلُّ على الهيئة التي تنال حيزاً مستقلاً عن سابقها ولحقها بمسافةٍ، ومصطلحه الأجنبي n-grams، ومفرده n-gram الذي يعني (المتتابع اللَّفْظِيّ)، وقد عرِّبته بـ (نغرام)، وجمعه: نغراميات.

إحصائية إضافية لقياس معنوية التصاحبات اللفظية، ناهيك عما قد دُمج فيها من أدوات إحصائية أخرى؛ مثل تمثيل البيانات (data visualization)، والانحدار اللوجستي للمتغيرات اللغوية التصنيفية، وتحليل الارتباط، ومقارنة المجموعات، وتحليل التناظر، والتجميع، وتحليل التغير اللغوي عبر الزمن، وغيرها مما سنعرضه بالتطبيق في جميع مباحث فصول هذا الباب.

الفصل الأوّل

الإحصاءات وأنواع تمثيل البيانات

وضعتُ في الملحق (أ) بيانات أسماء سور القرآن الكريم، وترتيب نزولها، وترتيبها في المصحف الشريف، وعدد الآيات والكلمات والحروف، وزمن النزول (مكيّة أم مدنيّة)، ووجود السجدة من عدم وجودها بين السور.

سأبين في هذا الفصل أنواع المتغيّرات في البيانات اللُّغَوِيّة في المبحث الأوّل، ومفهوم التكرار والتوزيع والتنوّع والكثافة والتكرار المعايير في المبحث الثاني، والإحصاءات الوصفية في المبحث الثالث، والإحصاءات الاستدلالية^(١) في المبحث الرابع، ثم أنواع الأشكال البيانية وتمثيلها من البيانات اللُّغَوِيّة في المبحث الخامس.


المبحث الأوّل: البيانات اللُّغَوِيّة

يُراد بالمُدَوْنَة اللُّغَوِيّة النَّصّ اللُّغَوِيّ، أما البيانات اللُّغَوِيّة فهي جدولٌ خلايا يتضمّن حقائق عن تلك المُدَوْنَة اللُّغَوِيّة، وهي حقائق يُعبّر عنها بمصطلح مُتَغَيَّرَات (variables). قد يجد الباحث بياناتٍ لُغَوِيّةً مجدولةً وجاهزةً، تتضمّن حقائق عن نصّ لُغَوِيٍّ ما، وهذا نادرٌ في مصادر اللغة العربيّة المفتوحة. ويعمل الباحث في الأغلب على إعداد هذه البيانات، وما تتضمنه من مُتَغَيَّرَات، وتنقسم هذه المتغيّرات إلى قسمين؛ الأوّل: مُتَغَيَّرَات لُغَوِيّة. والثاني: مُتَغَيَّرَات تأويليّة. وتتضمّن المتغيّرات اللُّغَوِيّة السّمات اللُّغَوِيّة؛ مثل الكلمات (الأسماء والأفعال والضمائر إلخ)، أو العبارات والجمل (الجملة الاسميّة والجملة الفعليّة). أما المتغيّرات التأويليّة فتعبّر عن سياقات تلك السّمات،

(١) تنويه مهم للقارئ: عندما تقف على المواضيع التي فيها ذكر قياسات حجم التأثير للإحصاءات الاستدلالية في كلّ مواضع الباب الأوّل؛ فمن المهم أن تعرف القيم المعلنة في كلّ إحصاء من تلك الإحصاءات، وهي قيمٌ تخبرك عن حجم الأثر، وهل هو كبيراً أم متوسطاً أم صغيراً، وذلك هو السبيل إلى تفسير النتيجة، وهل الأثر دالٌّ أم غير دالٍّ.

كأن نقيس سمة الجنس (ذكر وأنثى)، أو سمة الأوعية كوعاء الصحف والكتب والمجلات، أو سمة المجالات كالمجلات المتفرعة في كل وعاء، مثل مجال المقالات، ومجال الأخبار داخل وعاء الصحف، أو سمة الموضوعات المتفرعة من كل مجال، أو سمة المواقع الجغرافية للنص، أو سمة أزمنة النص.

وتكون المتغيرات اللغوية والمتغيرات التأويلية إما متغيرات اسمية (nominal)، أو متغيرات ترتيبية (ordinal)، أو متغيرات مقياسية (scale). وتُسمى المتغيرات الاسمية والترتيبية بالمتغيرات الفئوية، وتكون المتغيرات المقياسية إما متغيرات منفصلة أو متقطعة (discrete)؛ أي: أعداد محدودة، أو متغيرات متواصلة (continuous)؛ أي: أعداد غير محدودة^(١). في الشكل (٣) توضيح لتقسيمات هذه المتغيرات في البيانات.



شكل ٣: المتغيرات في البيانات (اللغوية)

(١) على سبيل المثال: لو كان لدينا عشرة كتب، فأعداد الفصول في كل كتاب تكون متغيرات منفصلة؛ كونها محدودة، وتشير إلى قيم فردية محددة. أما أعداد الكلمات في كل فصل أو كتاب؛ فهي متغيرات متواصلة؛ كونها غير معروفة، وتشير إلى قيم غير متناهية. وقد تكون المتغيرات المنفصلة أيضاً متغيرات ثنائية (مثل: النكرة والمعرفة)، أو أعداد في المتغيرات الفئوية (الاسمية أو الترتيبية). هل ما زال هناك غموض في هذه المتغيرات في البيانات اللغوية؟ إذا كان الجواب نعم؛ فتأكد بأن وضوحها مرهون بالتطبيق والممارسة، فكلما زاد اطلاعك على أنواع عديدة من مجموعة البيانات اللغوية (linguistic datasets)؛ بانت الفروقات بيانياً جلياً بينها.

تُمثّل المُتَغَيَّرَاتُ الاسميّةُ فئاتٍ مختلفة تُعبّر عن حالاتٍ غير متسلسلة؛ مثل الجنس (الذكر والأنثى)، وتُمثّل المُتَغَيَّرَاتُ الترتيبيةُ فئاتٍ مختلفة تُعبّر عن حالاتٍ متسلسلة؛ مثل مراحل العمر (المراهقة والبلوغ والشيخوخة). أما المُتَغَيَّرَاتُ المقياسيةُ فهي قيمٌ حسابيةٌ تُمثّل تكرارات ملحوظة أو تكراراتٍ نسبيةً أو قيمًا إحصائيةً. وغالبًا ما تتم في أدوات المعالجة الإحصائية الإشارة إلى المُتَغَيَّرَاتِ الاسميّةِ والترتيبية بأرقامٍ فئوية، كأن نضع للذكر رقم (١)، وللأنثى رقم (٢)، ونضع للمراهقة رقم (١)، وللبلوغ رقم (٢)، وللشيخوخة رقم (٣). في الشّكل (٤) تمثيلٌ لهيكلة بياناتٍ لغوية افتراضية لهذه المُتَغَيَّرَاتِ، تتضمّن رواياتٍ مكتوبةً من ١٠ كُتّاب، وجنس كل كاتب، ومرحلته العمرية، وعدد تكرار الأسماء والأفعال والضّمائر في كلّ رواية.

الكاتب	الجنس	المرحلة العمرية	الأسماء	الأفعال	الصفات
هند	2	3	26740	956	287
عبدالعزیز	1	3	20121	934	278
مشاعل	2	2	6900	910	143
شيخة	2	2	6899	893	189
محمد	1	2	5008	610	178
الجوهرة	2	2	432	676	156
عبدالله	1	1	1112	198	67
خالد	1	1	1007	201	89
سارة	2	1	998	198	68
نور	2	1	108	99	98

شكل ٤: شكل بيانات الأعمدة والصفوف المُتَغَيَّرَاتِ لغوية افتراضية

وأنواع المُتَغَيَّرَاتِ في هذا الشّكل هي على النحو الآتي:

- المُتَغَيَّرَاتُ التأويلية: الجنس ومرحلة العمر.
- المُتَغَيَّرَاتُ اللغوية: الأسماء والأفعال والضّمائر.

- المتغيّر الاسمي: الجنس.
- المتغيّر الترتيبي: مرحلة العمر.
- المتغيّر المقياسي: تكرارات الأسماء والأفعال والضمائر.

بقي مفهوم المتغيّر المُستقلّ (independent variable)، ويُسمى -أيضاً- المتغيّر التأويلي (explanatory variable) والمتغيّر التابع (dependent variable)، والفرق الفاصل بينهما هو أنّ المتغيّر التابع يتأثر ويتغيّر ويتبدّل بالمتغيّر المُستقلّ، والعكس غير صحيح.

لو أردنا أن نهَيّ بياناتٍ لغويّةً تتضمّن هذه الأنواع من المتغيّرات من مدوّنة القرآن الكريم^(١)؛ بوصفها المدوّنة محلّ التّطبيق الإحصائيّ لباب الإحصاء اللّغويّ من هذا الكتاب؛ فكيف سيكون شكلُ هيكلية البيانات؟ الجواب: نحتاج إلى التّفكير الإحصائيّ عند استخدام كلّ نوعٍ من أنواع الإحصاءات اللّغويّة. كيف نفكر إحصائياً؟ لنمعن النّظر دائماً فيما يمكن أن يكون متغيّراتٍ لغويّةً ومتغيّراتٍ تأويليّةً أوّلاً. المتغيّرات اللّغويّة

(١) تتوفر بيانات للقرآن الكريم في موقع (Kaggle)، تتضمّن رقم كلّ سورة حسب ترتيبها في المصحف الشريف، ورقم الآية في كلّ سورة، ونص الآية الكريمة: <https://www.kaggle.com/zusmani/the-holy-quran> (تاريخ الاسترداد ٢٤ أكتوبر، ٢٠٢٢). رأيت أن هذه البيانات ينقصها بعض المعلومات التي أحتاج إليها في التّحليل، مثل: تصنيف السّور من حيث مكان النزول (مكية ومدنية)، وترتيب نزول القرآن الكريم زمنياً، وقد تطلّب مثل هذا النقص البحث عن معلومات جديدة عن بيانات السّور وإدخالها في بيانات التّحليل. قد يتبادر سؤالٌ إلى ذهن الباحث عن إمكانات الحصول على البيانات اللّغويّة. يندر غالباً أن نجد بيانات لغويّة عربيّة جاهزة ومفتوحة المصدر. ويتطلب من الباحث في هذه الحالة أن يُعدّ هذه البيانات، ويُمكن جمع البيانات اللّغويّة المهيكلة بطرقٍ عديدة، منها ما هو برمجيّ (مثل: مكتبة Beautiful Soup في البايثون)، ومنها ما هو عن طريق أداةٍ شبكية جاهزة (مثل <https://www.parsehub.com>: تاريخ الاسترداد ٢٤ أكتوبر، ٢٠٢٢) تعمل على جمع النصوص والمعلومات عنها، وهيكلتها من مواقع الويب. وفي حال صعبت هذه الوسائل على الباحث؛ فمن أسهل الطرق هو أن يعتمد على أدوات معالجة المدوّنات اللّغويّة؛ مثل غواص (وورد سميث WordSmith Tools)، لتحويل النّص الخام إلى بيانات مهيكلة تتضمّن الكلمات أو العبارات، وتتضمّن المتغيّرات التي يريد الباحث قياسها.

عديدة، ولا تقتصر فقط على أقسام الكلام أو على أقسام الجمل، إذ يُمكن أن تكون موضوعاً نحوياً أو استعمالاً لُغَوِيّاً. إذن؛ نحتاج هنا إلى أن نفكر فيما نرغب قياسه إحصائياً من المُتَغَيَّرَات، وفي الآتي فكرة إحصائية من أجل التَّوضيح:

- المُتَغَيَّرَات التَّأْوِيلِيَّة الاسمية، وهي مُتَغَيَّرَات غير متسلسلة، أو لا تربطها علاقة هَرَمِيَّة، ومن الأمثلة الممكنة: السُّور المَكِّيَّة والسُّور المَدَنِيَّة.
- المُتَغَيَّرَات التَّأْوِيلِيَّة الترتيبية، وهي مُتَغَيَّرَات متسلسلة، وتربطها علاقة هَرَمِيَّة، ومن الأمثلة الممكنة: ترتيب سور القرآن الكريم حسب النزول.
- المُتَغَيَّرَات اللُّغَوِيَّة: استخدام النداء للناس (يا أيها الناس)، وللمؤمنين (يا أيها الذين آمنوا).
- المتغير المقياسي: التكرارات الملحوظة، أو التكرارات النَّسْبِيَّة، أو أي قيمة عددية، نضعها للمُتَغَيَّرَات اللُّغَوِيَّة.

بعد تحديد المُتَغَيَّرَات التي يُراد تحليلها، وإعداد بياناتها (الشكل ٥)، يتطلَّب بالضرورة أن نصوغ الأسئلة التي نقيسُ بها تلك المُتَغَيَّرَات. وفي الآتي مثالٌ لثلاثة أسئلةٍ محدَّدة:

السؤال الأول: هل هناك علاقةٌ بين السُّور المَكِّيَّة والسُّور المَدَنِيَّة (متغير تأويلي اسمي مستقل) وبين ترتيب نزول السُّور (متغير تأويلي ترتيبي تابع)؟

السؤال الثاني: هل هناك علاقةٌ بين السُّورَة المَكِّيَّة والسُّورَة المَدَنِيَّة (متغير تأويلي اسمي مستقل) وبين استخدام المنادى (متغير لُغَوِيّ مقياسي تابع)؟

السؤال الثالث: هل هناك علاقةٌ بين ترتيب نزول السُّور (متغير تأويلي ترتيبي مستقل) وبين استخدام المنادى (متغير لُغَوِيّ مقياسي تابع)؟

السورة	مكان النزول	ترتيبها في المصحف	الترتيب حسب النزول	عدد الآيات	يا أيها الناس	يا أيها الذين آمنوا
البقرة	مدنية	2	87	286	2	11
آل عمران	مدنية	3	89	200	0	7
النساء	مدنية	4	92	176	3	9
المائدة	مدنية	5	112	120	0	16
الأنعام	مكية	6	55	156	0	0
الأعراف	مكية	7	39	206	1	0
الأنفال	مدنية	8	88	75	0	6
التوبة	مدنية	9	113	129	0	6
...	...	...	...	...	...	...
...	...	...	...	...	...	...

شكل ٥: بيانات المتغيرين اللغويين (يا أيها الناس) و(يا أيها الذين آمنوا) من مُدَوَّنَةِ القرآن الكريم

سيُعتاد الباحث على طرائق تحديد المُتَغَيَّرَاتِ بأنواعها، وعلى طرائق قياس المُتَغَيَّرَاتِ الاسميَّةِ والترتيبيَّةِ والمقياسيَّةِ، وذلك ليس على قياس التكرار وحسب، بل على أنواع أخرى من الإحصاءات التي تردُّ في المباحث والفصول القادمة من هذا الباب، وسيُتجلَّى من هذا الاعتياد ازدياد ملحوظ في فهم أنواع المُتَغَيَّرَاتِ، وأسلوب توزيعها في أيِّ نصٍّ لغويٍّ.

المبحث الثاني: التَّكْرَارُ والتَّوْزِيعُ والتَّنَوُّعُ والكثافة

سيُشار هنا إلى حساباتٍ أوليَّةٍ تُجرى في بداية معالجة المُدَوَّنَةِ اللُّغَوِيَّةِ العَرَبِيَّةِ؛ وهي:

١. التَّكْرَارُ المطلق والتَّكْرَارُ النَّسْبِيَّ.
٢. الكلمة النَّوعِيَّةُ والكلمة الفِعْلِيَّةُ.
٣. التَّوْزِيعُ (distribution)، والتَّسْتُّ (dispersion).

٤. التَّنَوُّع المعجمي.

٥. الكثافة المعجمية.

٦. التكرار المعايير.

باستعمال أدوات (لانكستر) الإحصائية؛ يبلغ عدد الكلمات في القرآن الكريم ٧٧,٧٩٩ كلمة، وذلك باعتبار الرّسم الإملائي، أما باعتبار الرّسم العثماني فالعدد يبلغ ٧٧,٤٣٩ كلمة^(١). يتغير العدد في الرّسم الإملائي عند تقطيع (segmenting) الكلمات في المعالجة القبلية للنص، وهذا طبيعي، ويعود إلى شكل الكلمة الفعلية الذي ينال حيناً مستقلاً في الخطّ الكتابي، ويكون مفصّلاً بمسافة (الجدول ١)، كما يتغير عدد الكلمات الفعلية -أيضاً- في النصوص المشكّلة، باعتبار اختلاف الحركات للكلمة الواحدة.

جدول ١: الرّسم العثماني والرّسم الإملائي قبل التقطيع وبعد أسلوب معين من التقطيع

الآية	الرّسم	عدد الكلمات الفعلية
يُحْيِي خِذْ أَلْكِتَبْ بِقُوَّةٍ وَأَتَيْنَهُ الْحُكْمَ صَبِيًّا	العثماني	٧
يا يحيى خذ الكتاب بقوة وآتيناه الحكم صبيًّا	الإملائي	٨
يا يحيى خذ الكتاب ب قوة وآتيناه الحكم صبيًّا	الإملائي (مقطع)	١٠

(١) ذكر السيوطي في الإتيان قول الدّاني: «أجمعوا على أنّ عدد آيات القرآن ستة آلاف آية، ثم اختلفوا فيما زاد على ذلك، فمنهم من لم يزد، ومنهم من قال: ومئتا آية وأربع آيات، وقيل: وأربع عشرة، وقيل: وتسع عشرة، وقيل: وخمس وعشرون، وقيل: وست وثلاثون، كما أن الاختلاف في عدد الآيات قد نبع من اختلافه بين أهل المدينة ومكة والشام والبصرة والكوفة، ولهذه الاختلافات أسبابها الخاصّة بها، التي قد يكون مردّها إلى اجتهد الكتاب في وضع الفواصل عند سماعهم للنبي محمد -صلى الله عليه وسلم- في بداية مراحل كتابة القرآن. السيوطي. الإتيان في علوم القرآن، تحقيق: شعيب الأرنؤوط، مؤسسة الرسالة، دمشق، ٢٠٠٨، صفحة ١٤٧.

وأحوال التَّقْطِيع في النُّصُوص العَرَبِيَّة متباينةٌ، فهناك مقطّعات تفصل (أل) التعريف وغيرها من المباني الصرفيّة والنَّحْوِيَّة. وعلى اختلافنا في مسائل التَّقْطِيع من وجهة نظر نَحْوِيَّةٍ؛ إلاَّ أنَّه يتطلب من اللُّغَوِيِّ الإفصاح عن آليَّة التَّقْطِيع عندما تكون هناك آليَّة مدمجة في أداة من أدوات المعالجة؛ كي يتبيّن واقع حساب الكلِّمات في النصِّ، وكي تُبنى المعاملات الإحصائيَّة عليها؛ نظراً لاختلاف النَّتَاج نسبياً بين النُّصُوص المعالجة بالتَّقْطِيع والنُّصُوص المعالجة دونه.

وفيما يأتي تعريفات لهذه الحسابات الأولىَّة.

١. التَّكْرَار المطلق: هو تكرار الكلمة الفعليَّة في النصِّ، أو تكرار جميع الكلِّمات الفعليَّة في النصِّ. والتَّكْرَار النَّسْبِيّ: نسبة ورود الكلمة في كامل المُدَوَّنة، أو نسبة ورودها في كُلِّ معيارٍ محدّدٍ من الحجم، كأن يُقال: نسبة ورود الكلمة في كُلِّ ١٠٠٠ كلمة، أو في كُلِّ ١٠,٠٠٠ كلمة، أو في كُلِّ ١٠٠ ألف كلمة، أو في كُلِّ مليون كلمة.
٢. الكلمة النَّوْعِيَّة: الصِّيغة الفريدة، أي كُلِّ كلمةٍ فريدةٍ في تهجّتها من دون تكرار. والكلمة الفعليَّة: ورود كُلِّ صيغةٍ كما هي في كامل المُدَوَّنة مع تكراراتها.
٣. التَّوْزِيع والتَّشْتُّت، وهما قياسان يُستعملان لمعرفة انتشار الكلِّمات في المُدَوَّنة، وعادةً يُفصح عن التَّوْزِيع ولا يُفصح عن التَّشْتُّت مع أهمّيَّته. لننظر إلى الفرق بينهما من خلال تطبيق مفهومهما على تكرار الكلمة المعرّفة (الكتاب) في القرآن الكريم كما في الجدول (٢). نلاحظ أن توزيع هذه الكلمة يغطي ما نسبته ٠,٢١ من المائة من عدد الكلِّمات الفعليَّة في القرآن الكريم، وهي نسبةٌ قليلةٌ جدّاً، أما التَّشْتُّت فهو منتشرٌ في كُلِّ أجزاء القرآن الكريم (٣٠ جزءاً) عدا الجزء السابع عشر. إذن؛ نستطيع أن نقول عن كلمة (الكتاب) بأنَّ توزيعها قليلٌ وتشتَّتْها كثيرٌ. قس على ذلك قياساً عكسياً على بعض الكلِّمات التي قد يكون توزيعها كثيراً وتشتَّتْها قليلاً.

جدول ٢: التوزيع والتشتت لكلمة (الكتاب)

الكلمة الفعلية	التكرار الملاحظ	التكرار النسبي للكلمة من ١٠٠	التكرار النسبي للأجزاء	الأجزاء
الكتاب	163	0.210	96.667	1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 18, 19, 20, 21, 22, 23, 24, 25, 26, 27, 28, 29, 30
كتاب	47	0.060	86.667	1, 3, 5, 6, 7, 8, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25, 26, 27, 29, 30
كتابا	12	0.015	36.667	4, 5, 6, 7, 15, 17, 22, 23, 25, 26, 30
والكتاب	8	0.010	20.000	2, 4, 5, 20, 25, 27

٤. التَّنَوُّع المعجمي: ويقاس إما بنسبة تكرار الكلمة الفعلية إلى تكرار الكلمة النوعية (type-token ratio TTR) وهي (ناتج قسمة عدد الكلمة الفعلية على عدد الكلمة النوعية)، أو بمتوسط نسب تكرار الكلمة النوعية إلى الكلمة الفعلية في كل ١٠٠٠ كلمة^(١) (STTR1000).

٥. الكثافة المعجمية: نسبة الكلمات المعجمية (الكلمات ذات المحتوى فقط، أي: لا بدّ من إزالة الكلمات الوظيفية من قائمة الكلمات) إلى الكلمات الفعلية كلها.

(١) تعتمد نسبة الكلمة الفعلية إلى الكلمة النوعية (أي: النسبة التي تنتج عن قسمة عدد تكرار الكلمة الفعلية على عدد تكرار الكلمة النوعية) على أسلوب آخر يُعرف بالنسبة الموحدة للكلمة الفعلية إلى الكلمة النوعية STTR standardized type-token ratio التي تعمل على تجزئة النصّ إلى أجزاء عديدة، كل جزء يكون فيه عدد الكلمة الفعلية موحداً، وتكون فيه نسبة الكلمة الفعلية إلى النوعية خاصةً بها، ثم يُستخرج متوسط نسب كل الأجزاء لإظهار قيمة النسبة الموحدة. وعند استخدام صيغة (STTR1000)؛ يكون كل جزء متضمناً ١٠٠٠ كلمة، ويُمكن اختيار غير الألف، حسب حجم المدوّنة، وعادةً يكون التجزئة على عشرة أجزاء، فإن كان حجم المدوّنة مليون كلمة؛ تكون صيغة النسبة الموحدة (STTR100000)، أي: ١٠٠ ألف كلمة في كل جزء منفصل. وتفيد هذه النسبة المعرفة الدقيقة لنسبة توزيع الكلمة الفعلية إلى الكلمة النوعية في أجزاء النصّ.

تتيح أداة غواص خاصية (قائمة الإيقاف)، وبها تستطيع أن تضيف قائمة الكلمات الوظيفية (حروف الجر، وحروف العطف، وأدوات الربط، وأسماء الاستفهام، إلخ). كل ما عليك فعله هو أن تفتح ملفاً نصياً جديداً (notepad)، ثم تكتب كل كلمة في سطر، ثم تحفظ الملف بالترميز (ANSI)، (تنبه إلى الترميز حيث إن الترميز utf-8 لن يعمل في خاصية قائمة الإيقاف في أداة غواص)، ثم تحمل الملف في خيار قائمة الإيقاف في أداة غواص.

٦. التكرار المعياري (normalized): ويُستخرج من بين عيناتٍ مختلفة الحجم في المَدَوّنات اللُّغويّة؛ لأجل تحقيق الدّقة، فلو وردت كلمة (الرجل) ألف مرة في مَدَوّنة حجمها عشرة آلاف كلمة، ثم وردت عشرة آلاف مرة في مَدَوّنة أخرى حجمها مليون كلمة، فلا يمكن القول بأن ورودها في المَدَوّنة الثانية أعلى. نحتاج هنا إلى أن نعاير تكرار الرجل في كلّ مائة كلمة أو ألف كلمة في كلتا المَدَوّنتين؛ لإظهار نسبة التّكرار المعايير. وفي المثال هنا عن كلمة (رجل)، تكون نسبتها في مَدَوّنة الـ ١٠,٠٠٠ كلمة (١٠٪)، ونسبتها في مَدَوّنة المليون كلمة (١٪)، وعليه يكون التّكرار في الأوّل أعلى من التّكرار في الثاني.

لننظر إلى الجدول (٣) لنتأجّ حسابات التّكرار من القرآن الكريم.

جدول ٣: التّكرارات والتّنوع المعجمي والكثافة المعجمية للرسم الإملائي قبل التقطيع

المَدَوّنة	الكلمات الفعلية	الكلمات النّوعية	التّنوع المعجمي		الكثافة المعجمية
القرآن الكريم	77799	14952	TTR	STTR1000	0.687
			0.19	0.54	
السُّور المكيّة	47642	10665	TTR	STTR1000	0.683
			0.22	0.60	
السُّور المدنيّة	30157	7336	TTR	STTR1000	0.693
			0.24	0.56	

يُمكن الحصول على هذه النتائج من خلال نسخ النَّص في أدوات (لانكستر) الإحصائية، في مربع حساب الكَلِمَات (word calculator)، في حزمة المفردات (التكرار والتشتت) كما في الشَّكل (٦).

شكل ٦: واجهة حساب الكَلِمَات

أزيلت علامات التشكيل من مُدَوَّنة القرآن الكريم، حيث إن هذه العلامات تعطي في أدوات معالجة المُدَوَّنة عدداً مختلفاً لتكرارات الكَلِمَات النُّوعِيَّة. على سبيل المثال؛ لو جاءت كلمة (الناس) في النَّص ثلاث مراتٍ، فعدد تكرار الكلمة الفِعْلِيَّة لها هو ثلاث مراتٍ، وعدد تكرار الكلمة النُّوعِيَّة لها مرَّةً واحدة. ولكن، لو وردت هذه الكلمة ثلاث مرَّاتٍ بثلاث علامات تشكيل في آخرها؛ مثل: النَّاسُ، النَّاسِ، النَّاسِ، فتخبرنا الأداة بأن عدد تكرارها فعلياً ثلاث مرَّاتٍ، وعدد تكرارها نوعياً ثلاث مرَّاتٍ -أيضاً-، وهذا غير دقيق في حساب عدد تكرار الكلمة النُّوعِيَّة، وفي حساب نسبة عدد الكَلِمَات النُّوعِيَّة إلى الكَلِمَات الفِعْلِيَّة (type-token ratio).

يجب أن يُدرك واقع عدد الكلمات الفعلية في النص العربي بعد التقطيع (segmentation)، كما يجب الإفصاح عن ذلك. ويُجرى التقطيع في معالجة اللغة الطبيعية لضمان الدقة الأعلى في نتائج حالات الكلمات من ناحية مبانيها النحوية، ويُجرى التقطيع قبل التوسيم النحوي (part-of-speech POS tagging)؛ لضمان دقة التوسيم. استعملت نظام التقطيع والتوسيم النحوي لستانفورد - انظر إلى قائمة الوسوم النحوية للغة العربية في الملحق (ب) -؛ كونه مفتوح المصدر في مكتبة (البايثون) للغة العربية، وذلك في التحليل الذي يتطلب معالجة نحوية في بعض مباحث هذا الباب، ولمن يرغب في تقطيع النص وتوسيمه، فإن ذلك يمكن إجراؤه أيضاً في أداة محرك التخطيط (Sketch Engine). إليكم في الجدول (٤) كيف أن عدد الكلمات الفعلية والكلمات النوعية والتنوع المعجمي والكثافة المعجمية قد تغير بعد تقطيع النص القرآني. ويجب أن نضع في الاعتبار طبيعة اختلاف نماذج التقطيع الآلي للغة العربية، فنموذج (ستانفورد) يختلف عن نماذج الآلة أخرى، فبعضها تقوم على التقطيع القائم على المباني الصرفية، كقطع (أل) التعريف عن الكلمة، أو قطع الضمير المتصل من آخر الكلمة، وهذا سيؤدي لاختلاف النتائج الإحصائية عن المدونة، ولا مشكلة في ذلك من وجهة نظري، بشرط أن يفصح عن كل ما اختاره المحلل من المعالجات القبلية من تقطيع، أو توسيم، أو إيقاف للكلمات الوظيفية.

جدول ٤: التكرارات والتنوع المعجمي والكثافة المعجمية للرسم الإملائي بعد التقطيع

المُدَوَّنَة	الكلمات الفعلية	الكلمات النوعية	التنوع المعجمي		الكثافة المعجمية
القرآن الكريم	87457	13342	TTR	STTR1000	0.602
			0.15	0.48	
السُّور المَكِّيَّة	53519	9724	TTR	STTR1000	0.603
			0.18	0.52	
السُّور المَدَنِيَّة	33938	6573	TTR	STTR1000	0.599
			0.19	0.48	

المبحث الثالث: الإحصاءات الوصفية

يُستخدم هذا النوع من الإحصاء لوصف البيانات اللغوية وصفاً خاصاً بها، بحيث نعمّم نتائجها على المجتمع اللغوي الكلي، ويختلف هذا النوع عن الإحصاءات الاستدلالية (المبحث القادم) التي تقوم على الطرائق الاحتمالية التي تُساعد على تعميم نتائج البيانات اللغوية المحددة على المجموعة اللغوية الكاملة. ومن أكثر الطرائق شيوعاً لهذا النوع من الإحصاءات مقاييس النزعة المركزية (المتوسط والوسيط)، ومقاييس التشتت (المدى، والانحراف المعياري، ومعامل التباين^(١)، وتوزيع جولاند، وانحراف النسب).

في الشكل (٧) تضمين لكل هذه الإحصاءات الوصفية^(٢) عن تكرار الكلمات الفعلية في كل جزء من أجزاء القرآن الكريم، وعن تكرار كلمة (الناس) في كل جزء، مع ملاحظة أن النص القرآني المعالج مكتوب بالرسم الإملائي، ومن دون تقطيع للمباني النحوية.

كيف هيّئت البيانات عن أجزاء القرآن كما في الشكل (٧)؟ أولاً: وُضع كل جزء في ملف خاص به، ليكون عدد الملفات النصية ٣٠ ملفاً. ثانياً: باستخدام أداة غواص، أُستخرج مجموع تكرارات الكلمات الفعلية في كل جزء، ثم أُستخرجت التكرارات المطلقة

(١) ترجمت هذا المصطلح بـ (معامل التنوع coefficient of variation) في: بريزينا، فاكلاف. علم الإحصاء في لغويات المدونة الحاسوبية. ترجمة: سلطان المجبول. دار جامعة الملك سعود للنشر، الرياض، ٢٠٢١، الصفحات ٦٤-٦٦. لهذا المصطلح مقابلات عديدة كثيرة، ومنها: معامل التغير، ومعامل التفاوت، ومعامل الانحراف، ومعامل الفرق. أُعيد هنا عن المقابل (معامل التنوع)، ليكون المقابل (معامل التباين)، والسبب في ذلك يعود إلى انتشار ترجمة مصطلح (ANOVA) بتحليل التباين، وهو مصطلح مختصر من (Analysis of Variation). إذن: أميل إلى المقابل (التباين): لانتشاره في الكتب الإحصائية، فعنصر الانتشار وكثرة الاستعمال هو ما أميل إليه في اختيار المقابل العربي مقابل المصطلح الأجنبي، وإن كان المقابل العربي غير دقيق.

(٢) يمكن إجراء هذه الإحصاءات باستخدام أداة صندوق (لانكسبروكس LancsBox).

Brezina, V., Weill-Tessier, P., & McEnery, A. (2020). #LancsBox v. 5.x. [software].

Retrieved October 24, 2022, from <http://corpora.lancs.ac.uk/lancsbox>.

(التكرّارات الملحوظة) لكلمة (الناس) من كلّ جزء. ثالثاً: استُخلصت النّسب المتوقّعة (النّظريّة) بقسمة كلّ تكرارٍ فعليٍّ للكلمات الفعليّة على مجموعها، على سبيل المثال: في الجزء الأوّل في الصف (١) في الشّكل (٧)، عندما قُسم التّكرار ٢٥٣٢ على المجموع ٧٧٧٩٩؛ ظهر النّاتج ٠,٣١٦، وهكذا دواليك على بقيّة النّسب المتوقّعة في بقيّة الأجزاء. رابعاً: استُخلصت النّسب الملحوظة بقسمة كلّ تكرارٍ ملحوظٍ لكلمة الناس في كلّ جزءٍ على مجموع التّكرّارات الملحوظة للكلمة، على سبيل المثال؛ في الجزء الأوّل في الصّف (١)، في الشّكل (٧)، عندما قُسم التّكرار (٨) على المجموع (١٨٤)؛ ظهر النّاتج (٠,٠٤٣)، وهكذا دواليك على بقيّة النّسب الملحوظة في بقيّة الأجزاء. أما الفروقات النّسبيّة فهي قيمة الفارق بين النّسبة المتوقّعة والنّسبة الملحوظة في كلّ صفّ.


الجزء	تكرار الكلمات الفعلية	(الناس) التكرار المطلق	(الناس) التكرار النسبي	النسبة المتوقعة	النسبة الملحوظة	الفروقات بين النسب
1	2532	8	0.316	0.033	0.043	0.011
2	2586	16	0.619	0.033	0.087	0.054
3	2636	7	0.266	0.034	0.038	0.004
4	2517	7	0.278	0.032	0.038	0.006
5	2589	11	0.425	0.033	0.060	0.027
6	2529	8	0.316	0.033	0.043	0.011
7	2788	2	0.072	0.036	0.011	-0.025
8	2583	3	0.116	0.033	0.016	-0.017
9	2500	5	0.200	0.032	0.027	-0.005
10	2398	4	0.167	0.031	0.022	-0.009
11	2665	13	0.488	0.034	0.071	0.036
12	2731	11	0.366	0.035	0.060	0.025
13	2624	9	0.343	0.034	0.049	0.015
14	2503	2	0.080	0.032	0.011	-0.021
15	2688	4	0.149	0.035	0.022	-0.013
16	2777	2	0.072	0.036	0.011	-0.025
17	2453	14	0.571	0.032	0.076	0.045
18	2646	0	0.000	0.034	0.000	-0.034
19	2624	3	0.114	0.034	0.016	-0.017
20	2562	6	0.234	0.033	0.033	0.000
21	2592	12	0.463	0.033	0.065	0.032
22	2655	9	0.339	0.034	0.049	0.015
23	2639	1	0.038	0.034	0.005	-0.028
24	2531	5	0.198	0.033	0.027	-0.005
25	2673	4	0.150	0.034	0.022	-0.013
26	2622	3	0.114	0.034	0.016	-0.017
27	2531	3	0.119	0.033	0.016	-0.016
28	2643	2	0.076	0.034	0.011	-0.023
29	2667	0	0.000	0.034	0.000	-0.034
30	2315	10	0.432	0.030	0.054	0.025
المجموع	77799	184		1	1	0.032
المتوسط	6.133	ناتج مجموع التكرار المطلق للكلمة ÷ عدد الأجزاء				
الوسيط	4.500	الرقم المتوسط بين التكرار المطلق لكل كلمة				
الانحراف المعياري	4.369	الحذر التربيعي لمجموع مربعات المسافات من المتوسط ÷ مجموع أجزاء المدونة (أجزاء القرآن) - ١				
المدى ١	الربع الثاني	الرقم ٦ يقع في الربع الثاني بين الصفر والعشرين				
المدى ٢	0.933	عدد الأجزاء التي وردت فيها الكلمة ÷ عدد أجزاء المدونة				
معامل التباين	0.130	الانحراف المعياري ÷ المتوسط = معامل التباين. (ثم معامل التباين ÷ عدد أجزاء المدونة - ١)				
توزيع جولاند	0.976	معامل التنوع ÷ الجذر التربيعي لـ (عدد أجزاء المدونة - ١)				
انحراف النسب	0.016	مجموع الفروقات بين النسب ÷ ٢				

شكل ٧: الإحصاءات الوصفية ومقاييس التشتت لكلمة (الناس) في القرآن الكريم

يُستخرج المتوسط بجمع كل تكرارٍ مطلقٍ مع الآخر، ثم بقسمة الناتج على عدد الحالات (٣٠ حالة). ونضطرُّ إلى استخدام الوسيط بدلاً من المتوسط عندما تكون هناك قيم متطرفة ستؤثر في المتوسط، ولا تعطي متوسطاً دقيقاً. في البيانات في الشكل (٧)؛ لا نجد قيمةً متطرفة؛ وعليه فلا حاجة بنا إلى النظر إلى الوسيط. لقد استخرج الوسيط لأجل توضيح كيفية استخلاصه. وهو لا يتطلب أي حساب، إنما يتم البحث عن العدد الواقع في الوسط لكل القيم. لدينا ثلاثون قيمةً، وآخر قيمة في النصف الأول هي (٤)، وأول قيمة في النصف الثاني هي (٥)، وما بينهما بطبيعة الحال هي قيمة الوسيط، وهي (٤,٥). لو افترضنا بأن بعد القيمة ١٤ جاء تكرار الكلمة في الجزء (٣٠)، بواقع (٩٠٥) مرات، فبمثل هذه الحالات نستعمل الوسيط بدلاً من المتوسط الذي ستكون قيمته (٣٦)، وهي قيمة مُضَلَّلَةٌ. أما الانحراف المعياري فيُحسب عن طريق (الجزء التربيعي لمجموع مربعات مسافات قيم التكرار من المتوسط) مقسوم على (مجموع الأجزاء - ١).

٥, ٥, ٦, ٧, ٧, ٨, ٨, ٩, ٩, ١٠, ١١, ١١, ١٢, ١٣, ١٤, ١٦	↓	٠, ٠, ١, ٢, ٢, ٢, ٢, ٢, ٣, ٣, ٣, ٣, ٤, ٤, ٤
	4.5	

ولقياس المدى الذي يعدُّ أول مقاييس التشتت طريقتان؛ الأولى تُعرف بـ: المدى (الشكل ٨) الذي يبين موقع المتوسط بين الربع الأدنى والأعلى للمدى، وهو يفيد في معرفة طبيعة الانحراف من المتوسط، وموقع المتوسط على وجه التحديد، أما الثانية فتُعرف بـ: المدى الذي يقيس تشتت الكلمة بين أجزاء المدونة، وتُعرف قيمته عن طريق المعادلة الآتية: (عدد الأجزاء التي وردت فيها الكلمة ÷ إجمالي عدد أجزاء المدونة × ١٠٠)، لتكون قيمته (٩٣,٠)، وهي قيمة عالية، ذات دلالة على جودة تشتت الكلمة في المدونة.



شكل ٨: المدى

كيف تُعرف القيم المتطرفة؟ الجواب: باستخدام منطوق الربعيات (quantiles)، وفق المعادلة الآتية: $(Q1 - Q3 \times 1.5)$. في بيانات الشَّكْل (٧) لا توجد قيم متطرفة. لننظر مثلاً إلى تكرارات كلمة (النَّاس)، وهي قيمٌ تبدأ من (١) إلى (١٦). الربع الأول ($Q1$) يمتدُّ من (١) إلى (٤)، ويمتدُّ الربع الثاني ($Q2$) من (٥) إلى (٨)، ويمتدُّ الرُّبُع الثالث ($Q3$) من (٩) إلى (١٢)، ويمتدُّ الرُّبُع الرابع من (١٣) إلى (١٦). لنجري معادلة منطوق القيمة المتطرفة على النُّحو الآتي: $(١ - ١,٥ \times ٩)$ يساوي (١٢). يُضاف هذا النَّاتِج إلى أوَّل قيمةٍ للرُّبُع الثالث (أي: $٩ + ١٢$)، لتكون النتيجة (٢١)، وعليه تكون القيمة (٢١) فأعلى هي القيم المتطرفة في هذا المثال، وتُعرف هذه الطريقة بمعدَّل الربعيات البينيَّة (Inter Quantile Rate - IQR)، وتُجرى ألياً على البَيِّنَات.

يُحدِّد لنا معاملُ التَّبَاينِ حجمَ تنوُّعِ الكلمة في المُدَوَّنة اللُّغويَّة، وبينه وبين التَّشَتُّتِ علاقةٌ طرديَّةٌ، فكلما زادت قيمة معامل التَّبَاينِ زادت قيمة التَّشَتُّتِ، ويعتمد حساب التَّنَوُّعِ على ناتج قسمة (الانحراف المعياري) على (المتوسِّط)، ثم يُقسَّمُ النَّاتِجُ على الجذر التَّربيعي لعدد أجزاء المُدَوَّنة - ١ للحصول على قيمة معامل التَّبَاينِ.

$$0.712 = 6.133 \div 4.369$$

$$0.13 = 5.385 \div 0.712 = \sqrt{1 - 30} \div 0.712$$

$$13\% = (100 \times 0.13) \text{ لتحويل القيمة إلى نسبيَّة مئويَّة}$$

كلما كانت قيمة معامل التباين أقل من ٥٠٪؛ كان التنوع أقل والتشتت أفضل، وكلما ازدادت دل ذلك على وجود تباين في التكرارات أو بين التكرارات، ويُعيدنا هذا إلى الكلام عن الفرق بين التوزيع (distribution)، وبين التشتت (dispersion)، ومن المهم أن يُفصح عنهما، فازدياد قيمة معامل التباين يعني أن التوزيع غير عادل، وأن التباين عالٍ بين التكرارات، وأن التشتت ليس جيداً. أما توزيع (جولاند)^(١)؛ فهو على عكس معامل التباين، إذ كلما زادت قيمة توزيع (جولاند)؛ دل ذلك على أن التوزيع عادل، وأن التباين أقل، وأن التشتت أفضل. تكون قيمة توزيع (جولاند) بين (٠) و(١)، حيث يشير (٠) إلى أن التوزيع غير عادل أبداً، ويشير (١) إلى أن التوزيع عادل تماماً، ويتم استخراج قيمة توزيع (جولاند) بالإجراء الحسابي الآتي:

$$\bullet 1 - (\text{معامل التباين}) \div (\text{الجذر التربيعي لعدد أجزاء المدة} - 1)$$

$$\bullet 1 - (0.13) \div (\sqrt{1 - 30})$$

$$\bullet 1 - (0.13) \div (5.385)$$

$$\bullet 1 - 0.024 = 0.976$$

وفي آخر مقاييس التشتت؛ نجد ما يُسمى بالانحراف النسبي، ويُستخرج بقسمة (٢) على (مجموع الفروقات النسبية)، ونتيجته ٠,٠١٦، ويُفسر على أن التوزيع بين الأجزاء عادل جداً، إذ كلما اقتربت القيمة إلى (٠)؛ دل ذلك على تساوي التكرارات وتكافؤها بين الأجزاء، وكلما اقتربت القيمة إلى (١) دل ذلك على أن التوزيع غير متساوٍ ومتكافئ بين الأجزاء.

(1) Juilland, A. G., Brodin, D. R. & Davidovitch, C. (1970). Frequency dictionary of French words. The Hague: Mouton.

المبحث الرَّابِع: الإحصاءات الاستدلاليَّة

تُستخدمُ هذه الإحصاءاتُ لوصفِ البَيِّنَاتِ اللُّغَوِيَّةِ العشوائِيَّةِ، وللحصولِ على معلوماتٍ وأحكامٍ عامَّةٍ عن المجتمع اللُّغَوِيِّ كُلِّهِ من خلال عَيِّنَةٍ من المجتمع اللُّغَوِيِّ. وتُجرى هذه الإحصاءاتُ لغرض اختبار فرضيةٍ ما، وفي الآتي الاختبارات التي ستناقش في هذا المبحث.

- كاي تربيع (chi-squared)، وكاي تربيع بتصحيح ييتس (chi-squared Yates's correction)، والاحتمال اللوغاريتمي log likelihood، واختبار فيشر المنضبط Fisher exact test.
- معامل (كريمرف Cramer V).
- نسبة الاحتمال.

نحتاج بدايةً أن نفترض فرضيةً بحثيةً في مدوَّنة القرآن الكريم؛ لنفترض أنَّ الفعل (يخشون) والفعل (يخافون) لا يختلفُ ورودهما بين السُّورِ المكيَّةِ والسُّورِ المدنيَّةِ. فيما يلي صياغة الفرضية الصِّفريَّة، ثم صياغة الفرضية البديلة.

الفرضية الصِّفريَّة: ليس للسياق أثرٌ في استخدامات الفعل (يخشون) والفعل (يخافون).

الفرضية البديلة: للسياق أثرٌ في استخدامات الفعل (يخشون) والفعل (يخافون).

وبعد صياغة الفرضيتين؛ تُهيأُ البَيِّنَاتُ إما على صيغة جدولٍ متقاطعةٍ cross-tabulation على نحو (أ) في الشَّكْل (٩)، أو على شكل مجموعة بيانات (data set)، على نحو (ب) في الشَّكْل (٩).

لاحظُ أن الكَلِمَاتِ قد أُدخلت بحروفٍ لاتينية بدلاً من الحروف العربيَّة، وسبب ذلك أن أدوات (لانكستر) الإحصائية لا تقبل الحروف العربيَّة، ويُمكن معالجة ذلك باستعمال أي طريقةٍ من طرائق الكتابة الصَّوتية الدوليَّة للحروف العربيَّة، وبعد الحصول على النَّتائج؛ يُمكن إعادة تمثيل النَّتائج بالحروف العربيَّة.

بالنسبة للتكرارات الملحوظة؛ ورد الفعل (يخشون) أربع مرات في السُّور المكيَّة، ومرتين في السُّور المدنيَّة. وورد الفعل (يخافون) أربع مرات في السُّور المكيَّة، وأربع مرات في السُّور المدنيَّة. نظرتُ إلى صيغ الفعلين من دون اشتقاقاتها، ومن دون اللواصق التصريفية. ستعمل أدوات (لانكستر) الإحصائية على تحويل التكرارات الملحوظة إلى التكرارات المتوقعة (النظرية)، لمعرفة طريقة هذا التحويل تطبيقاً؛ يشير الجدول (٥) إلى التكرارات الملحوظة، ويشير الجدول (٦) إلى طريقة استخراج التكرارات المتوقعة نظرياً.

ID	Variety	Outcome	(ب)	(أ)		
				Context	yakhšawna	yakhāfūna
1	Makkiyya	yakhšawna		Makkiyya	2	4
2	Makkiyya	yakhšawna		Madaniyya	4	4
3	Makkiyya	yakhšawna				
4	Makkiyya	yakhšawna				
5	Makkiyya	yakhšawna				
6	Makkiyya	yakhšawna				
7	Madaniyya	yakhāfūna				
8	Madaniyya	yakhāfūna				
9	Madaniyya	yakhāfūna				
10	Madaniyya	yakhāfūna				
11	Madaniyya	yakhāfūna				
12	Madaniyya	yakhāfūna				
13	Madaniyya	yakhāfūna				
14	Madaniyya	yakhāfūna				

شكل ٩: جدولة متقاطعة للفعلين (يخشون) و(يخافون)

جدول ٥ : التكرارات الملحوظة للفعليين (يخشون) و(يخافون) في السُّور المكيَّة والسُّور المدنيَّة

نوع السياق	الأفعال		
	يخشون	يخافون	المجموع
مَكِّيَّة	2	4	6
مدنيَّة	4	4	8
المجموع	6	8	14

جدول ٦ : التكرارات المتوقعة للفعليين (يخشون) و(يخافون) في السُّور المكيَّة والسُّور المدنيَّة

نوع السياق	الأفعال		
	يخشون	يخافون	المجموع
مكيّة	$2.57 = \frac{6 \times 6}{14}$	$3.43 = \frac{8 \times 6}{14}$	6
مدنيّة	$3.43 = \frac{8 \times 6}{14}$	$4.57 = \frac{8 \times 8}{14}$	8
المجموع	6	8	14

لن أشير هنا إلى طريقة استخراج كلِّ قيمةٍ لكل الاختبارات الفرضيَّة^(١)، إذ يكفي أن يعرف القارئ المفهوم النَّظريَّ للتكرارات المتوقعة، كما أن أدوات (لانكستر) الإحصائيَّة ستُخرج القيم الاحتماليَّة (p values) لكل اختبارات الفرضيَّة، والذي يهمُّ عندئذٍ هو القيمة الاحتماليَّة، فماذا تعني القيمة الاحتماليَّة؟ الجواب ببساطة هو على النَّحو الآتي:

— إذا جاءت القيمة الاحتماليَّة أقلَّ من ٠,٠٥ (أي: أقل من ٥٪)؛ نرفض الفرضيَّة الصَّفريَّة، وتكون الفرضيَّة البديلة هي الصحيحة.

(١) من أراد الاطلاع على الحسابات النظرية لاختبارات الفرضيَّة؛ فليعد إلى المرجع الآتي: بريزينا، فاكلاف. علم الإحصاء في لغويَّات المُدَوَّنة الحَاسُوبِيَّة. ترجمة: سلطان المجيلول. دار جامعة الملك سعود للنشر، الرياض، ٢٠٢١، الصفحات ١٤١-١٥٣.

— إذا جاءت القيمة الاحتمالية أعلى من ٠,٠٥ (أي: أعلى من ٥٪): نقبل الفرضية الصفرية، وتكون عندئذٍ صحيحة.

لاستخراج القيمة الاحتمالية (p value)، تُجري أدوات (لانكستر) اختبار الفرضية واستخراج القيمة الاحتمالية بأربعة اختبارات: كاي تربيع (chi-squared)، وكاي تربيع بتصحيح بيتس (Yates's correction) chi-squared، والاحتمال اللوغارثمي (log likelihood)، واختبار (فيشر) المنضبط (Fisher exact test) (الشكل ١٠). في الخانة الفارغة من هذا الشكل؛ نقوم بنسخ خلايا بيانات الجدولة المتقاطعة cross-tab (أ من الشكل ٩)، أو بنسخ خلايا بيانات المجموعة data set (ب من الشكل ٩)، ثم نلصقها فيها. سنختار من صيغة إدخال البيانات (input format of the data) الخيار الأول: cross-tab، بعد ذلك نختار نوع الاختبار من الاختبارات الأربعة المدمجة في الأداة، وتظهر نتائج الاختبارات بعد الضغط على خيار المقارنة (Compare)، في الآتي عرضُ لنتائج كل اختبار من الاختبارات الأربعة.

4 Lexico-grammar *From simple counts to complex models*

Cross-tab Categories comparison Logistic regression

Videos

1. Paste tab delimited data including header row and id column. For help click [here](#).

2. Select options.

Input format of the data: ☒ Cross-tab ☐ Data set

Test: ☒ Chi-squared ☐ Chi-squared (Yates's correction) ☐ Log likelihood ☐ Fisher exact test

☐ Visualize relationship

Compare Clear

R code

شكل ١٠: واجهة مقارنة المجموعات في صندوق (النحو المُعْجَبِي)

ستظهر نتائج كاي تربيع على النحو الآتي:

Some expected frequencies are too small. Try Fisher exact test or Log likelihood test instead.

Pearson's Chi-squared test: 0.39 (1), $p = 0.532884$, Cramer's $V = 0.167$, 95% CI [0, 0.687], SMALL EFFECT

Probability ratios (PR):

PR of verb_1 in Makkiyya vs. Madaniyya = 1.333 (95% CI: 0.545, 3.262)

PR of verb_1 in Madaniyya vs. Makkiyya = 0.75 (95% CI: 0.307, 1.835)

PR of verb_2 in Makkiyya vs. Madaniyya = 0.667 (95% CI: 0.177, 2.513)

PR of verb_2 in Madaniyya vs. Makkiyya = 1.5 (95% CI: 0.398, 5.654)

الترجمة:

بعض التكرارات المتوقعة صغيرة جداً. حاول استخدام اختبار فيشر المنضبط أو اختبار الاحتمال اللوغاريتمي.

اختبار كاي تربيع بيرسون: 0.39 درجة الحرية (1)، قيمة الاحتمال $p = 0.532884$ ، معامل كريمرث $= 0.167$ ، 95% مجال الثقة [0, 0.687]، الأثر صغير.

نسب الاحتمال:

نسبة احتمال الفعل (يخشون) في السُّور المكيّة مقابل الفعل (يخشون) في السُّور المدنيّة = 1.333 (95% مجال الثقة: 0.545, 3.262).

نسبة احتمال الفعل (يخشون) في السُّور المدنيّة مقابل الفعل (يخشون) في السُّور المكيّة = 0.75 (95% مجال الثقة: 0.307, 1.835).

نسبة احتمال الفعل (يخافون) في السُّور المكيّة مقابل الفعل (يخافون) في السُّور المدنيّة = 0.667 (95% مجال الثقة: 0.177, 2.513).

نسبة احتمال الفعل (يخافون) في السُّور المدنيّة مقابل الفعل (يخافون) في السُّور المكيّة = 1.5 (95% مجال الثقة: 0.398, 5.654).

شكل ١١: نتائج كاي تربيع للفعلين (يخشون) و(يخافون)

أما بخصوص بقية الاختبارات الثلاثة، فستظهر نتيجة كاي تربيع (تصحیح يیتس) = ۰,۰۱، ودرجة الحرية (۱)، وقيمة الاحتمال $p = 0.938$ ، وستظهر نتيجة الاحتمال اللوغارثمي = ۰,۳۹، ودرجة الحرية (۱)، وقيمة الاحتمال $p = 0.531$ ، وستظهر قيمة الاحتمال لاختبار (فيشر) المنضبط $p = 0.627$. أما نسب الاحتمال من هذه الاختبارات الثلاثة الأخيرة؛ فهي نسب الاحتمال الواردة في كاي تربيع نفسها.

سنشرح معامل (كريمرف)، ونسبة الاحتمال؛ بعد الوقوف على قيم الاحتمال، ودرجة الحرية، ومجال الثقة. دعونا نعد إلى الفرضية الصفرية والفرضية البديلة. قلنا إن كانت قيمة الاحتمال أقل من ۰,۰۵؛ نرفض الفرضية الصفرية، ونعدها غير صحيحة. وإذا نظرنا إلى قيم الاحتمال في كل هذه الاختبارات الأربعة؛ سنجدها أعلى من ۰,۰۵. فالفرضية الصفرية صحيحة، ونستنتج من ذلك أنه لا يوجد دليل كافٍ لرفض الفرضية الصفرية.

هي لعبة احتمالات، وتتطلب توخي الحذر عند التفسير، فهي لا تُخبرنا قطعاً بصحة الفرضية الصفرية، وخطأ الفرضية البديلة، فلو أجرينا بحثاً عن الألفاظ العاطفية بين الرجال والنساء، وجمعنا مدونة لروايات كتبها رجال، وروايات أخرى كتبها نساء، ووضعنا الفرضيتين الآتيتين؛ الفرضية الصفرية: لا فرق بين الرجال والنساء في استخدام الكلمات العاطفية، والفرضية البديلة: هناك فرق بين الرجال والنساء في استخدام الكلمات العاطفية؛ فإنَّ قِيَم الاحتمال قد تكون أقل من ۰,۰۵، بين رواياتٍ محدَّدة، وقد تكون أعلى من ۰,۰۵، في حال لوزدنا حجم الروايات، ولا بدَّ أن تكون الافتراضات سليمة، وأن تكون البيانات اللغوية (العينة) متسقة مع بيانات المجموعة اللغوية كلها، والأخذ في الحسبان بعوامل متعلقة بالخلفيات الثقافية والعمرية لكتاب هذه الروايات؛ كي يكون الاختبار الإحصائي دقيقاً في نتائجه.

نأتي إلى معامل (كريمرف)، وهي عملية إحصائية، تحسب لنا حجم التأثير لكاي تربيع، وتكون مهمة في حال صارت قيم إحصائيات تربيع كاي في تزايد، بسبب تزايد حجم العينة، وبما أن كاي تربيع يقدم لنا دليل قبول أو عدم قبول الفرضية الصفرية؛ فحجم التأثير باستخدام هذا المعامل يقدم لنا قابلية المقارنة بين أحجام العينة. متى يكون حجم التأثير كبيراً؟ الجواب: تظهر قيمة هذا المعامل بين (٠) و (١). وضع (كوهن)^(١) التفسير الموصى به لتلك القيم، وهي في الجدول (٧).

جدول ٧: توصية (كوهن) لتفسير حجم التأثير بمعامل (كريمرف)

درجة الحرية	حجم التأثير بمعامل كريمرف		
	التأثير صغير	التأثير متوسط	التأثير كبير
١	0.10	0.30	0.50
٢	0.07	0.21	0.35
٣	0.06	0.17	0.29

لو عدنا إلى نتيجة المعامل من أدوات (لانكستر) الإحصائية؛ سنجد أن القيمة هي (٠,١٦٧) لدرجة الحرية (١)، وبناءً على تفسير كوهن؛ فالتأثير صغير أو ضعيف. ماذا يعني ذلك؟ يعني أنه لا يوجد تأثير في اختلاف استعمال الفعل (يخشون) والفعل (يخافون) بين السور المكّيّة والسور المدنيّة.

سؤال أخير عن درجة الحرية؛ ماذا تعني؟ الجواب ببساطة: هي تذكرك إحصائي يقوم على الاحتمالات التي لدينا عند حساب الحالات، لدينا حالتان في المثال الذي طبقناه في العمود (الفعلين) وحالتان في الصف (المكّيّة والمدنيّة) في البيانات. درجة الحرية هي (١)، وتكون درجة الحرية دائماً هي (عدد الحالات - ١).

(1) Cohen, J. (1988). Statistical power analysis for the behavioral sciences. Hillsdale, NJ: Erlbaum.

لماذا ناقص واحد؟ الجواب: لأنَّ الاحتمال الثاني غير محسوبٍ، فالقياس ليس حرّاً في اختياره؛ لأنه هو ما قد تبقى. تشبه فكرة الحرية فكرة أن تكون أمام حرية انتقاء سيارتين، أنت حرٌّ في اختيار السيارة الأولى، أما في مرحلة الاختيار الثانية فليست هناك حرّية؛ لأنه لم يتبقَّ لك إلا هذه السيارة.

نأتي إلى نسبة الاحتمال؛ في كلّ الأبحاث التجريبية، سواءً الطبيّة أم غيرها؛ يهتمُّ الباحثون بنوع واحد من التأثير لنسبة الاحتمال، وهي نتيجة عيّنة الدّراسة مقابل المجموعة المرجعية كلّها. في الإحصاء اللّغويّ؛ يُمكن أن نحسب أكثر من نسبة احتمال واحدة، حسب محاور الحالات في البيانات. ولتوضيح طريقة إظهار نسب الاحتمال؛ فهي نتيجة قسمة التكرار الملحوظ لكلِّ فعلٍ على مجموع تكرار الأفعال في السّياق الواحد. لننظر إلى الجدول (٩) ونقارنه بجدول (٨) للتكرارات الملحوظة، ثم ننظر إلى النتائج التي أظهرتها أدوات (لانكستر) الإحصائية لنسب الاحتمال من أجل فهم طريقة استخراجها.

جدول ٨ : التكرارات الملحوظة

الأفعال	يخشون	يخافون	المجموع
نوع السّياق			
مَكِّيّة	2	4	6
مدنيّة	4	4	8
المجموع	6	8	14

جدول ٩ : التكرارات المتوقعة (نظرياً)

الأفعال	يخشون	يخافون	المجموع
نوع السّياق			
المؤلف	$0.333 = 6 \div 2$	$0.666 = 6 \div 4$	6
مدنيّة	$0.5 = 8 \div 4$	$0.5 = 8 \div 4$	8
المجموع	8	6	14

نتائج أدوات (لانكستر) الإحصائية

- نسبة احتمال الفعل (يخشون) في السُّور المكيّة مقابل الفعل (يخشون) في السُّور المدنيّة $\left(\frac{0,333}{0,5}\right) = (0.667)$.
- نسبة احتمال الفعل (يخشون) في السُّور المدنيّة مقابل الفعل (يخشون) في السُّور المكيّة $\left(\frac{0,5}{0,333}\right) = (1.5)$.
- نسبة احتمال الفعل (يخافون) في السُّور المكيّة مقابل الفعل (يخافون) في السُّور المدنيّة $\left(\frac{0,666}{0,5}\right) = (1.333)$.
- نسبة احتمال الفعل (يخافون) في السُّور المدنيّة مقابل الفعل (يخافون) في السُّور المكيّة $\left(\frac{0,5}{0,666}\right) = (0.75)$.
- تُفسّر نسب الاحتمال هذه على النحو الآتي:
- نسبة الاحتمال (١): لا يوجد فرق بين السياقين.
- نسبة الاحتمال الأصغر من (١): ظهور الفعل (يخشون) في السُّور المكيّة أقلّ احتمالاً من ظهوره في السُّور المدنيّة، وظهور الفعل (يخافون) في السُّور المدنيّة أقلّ احتمالاً من ظهوره في السُّور المكيّة.
- نسبة الاحتمال الأكبر من (١): ظهور الفعل (يخشون) في السُّور المدنيّة أكبر احتمالاً من ظهوره في السُّور المكيّة، وظهور الفعل (يخافون) في السُّور المكيّة أكبر احتمالاً من ظهوره في السُّور المدنيّة.

المبحث الخامس: أنواع الأشكال البيانيّة

يحتوي هذا المبحث على أساليب تمثيل البيانات (visualization)، وفي كلّ نوع من أنواع تمثيل البيانات اللُّغويّة أمثلة للمتغيّرات اللُّغويّة، ونوع العيّنة من القرآن الكريم، وعدد النُّصوص، بالإضافة إلى هيكل البيانات لكلّ نوع من أنواع الأشكال البيانيّة. وكلّ ما يُحتاج

القيام به بعد تهيئة هيكل البيانات في ملف (إكسل) هونسخه ثم لصقه في أدوات (لانكستر) الإحصائية، ثم اختيار المقاييس (parameters): متغير لغوي واحد (one linguistic variable)، أم متغيرات لغوية متعددة (العلاقة) (Multiple linguistic variables (relationship))، ووصف (description) أم استدلال (inference) (الشكل ١٢).

شكل ١٢ : واجهة أداة تمثيل البيانات اللغوية

أولاً: المخطط الدَّرجي histogram

يُجرى هذا الشكل البياني للإحصاء الوصفي، ولتمثيل هذا المخطط؛ تحتوي البيانات اللغوية على متغير لغوي واحد، ومدونة واحدة، ونصوص متعددة ضمن هذه المدونة.

مثال:

● المتغير اللغوي: عبارة (الذين آمنوا: تتابعان لفظيان 2n-grams).


● الوصف description.

- المَدَوْنَةُ الواحدة: السُّور السَّبْع الطُّوال (أي: بين سورة البقرة، وآل عمران، والنِّساء، والمائدة، والأنعام، والأعراف، والأنفال والتَّوبَة مَعاً).
- النُّصُوص المتعدِّدة سبعة، باعتبار أن كُلَّ سورةٍ قد جُعِلَتْ نَصًّا مُستَقِلًّا.

عندئذ يُهيأُ هيكل البَيِّنَات وفق الشَّكل (١٣)، ويخرج تمثيل المَخَطَط الدَّرَجِي كما في الشَّكل (١٤).

Texts	Frequency
text1	26
text2	12
text3	17
text4	22
text5	1
text6	2
text7	21

شكل ١٣: تكرار (الذين آمنوا) في السُّور الطوال



شكل ١٤: المَخَطَط الدَّرَجِي لتكرار (الذين آمنوا) في السُّور الطوال

ثانياً: مخطط الصندوق (أو رسم المربع) boxplot

يُجرى هذا الشكل البياني للإحصاء الوصفي، ولتمثيل هذا المخطط؛ تحتوي البيانات اللغوية على متغير لُغوي واحد، ومدونات متعددة (أي: مدونتين أو أكثر)، ونصوص متعددة في كل مدونة.


مثال:

- المتغير اللغوي: كلمة (ما).
- الوصف description.
- المدونات: ثلاث مدونات منفصلة. المدونة الأولى (corpus1): جزء عمّ، والمدونة الثانية (corpus2) جزء تبارك، والمدونة الثالثة (corpus3) جزء قد سمع.
- عدد النصوص: ٥٧ نصاً (على اعتبار عدد السور في هذه الأجزاء الثلاثة).

ويُهيأ شكل البيانات كما في الشكل (١٥)، إذ يتضمّن العمود الأول (النص Text)، وكل نص محفوظ برقم ترتيب السورة في المصحف الشريف في الأجزاء القرآنية الثلاثة الأخيرة، ويتضمّن نص السورة، ويخرج تمثيل المخطط الصندوقي كما في الشكل (١٦).

Text	Corpus1	Corpus2	Corpus3
text58	0	0	7
...	...	...	...
text67	0	5	0
...	...	...	...
text78	2	0	0

شكل ١٥: سبعة وخمسون نصاً (سورة ٥٧) في الأجزاء الثلاثة الأخيرة



شكل ١٦: مخطط الصندوق

ثالثاً: أعمدة الخطأ. مجال الثقة ٩٥٪

يُجرى هذا الشكل البياني للإحصاء الاستدلالي، ولتمثيل هذا المخطط؛ تحتوي البيانات اللُّغَوِيَّة على متغيرٍ لُّغَوِيٍّ واحد، ومدونةٍ تتضمن نصوصاً متعددة، أو مدوناتٍ متعددة (أي: مدونتين أو أكثر) تتضمن نصوصاً متعددة في كلِّ مدونةٍ.


مثال:

- المتغير اللُّغَوِيّ: كلمة (ما).
- الاستدلال inference.
- المدونات: ثلاث مدونات منفصلة. المدونة الأولى (corpus1): جزء عمّ، والمدونة الثانية (corpus2) جزء تبارك، والمدونة الثالثة (corpus3) جزء قد سمع.
- عدد النصوص: ٥٧ نصّاً (على اعتبار عدد السُّور في هذه الأجزاء الثلاثة).

ويُهيأ شكلُ البَيِّنَات كما في الشَّكل (١٧)، إذ يتضمَّن العمود الأوَّل (النَّص Text)، وكل نصَّ محفوظ برقم ترتيب السُّورة في المصحف الشَّريف في الأجزاء القرآنيَّة الثلاثة الأخيرة، ويتضمَّن نصَّ السُّورة، وبعد المعالجة يخرج تمثيل المخطَّط الصندوقي كما في الشَّكل (١٨).

Text	Corpus1	Corpus2	Corpus3
text58	0	0	7
...	...	...	...
text67	0	5	0
...	...	...	...
text78	2	0	0

شكل ١٧ : سبعة وخمسون نصًّا (٥٧ سورة) في الأجزاء الثلاثة الأخيرة



شكل ١٨ : أعمدة الخطأ

رابعاً: مخطط التَّشْتُّت scatter plot

يُجرى هذا الشَّكْلُ البياني للإحصاء الوصفيّ، ولتمثيل هذا المخطط؛ تحتوي البَيَّانات اللُّغَوِيَّة على مُتَغَيَّرَات لُّغَوِيَّة عديدة، ومدوِّنة لُّغَوِيَّة واحدة تَتَّصَمَّن نصوصاً عديدة.


مثال:

- المُتَغَيَّرَات اللُّغَوِيَّة: كلمة (الجنة) heaven وكلمة (النار) hell.
- الوصف description.
- المدوِّنة: القرآن الكريم كاملاً.
- النُّصوص: ٣٠ نصّاً، ويَتَّصَمَّن كُلُّ نصٍّ جزءاً من أجزاء القرآن الكريم.

ويُهيَّأ شكل البَيَّانات كما في الشَّكْل (١٩)، إذ يَتَّصَمَّن العمودُ الأول (النُّصوص Texts)، ويحمل اسم كُلِّ ملفٍّ نصِّي رقمَ الجزء في المصحف الشريف، ويحتوي على نصِّ سورة، وبعد الضَّغط على مفتاح (أنشئ الشَّكْل Create graph) يخرج تمثيلٌ مخطط التَّشْتُّت كما في الشَّكْل (٢٠).

Texts	heaven	hell
1	3	5
2	2	6
3	0	5
...	...	...
30	3	2

شكل ١٩: الجنة والنار بين أجزاء القرآن



شكل ٢٠: مخطط التشتت

خامساً: مخطط خطي line chart بخط انحداري regression line

يُجرى هذا الشكل البياني للإحصاء الاستدلالي، ولتمثيل هذا المخطط؛ تحتوي البيانات اللغوية على متغيرات لغوية عديدة، ومدونة لغوية واحدة تتضمن نصوصاً عديدة.


مثال:

- المتغيرات اللغوية: كلمة (الجنة) heaven وكلمة (النار) hell.
- الاستدلال inference.
- المدونة: القرآن الكريم كاملاً.
- النصوص: ٣٠ نصاً، ويتضمن كل نص جزءاً من أجزاء القرآن الكريم.

ويُهيأ شكل البَيِّنَات كما في الشَّكْل (٢١)، إذ يَتَضَمَّن العمود الأول (النُّصُوص Texts)، ويحمل اسم كُلِّ مَلَفٍّ نَصِّيَّ رقم الجزء في المصحف الشَّريف، ويحتوي على نَصِّ سورة، وبعد الضَّغَط على إنشاء الشَّكْل يخرج تمثيلُ المَحْطَط الخَطِّي الانحداريِّ كما في الشَّكْل (٢٢).

Texts	heaven	hell
1	3	5
2	2	6
3	0	5
...	...	...
30	3	2

شكل ٢١: الجنة والنار بين أجزاء القرآن



شكل ٢٢: المَحْطَط الخَطِّي الانحداريِّ

سادساً: مخطط خطي line chart

يُجرى هذا الشَّكْلُ البياني للإحصاء الوصفي، ولتمثيل هذا المخطط؛ تحتوي البيانات على مُتَغَيَّرَاتٍ لُغَوِيَّةٍ تُقَاس بين نصوص داخل مُدَوَّنَةٍ واحدة، أو بين مُدَوَّنَاتٍ متعدِّدة.


مثال:

- المُتَغَيَّرَاتِ اللُّغَوِيَّة: صيغ (جنة) heaven و(نار) hell في القرآن الكريم.
- الوصف description.
- المُدَوَّنَة: القرآن الكريم كاملاً.
- النُّصُوص: ٣٠ نصًّا، وَيَتَضَمَّن كُلُّ نَصٍّ جزءًا من أجزاء القرآن الكريم.

ويُهيأ شكلُ البَيَّانات كما في الشَّكْل (٢٣)، وَيَتَضَمَّن العمود الأول (النُّصُوص Texts)، ويشير اسم كُلِّ ملفٍّ نصِّيٍّ إلى رقمِ الجزء في المصحف الشَّريف، ويحتوي على نَصٍّ سورة، وبعد الضغط على إنشاء الشَّكْل يخرج تمثيل مخطط خطي كما في الشَّكْل (٢٤).

Corpus	heaven	hell
1	4	6
2	2	6
3	3	6
4	6	10
5	3	3
...	...	...
30	7	9

شكل ٢٣: اشتقاقات الجنة والنار بين أجزاء القرآن



شكل ٢٤: المخطط الخطي

سابعاً: الخريطة الجغرافية geomapping

يُجرى هذا الشَّكْلُ البياني للإحصاء الوصفيّ. ولتمثيل عدد تكرار Frequency الكلمات في المواقع الجغرافية؛ تحتوي البياناتُ على مُتَغَيَّرَاتٍ لُغَوِيَّةٍ بين الأماكن الجغرافية Place، مع تحديد خطّ الطُّول Longitude وخطّ العرض Latitude لكلِّ موقعٍ جغرافيّ.

مثال:


- المُتَغَيَّرَاتُ اللُّغَوِيَّةُ (عدد الكلمات بين السُّورِ المَكِّيَّةِ والسُّورِ المَدَنِيَّةِ).
- المَدُونَةُ: مَدُونَةُ السُّورِ المَكِّيَّةِ، ومَدُونَةُ السُّورِ المَدَنِيَّةِ.
- النُّصُوصُ: ٨٦ نَصّاً (أي سورة مَكِّيَّة) و٢٨ نَصّاً (أي سورة مَدَنِيَّة).

ويُهيأ شكلُ البيانات كما في الشَّكْل (٢٥)، إذ يتضمَّن العمودُ الأولُ السُّورَ المَكِّيَّةَ والسُّورَ المَدَنِيَّةَ، ثم المواقع الجغرافية لمكَّة المَكْرَمَةِ والمَدِينَةِ المَنُورَةِ، ثم إجمالي تكرارات

الكَلِمَاتُ الفِعْلِيَّةُ للمَكِّيَّةِ ثم للمَدَنِيَّةِ، وبعد الضَّغْطِ على إنشاء الشَّكْلِ يخرجُ تمثيلُ الخريطة الجغرافيَّة كما في الشَّكْلِ (٢٦).

Place	Longitude	Latitude	Frequency
Makkiyya	39.826168	21.42251	47642
Madaniyya	39.5692	24.5247	30157

شكل ٢٥: بيانات المواقع الجغرافيَّة^(١)



شكل ٢٦: تمثيل بيانات المواقع الجغرافيَّة

(١) القول الذي يذهب إلى أن السُّورَ المَكِّيَّةَ قد نزلت في مَكَّة، وأن السُّورَ المَدَنِيَّةَ قد نزلت في المدينة، قولٌ ضعيفٌ؛ لأنَّ هناك آياتٍ مَكِّيَّةً قد نزلت في غير مكان مكة، وآياتٍ مدنيَّةً قد نزلت في غير مكان المدينة، والقول الراجح في تصنيف السُّورَةِ المَكِّيَّةِ والسُّورَةِ المَدَنِيَّةِ هو أن التَّصنيف إنما هو باعتبار الرِّمَان، وليس باعتبار المكان، فالسُّورَ المَكِّيَّةَ قد نزلت في الزَّمن الذي سبق زمنَ الهجرة النبويَّة إلى المدينة، والسُّورَ المَدَنِيَّةَ قد نزلت في الزمن الذي تلا زمنَ الهجرة النبويَّة، وهو القول الرَّاجح، وذكره ابنُ النُّقَيْب في مقدمة (تفسيره)، وأخرجه عثمان بن سعد الرازي بسنده إلى يحيى بن سلام. السيوطي. الإتيان في علوم القرآن، تحقيق: شعيب الأرنؤوط، مؤسسة الرسالة: دمشق، ٢٠٠٨، الصفحات ٣٢-٣٢. إذن، فالغرض من التَّصنيف المكانيّ في تمثيل الخريطة الجغرافيَّة هو التَّعريف بأسلوب تمثيل بيانات المُتَغَيِّرات اللُّغويَّة القائمة على خطوط الطُّول وخطوط العرض ليس إلا.

ثامناً: مخطط الأعمدة المرسوفة stacked barchart

يُجرى هذا الشَّكل البياني لتمثيل مُتَغَيَّرَات لُغَوِيَّةٍ ضمن سجلاتٍ لُغَوِيَّةٍ Registers، أي: أكثر من متغيرٍ لُغَوِيٍّ واحدٍ يُقاس بين أكثر من سجلٍ لُغَوِيٍّ (أدب، سياسة، واقتصاد، إلخ).


مثال:

- المُتَغَيَّرَات اللُّغَوِيَّة: صيغ (جنة) heaven و(نار) hell في القرآن الكريم.
- صيغ (جنة) في السُّورِ المَكِّيَّة: الجنة، جنات، جنة، جنتين، جنتان، جنتك، جنتي، جنته.
- صيغ (جنة) في السُّورِ المَدَنِيَّة: جنات، الجنة، جنة، جنتان.
- صيغ (نار) في السُّورِ المَكِّيَّة: النار، ناراً، نار.
- صيغ (نار) في السُّورِ المَدَنِيَّة: النار، ناراً، نار.
- المَدُونَة: مَدُونَة السُّورِ المَكِّيَّة، ومَدُونَة السُّورِ المَدَنِيَّة.
- النُّصُوص: ٨٦ نَصًّا (أي سورة مكية) و٢٨ نَصًّا (أي سورة مدنية).
- المُتَغَيَّرَات المِقْيَاسِيَّة: التَّكَرَّرات المَطلَقة.

ويُهيَّأ شكل البيَّانات كما في الشَّكل (٢٧)، وبعد الضَّغط على إنشاء الشَّكل يظهر تمثيل مخطَّط الأعمدة المرسوفة ك ما في الشَّكل (٢٨).

Register	heaven	hell
Makkiyya	101	82
Madaniyya	57	63

شكل ٢٧: صيغ الجنة والنار بين السُّورِ المَكِّيَّة والسُّورِ المَدَنِيَّة




شكل ٢٨ : مخطط الأعمدة المرصوفة

- المتغيرات اللغوية: صيغ (جنة) heaven و(نار) hell في القرآن الكريم.
- صيغ (جنة) في السُّور المَكِّيَّة: الجنة، جنات، جنة، جنتين، جنتان، جنتك، جنتي، جنته.
- صيغ (جنة) في السُّور المدنيَّة: جنات، الجنة، جنة، جنتان.
- صيغ (نار) في السُّور المَكِّيَّة: النار، ناراً، نار.
- صيغ (نار) في السُّور المدنيَّة: النار، ناراً، نار.
- المدوَّنة: مدوَّنة السُّور المَكِّيَّة، ومدوَّنة السُّور المدنيَّة.
- النُّصوص: ٨٦ نصّاً (أي سورة مَكِّيَّة) و٢٨ نصّاً (أي سورة مدنيَّة).
- المتغيرات المقياسيَّة: التكرارات النسبيَّة.

ويُهيأ شكل البيّانات كما في الشَّكْل (٢٩)، وبعد الضَّغط على إنشاء الشَّكْل يظهر تمثيل مخطَّط الأعمدة المرصوفة كما في الشَّكْل (٣٠).

Register	heaven	hell
Makkiyya	0.189	0.153
Madaniyya	0.168	0.186

شكل ٢٩: صيغ الجنة والنار بين السُّور المكيّة والسُّور المدنيّة



شكل ٣٠: مخطط الأعمدة المرصوفة

تاسعاً: خطوط المؤشر sparklines



يُجرى هذا الشَّكل البياني لتمثيل سلسلة اتجاه المتغير اللُّغَوِيّ، وقد تكون هذه السُّلسلة تواريخ زمنيّة متتابعة، أو حالات متتابعة، أو أحداثاً متتابعة، ولتمثيل هذا المخطط؛ تحتوي البياناتُ على متغير لُّغَوِيّ واحد، أو متغيّرات لُّغَوِيّة عديدة.

مثال:

- المُمْتَعِرَات اللُّغَوِيَّة: صيغ (جنة) heaven و(نار) hell في القرآن الكريم.
 - صيغ (جنة) في السُّور المَكِّيَّة: الجنة، جنات، جنة، جنتين، جنتان، جنتك، جنّتي، جنته.
 - صيغ (جنة) في السُّور المَدَنِيَّة: جنات، الجنة، جنة، جنتان.
 - صيغ (نار) في السُّور المَكِّيَّة: النار، ناراً، نار.
 - صيغ (نار) في السُّور المَدَنِيَّة: النار، ناراً، نار.
 - المَدَوْنَة: القرآن الكريم كاملاً.
 - النُّصُوص: ٣٠ نصّاً يُمثّل الثلاثين جزءاً في القرآن الكريم.
 - تمثيل السَّلسَلَة الزمنية: من ١٠٠٠١ إلى ١٠٠٢٣ (أي: السَّنَوات الثَّلاث والعشرون التي نزلت فيها آيات القرآن الكريم).
- ويُهيأ شكل البَيِّنَات كما في الشَّكْل (٣١)، وبعد الضَّغْط على إنشاء الشَّكْل يظهر تمثيل خطوط المؤشر كما في الشَّكْل (٣٢).

Candle	heaven	hell
0001_0002	3	1
0002_0003	2	3
0003_0004	0	0
0004_0005	0	0
0005_0006	2	0
...	...	...
0023_0024	12	10

شكل ٣١ : صيغ الجنة والنار بين السنوات الزمنية (١-٢٣)



شكل ٣٢ : خطوط المؤشر

عاشراً: مخطّط الشموع candlestick plot

يُجرى هذا الشَّكْل البياني لتمثيل سلسلة اتجاه المُتَغَيِّر اللُّغَوِيّ، وقد تكون هذه السلسلة تواريخ زمنيّة متتابعة، أو حالات متتابعة، أو أحداثاً متتابعة. ولتمثيل هذا المخطّط؛ تحتوي البَيِّنَات على متغَيِّر لُّغَوِيّ واحد، أو مُتَغَيِّرَات لُّغَوِيّة عديدة.


مثال:

- المُتَغَيِّرَات اللُّغَوِيّة: صيغ (جنة) heaven و(نار) hell في القرآن الكريم.
- صيغ (جنة) في السُّور المكيّة: الجنة، جنات، جنة، جنتين، جنتان، جنتك، جنتي، جنته.
- صيغ (جنة) في السُّور المدنيّة: جنات، الجنة، جنة، جنتان.
- صيغ (نار) في السُّور المكيّة: النار، ناراً، نار.
- صيغ (نار) في السُّور المدنيّة: النار، ناراً، نار.
- المُدَوِّنة: القرآن الكريم كاملاً.
- النُّصوص: ٣٠ نصّاً يُمثل الثلاثين جزءاً في القرآن الكريم.
- تمثيل السُّلسلة الزمنيّة: من ١٠٠١ إلى ٢٠٢٣ (أي: السَّنَوَاتُ الثَّلَاث والعشرون التي نزلت فيها آيات القرآن الكريم).

ويُهيأ شكل البَيِّنَات كما في الشَّكْل (٣٣)، وبعد الضَّغْط على إنشاء الشَّكْل يظهر تمثيل مخطَّط الشُّموع كما في الشَّكْل (٣٤)، الذي يشير إلى متوسط التكرار لكل متي (جنة) و(نار) في جسم الشمعة، وإلى حجم بقية أعلى القيم وأقلها في الخط المتجهة من أعلى الجسم وأسفله.

Candle	heaven	hell
0001_0002	3	1
0002_0003	2	3
0003_0004	0	0
0004_0005	0	0
0005_0006	2	0
...	...	...
0023_0024	12	10

شكل ٣٣ : صيغ الجنة والنار بين السنوات الزمنية (٢٣-١)



شكل ٣٤ : مخطَّط الشُّموع

الفصل الثاني

تحليل الخطاب

قبل البدء في تطبيقات مقاييس حساب النصّ صاحب اللفظي، أنبه إلى أهميّة معالجة النصّ المراد تحليله، وما سيذكرهنا حول طبيعة هذا النصّ ما هو إلا من بعض التجارب التي طبّقناها، والتي تبين منها أن النصّ المراد تحليله يحتاج إلى معالجة محدّدة بحدود الغرض من تحليل الخطاب. ولأغراض تحليل الخطاب أو النصّ - من وجهة نظري - أربع بنيات خطيّة، وتأخذ كلّ بنية معالجة شكليّة محدّدة.

البنية الشكليّة الأولى: تحليل النصّ الخطابي المكتوب كما هو، الذي لا يتطلّب معالجة قبليّة بالتقطيع، وبفصل المباني النحويّة المتصلة في الكلمات، مثل فصل حرف العطف (و) عن الكلمة التي بعدها.

البنية الشكليّة الثّانية: تحليل النصّ الخطابي الذي يحتاج إلى معالجة آليّة قبليّة قبل تحليله، إما بالتقطيع، أو بإيقاف كلمات لا تفيد في التحليل، مثل الكلمات الوظيفيّة أو غيرها. يفيد التقطيع مثلاً تحليل الإحالات النصّيّة؛ وذلك نظراً إلى وجود ضمائر متّصلة يتطلّب فصلها عن الكلمة؛ وسبب الفصل يتأتّى من طبيعة وظائف أدوات التحليل في كشفها عن الأنماط والأمثلة بخاصيّة النغراميات - التتابعات اللفظيّة - (n-grams). أما استعمال كلمات الإيقاف؛ فيفيد بتحليل الكلمات المعجميّة ذات المحتوى وذات الدلالة المعجميّة، والوقوف على كشف استعمالات الأنماط شبكيّاً في البنية النصّيّة^(١).


(١) لكلمات الإيقاف قوائم مختلفة باختلاف ازدياد عددها أو نقصانه، غير أن مفهومها الدقيق يشير إلى الكلمات الوظيفيّة function words التي لا تدل على معنى بذاتها، بل تدل على وظيفة محدّدة سياقياً عند تلازمها مع الكلمات ذات المحتوى (الكلمات المعجميّة). يُمكن الاستفادة من هذه الدراسة التي قارنت الكلمات الوظيفيّة بين اللغة العربيّة القديمة واللغة العربيّة المعاصرة، وفي مدونة حاسوبية بلغ عدد الكلمات فيها ١٠ ملايين كلمة:

Almujaivel, S. (2019). Grammatical construction of function words between old and modern written Arabic: A corpus-based analysis. Corpus Linguistics and Linguistic Theory, 15(2). 267296-.

البنية الشكلية الثالثة: تحليل الكيانات والموضوعات، ويكون منطلق الغرض فيه الوقوف على أسماء الكيانات (الأشخاص، والمؤسسات، والمنظمات، إلخ)، أو على الموضوعات والتعقيبات عليها (الموضوع-التعليق topic-comment)، وهذه سأرجئها إلى الفصل الثالث من الباب الثاني؛ نظراً لإمكانية تحليلها آلياً باستخدام أداة (أورانج).

البنية الشكلية الرابعة: الخطاب الشفهي والحوارات، وهي بنية تتطلب معالجة ترميزية، وتخلو العربية من مدونة حاسوبية تتضمن نصاً شفهيًا مرموزاً برموز النبر والتنغيم، أو نصاً حوارياً مرموزاً برموز تحليل الحوار، وهذه الرموز تفيده فيما لو كانت هناك مدونة شفوية؛ وفائدتها تتجلى في إمكانية تحليل عينية مفيدة للدراسة، تتسم بمعايير اختيار العيّنات والتّمثيل العادل وعدم الانحياز.

ما الذي سيُطبّق من إحصاءات؟ سيُطبّق في هذا الفصل إحصاءات تتعلّق بعلم الدلالة وتحليل الخطاب، وهي: مقاييس حساب التّصاحب اللّفظي، واستخراج الكلمات المفتاحية (keywords) -المبحث الأول-، وحساب مواءمة المقدّر البيئي -المبحث الثاني-، ويمكن إجراء تلك المقاييس عن طريق اختيار حاسبة التّصاحب (Collocation calculator)، وذلك الحساب عن طريق اختيار حاسبة التّوافق (Agreement calculator) في أدوات (لانكستر) الإحصائية كما في الشّكل (٣٥).



شكل ٣٥: واجهة حساب التّصاحب اللّفظي في (علم الدلالة والخطاب)

المبحث الأول: التّصاحب اللفظي

التّصاحبُ (collocation) يعني الكلمة ومتصاحبها، والكلمة الرئيسة هي منطلق التحليل، والكلمة المتصاحبة (collocate) هي ما جاورت الكلمة على نافذة التّصاحب من يمين الكلمة الرئيسة ومن يسارها، ويمتدُّ من (يم-يس١) إلى (يم-يس٥). يحتوي هذا المبحث على تطبيقاتٍ تتعلّق بالتّصاحب اللفظي. وينقسم المبحث إلى قسمين.

الأول: مُعاملات مقاييس التّصاحب اللفظي.

الثاني: شبكات التّصاحب اللفظي.

أولاً: مُعاملات مقاييس التّصاحب اللفظي

تعمل مقاييس حساب التّصاحب (collocation calculator parameters) على كشف شبكات التّصاحب اللفظي في النّص، واغتمدت على بنية نصّ خالية من التّشكيل، ومعالجة بالتّقطيع (مقطع ستانفورد)؛ لتحليل التّصاحب اللفظي. سأوضّح هنا فائدة كلِّ مُعاملٍ من مُعاملات مقاييس التّصاحب اللفظي، ويبلغ عددها ١٢ مُعاملاً: المتبادل (mutual - MU)، والمعلومات المتبادلة (mutual information MI -)، والمعلومات المتبادلة ٢ (MI2)، والمعلومات المتبادلة ٣ (MI3)، والأرجحية اللوغارثمية (-log likelihood LL)، وقياس -ز (z-score)، وقياس -ت (t-score)، والدايس (Dice)، واللوغ دايس (log dice). ونسبة اللوغارثم (log ratio)، والحساسية الصغرى (minimum sensitivity)، ودلتا ب (delta P).

ما فائدة هذه المقاييس؟ كلُّ مقياس يُخبر عن جانبٍ من جوانب الاعتبار لعلاقة التّصاحب بين الكلمتين، وسيطبّق ذلك على التّصاحب اللفظي (غفور رحيم)، والتّصاحب اللفظي (الباقيات الصّالحات) في مدوّنة القرآن الكريم.

- حجم المُدَوَّنة (٨٧٤٥٦ كلمة فعلية)، وهي مُدَوَّنة معالجة بالتَّقْطِيع كما أُخبرتُ بذلك سابقاً.
- وردت كلمة (غفور) ٥٨ مرّة، وكلمة (رحيم) ٦١ مرّة، والتَّصَاخُب اللَّفْظِي (غفور رحيم) ٤٩ مرّة.
- وردت كلمة (الباقيات) مرّتين، وكلمة (الصّالحات) ٦١ مرّة، والتَّصَاخُب اللَّفْظِي (الباقيات الصّالحات) مرّتين.

— أسئلةٌ مهمّةٌ:

- كيف تعمل مقاييس التَّصَاخُب؟
- كيف تُحسب آلياً في أدوات (لانكستر) الإحصائية؟
- كيف تُفسر كلّ قياس على حدة؟

تعمل مقاييس التَّصَاخُب وفق خمس خطوات:

الأولى: يُحدّد حجم النّافذة للتّصاحب، فمثلاً: (R1-L1) تعني كلمةً على اليمين وكلمةً على اليسار (انظر: شبكات التَّصَاخُب في هذا المبحث)، وأختصرها بالعربية بـ (يم-يس).

الثانية: تُحسب آلياً التّكرّارات الملحوظة (أي المطلقة كما هي) للكلمة ومتصاحبها.

الثالثة: تُوزّع في جدولة تقاطعية تلك التّكرّارات الملحوظة، ويكون في الصّفوف عدد مرّات وجود الكلمة، وعدد مرّات غيابها عن المتصاحبة، ويكون في الأعمدة عدد مرّات وجود المتصاحبة وعدد مرّات غيابها.

الرابعة: تُحسب آلياً التّكرّارات المتوقّعة النّظرية في جدولة تقاطعية.

الخامسة: تُستخرج الأداة مقاييس التَّصَاخُب اللَّفْظِي، وقد جمعت كلّ نتاج (غفور رحيم) و(الباقيات الصّالحات) في جدول واحد (الجدول ١٠).

سأقف على نتائج مقاييس التّصاحب اللّفظي للمثالين، دون الوقوف على خوارزميات كلِّ معامل منها، وسأشير إلى مُنطلق تفسير كلِّ قيمةٍ من تلك القيم، وطريقة الإفصاح بشكلٍ عامٍّ عن قيمة التّصاحب لكلِّ معاملٍ، وكيفية الاعتماد عليه. هناك ستّ حالاتٍ عند استخدام هذه المعاملات لقياس التّصاحب اللّفظي.

جدول ١٠ : مقاييس التّصاحب اللّفظي

الباقيات الصالحات				غفور رحيم			
التكرارات الملحوظة				التكرارات الملحوظة			
المجموع	غياب المتصاحب	وجود المتصاحب		المجموع	غياب المتصاحب	وجود المتصاحب	
2	0	2	وجود الكلمة	58	9	49	وجود الكلمة
87,454	87,395	59	غياب الكلمة	87,398	87,386	12	غياب الكلمة
87,456	87,395	61	المجموع	87,456	87,395	61	المجموع
التكرارات المتوقعة				التكرارات المتوقعة			
المجموع	غياب المتصاحب	وجود المتصاحب		المجموع	غياب المتصاحب	وجود المتصاحب	
2	1.999	0.001	وجود الكلمة	58	57.960	0.040	وجود الكلمة
87,454	87,393.001	60.999	غياب الكلمة	87,398	87,337.040	60.960	غياب الكلمة
87,456	87,395	61	المجموع	87,456	87,395	61	المجموع
مقاييس التّصاحب اللّفظي				مقاييس التّصاحب اللّفظي			
MI3	MI2	MI	MU	MI3	MI2	MI	MU
12.486	11.486	10.486	1,433.705	21.472	15.857	10.242	1,211.233
Dice	Log Dice	Z-score	T-score	Dice	Log Dice	Z-score	T-score
0.063	10.023	53.511	1.413	0.824	13.720	243.4158	6.994
Delta P	MS	Log ratio	LL	Delta P	MS	Log ratio	LL
[0.0.32 ; 0.999]	0.033	10.534	25.141	[0.803 ; 0.844]	0.803	12.587	656.733
p < 0.0001				p < 0.0001			

حالات الاستخدام:

١. لاستنتاج ندرة وحصرية التّصاحب: مقاييس المتبادل (mutual) في عائلة مُعاملات المعلومات: المتبادل (mutual - MU)، والمعلومات المتبادلة (mutual information - MI)، والمعلومات المتبادلة ٢ (MI2)، والمعلومات المتبادلة ٣ (MI3). ولا يُقصد بالندرة والحصرية هنا معنى الضّعف، بل الأهميّة، فحصريّة الذّهب

على ندرته تجعل له قيمةً أعلى من غيره من المعادن^(١). يظهر ناتج المتبادل بقسمة التكرار الملحوظ لكلمة (غفور؛ 49 مرة) على التكرار المتوقع لها (0.040)^(٢). يتغير ناتج هذه القسمة للمعلومات المتبادلة باستخراج (log2) لناتج المتبادل، ويزيد هذا الناتج للمعلومات المتبادلة ٢ باستخراج أس اثنين (س ٢) للتكرار الملحوظ (٤٩) ليكون (2401)، ويزيد للمعلومات المتبادلة ٣ باستخراج أس ثلاثة (س ٣) للتكرار الملحوظ (٤٩) ليكون (117649). انظر إلى ناتج كل معامل كما هو في الآتي:

- المتبادلة: (0.040 + 49) = (1211.233)
- المعلومات المتبادلة: (0.040 + 49) = (10.242 = (log2 (1211.233)
- المعلومات المتبادلة ٢: (0.040 + 2401) = (15.857 = (log2 (59350.4169)
- المعلومات المتبادلة ٣: (0.040 + 117649) = (21.471 = (log2 (2908170.4329)

لماذا هذا التضاعف الأسّي في المعلومات المتبادلة ٢ والمعلومات المتبادلة ٣؟ ولماذا لا يُكتفى بالمتبادلة أو بالمعلومات المتبادلة؟ المتبادلة لا يمكن فهمها دون مُعايرة وضبط، ويصعب تحديد قيمة قوتها بين القيم الأخرى، أما المعلومات المتبادلة فهي منضبطة بين قيم محدودة. أما سبب التضاعف في المعلومات المتبادلة ٢ والمعلومات المتبادلة ٣؛ فعائدٌ إلى طبيعة اللغة في المدونة اللغوية التي يجمعها المحلل للتحليل والاختبار، يُشار

(١) لنعد إلى تجربة أجريتها في عام ٢٠١٥ للنظر في التّصاحّب اللّفظيّ (عاصفة شديدة) و(عاصفة قاشرة)، إذ ظهرت قيمة المعلومات المتبادلة لـ (عاصفة قاشرة) أعلى من التّصاحّب الأوّل، ويُمكن تفسير الحصريّة هنا على أن التّصاحّب الثّاني أندر، فـ (شديد) ترد مع كلماتٍ عديدةٍ من غير (عاصفة) على عكس (قاشرة)، ويُستفاد من مثل هذه التّطبيقات في بناء معاجم التّصاحّب اللّفظيّ، أو التّلازم اللّفظيّ كما يسميه البعض، وذلك بجعل التّصاحّب النادر مقدّمًا في التّمثيل عن التّصاحّبات الشّائعة. انظر: المجيلول، سلطان. (٢٠١٥). البحث اللّغويّ في المدوّنة العرّيّة الحاسوبية بين الممكن والمحمّل والمأمول، صفحة ٢٥٣.

(٢) قيمة التكرار المتوقع بالصورة الأدق هي: 0.0404546441518683853560793010098.

في أدبيات لغويات المدونة إلى أن قيمة المعلومات المتبادلة الدالة تكون من ٣ وأعلى. حسناً؛ ولكن ماذا لو مثلت المدونة عينة لا تحقق هذه القيمة فأعلى؟ هنا نحتاج إلى أن نستعين بالمعلومات المتبادلة^٢، وإن كانت القيمة أقل فيها - وهذا نادر - نستعين بالمعلومات المتبادلة^٣. قد لا تتحقق قيمة ٣ فأعلى للمعلومات المتبادلة في عينة لغوية، وهذا طبيعي، وحينئذ يُحكم إلى القيمة الأعلى عندما لا نستعمل المفاهيم الأسية في المعلومات المتبادلة^٢ والمعلومات المتبادلة^٣. لنأخذ على سبيل المثال (السموات والأرض) بين السور المكّية والسور المدنيّة. يُجرنا قياس المعلومات المتبادلة بالآتي:

التتابع	التكرار في المكّية	التكرار في المدنيّة	المعلومات المتبادلة في المكّية	المعلومات المتبادلة في المدنيّة
السموات والأرض	92	41	0.1758	-0.3305

هنا يُفصح عن أن دلالة المعلومات المتبادلة لهذا التّصاحب في السور المكّية أعلى من دلالاته في السور المدنيّة.

٢. لاستنتاج حصريّة التّصاحب: الدايس (dice)، واللوغ دايس (log dice)، أما قيمة الدايس فتكون بين (0) و(1)، وكلما تناقصت القيمة عن (1) ازدادت معنويّةه الحصريّة. على سبيل المثال: قيمة الدايس للتّصاحب (الباقيات الصالحات) أقل من قيمته في التّصاحب (غفور رحيم)، كلاهما اكتسبا الحصريّة، غير أنّ الأوّل أكثر حصريّة. لا بدّ من التّنبية إلى أنّ تلك القيمتين دالتان لكلّ تصاحب على حصريّتهما في مدوّنة القرآن الكريم، ويتم أخذ اعتبارات الأقلّ عندما ننظر في التّصاحب بين مدوّنتين مختلفتين، أما عند استخدام معامل اللوغ دايس؛ فالمفهوم النظري هو أنّ القيمة التي تظهر تشير إلى أن التّصاحب قد ورد كذا مرّة (حسب قيمة المرات الظاهرة) في كلّ ١٤ ألف كلمة، ويتم تفسير اللوغ دايس مثل تفسير الدايس من جهة الحصريّة.

٣. لاستنتاج أثر وكثرة التّصاحب: قياس -ت (t-score)، وقياس -ز (z-score). بالنسبة لمعامل الأوّل والثّاني، فتكون قيمة ٢ فأكثر وقيمة ٣ فأكثر على التوالي بداية اعتبار الأثر (وليس للحصريّة)، وينطبق حال الأمثلة التي تكون فيها القيمة كما قلنا في المعلومات المتبادلة، فيُفصح عن الأعلى وإن كان أقل من القيم المقترحة، وعادةً تكون قيمة هذين المعاملين قليلةً جدًّا لتأثرها بأحجام المُدوّنّة الكبيرة، فهما مقياسان إشكاليّان عند الاستخدام.

٤. لاستنتاج معنويّة التّصاحب: الأرجحية اللوغارثمية (LL)، ونسبة اللوغارثم (log ratio)، أما الأرجحية اللوغارثمية فكلّ قيمة أعلى من الأخرى تدلّ على معنويّة التّصاحب، وتُفسّر الأرجحية بقيمة الاحتمال، وهل هي دالّة أم لا، فإن كانت أقلّ من ٠,٠٥ فهي دالّة، وإن كانت أعلى فهي غير دالّة، وتُظهر أدوات (لانكستر) الإحصائيّة قيمة الاحتمال مع الأرجحية اللوغارثمية، أما نسبة اللوغارثم فهي نتيجة (log2) لقيمة الأرجحية اللوغارثمية.

٥. لاستنتاج حجم زيادة نموّ تكرار التّصاحب وانخفاضه: الحساسية الصّغرى (minimum sensitivity)، تُعطي قيمة هذا المعامل إشارة إلى أنّها تزيد مع زيادة تكرار التّصاحب، وتنخفض مع زيادة تكرار الكلمة وحدها، أو زيادة تكرار المتصاحب وحده، ونلاحظ أنّ قيمة الحساسية الصّغرى لـ (الباقيات الصالحات) أقلّ؛ وذلك نظراً إلى كثرة تكرار كلمة (الصالحات) وحدها، دون وجود سمة الكثرة للمتصاحب (الباقيات) وحده، فقلّة ورود كلمة (الباقيات) وحدها في مُدوّنّة القرآن الكريم جعلت من القيمة أقلّ مقارنة بقيمتها لـ (غفور رحيم).

٦. لاستنتاج استعمال ثنائيّة الاتجاه: دلتا ب (delta P). يشير هذا الاستنتاج إلى إمكانية استعمال التّصاحب استعمالاً ثنائيّاً الاتجاه كـ (غفور رحيم) و (رحيم غفور)، ويعطينا هذا المعامل قيمتين اثنتين، ونلاحظ أنّ تقارب أو تشابه القيمتين إشارة إلى أن التّصاحب (غفور رحيم) والتّصاحب العكسي (رحيم غفور) لهما

معنى استعمالي، أي أن استعملهما مقبول، على عكس (الباقيات الصّالحات)، فقيمتُهما متباعدة، وليس هناك معنى استعمالي للتّصاحب العكسي (الصّالحات الباقيات)، لماذا دلّ التّصاحب العكسيّ بالقيمتين القريبتين للتّصاحب (غفور رحيم)؟ سبب ذلك يعود إلى وجود التّصاحب العكسيّ بواقع مرّة واحدة في القرآن الكريم، وذلك في قول الله سبحانه وتعالى: ﴿يَعْلَمُ مَا يَلِجُ فِي الْأَرْضِ وَمَا يَخْرُجُ مِنْهَا وَمَا يَنْزِلُ مِنَ السَّمَاءِ وَمَا يَعْرُجُ فِيهَا وَهُوَ الرَّحِيمُ الْغَفُورُ﴾ [سبأ: ٢].

نأتي إلى كيفية استخراج الكلمات المفتاحية؛ قبل ذلك أشير إلى أن الكلمة المفتاحية هي كلمة مميّزة في النّص، وتكتسب هذا التّميّز من كونها فريدة أو رئيسة بوجودها في المدوّنة اللّغوية، ولا أنصح باستخدام الأرجحية اللوغارتمية؛ لأنها وحدها لا تكفي في تفسير الفريدة أو نسبة الفريدة؛ فهي لاستنتاج المعنوية دون استنتاج النّدرّة أو الحصريّة.

سيُطبّق معرفة استخراج الكلمات المفتاحية^(١) في مدوّنة القرآن الكريم بإجراء مقارنة بين مدوّنة السُّور المكيّة ومدوّنة السُّور المدنيّة باستخدام أداة غواص. سنضع مدوّنة

(١) قد يتساءل باحث عن كيفية استخراج ثلاث قوائم من المدوّنات: قائمة الشيوخ، وقائمة الألفاظ الأكاديمية، وقائمة المصطلحات العلميّة؛ يُستعان باستخراج هذه القوائم من المدوّنات التي تتضمّن نصوصاً متعدّدة الأوعية، ومن ضمن أوعيتها نصوص أكاديميّة، ومن المعايير التي تضبط استخراج هذه القوائم هو ما أجرته الباحثة حوراء الجاسم في رسالتها للمجستير بإشرافي. التجربة خير برهان، ولغويات المدوّنة الحاسوبية علمٌ تجريبيّ، وقد سعينا إلى اختبار المقاييس لضبط فواصل تلك القوائم، وباستخدام أدوات وورد سميث (WordSmith Tools)، وتم الوصول إلى مزية كلّ من نسبة اللوج (log ratio)، ومعيّار معلومات بايزي (Bayesian Information Criterion BIC)، ومقاييس التّشتت dispersion. ولمن أراد الاستفادة من نتائج هذا التّحليل التّجريبيّ العودة إلى المرجع الآتي. الجاسم، حوراء. الألفاظ الأكاديمية في المدوّنات العربيّة العلميّة: دراسة حاسوبية تحليلية. (رسالة ماجستير) إشراف: د. سلطان المجيلول. قسم اللغة العربيّة (جامعة الملك سعود)، ٢٠٢٢. الجاسم، حوراء، والمجيلول، سلطان. المدونة الأكاديمية العربية (أواك) Academic Written Arabic Corpus AWAC (قائمة الجاسم والمجيلول للألفاظ الأكاديمية وقوائم الجاسم والمجيلول للمصطلحات العربية العلمية، ٢٠٢٢)، الرابط: <https://www.kaggle.com/hawraaljasim/datasets>؛ والرابط: <https://www.arabic-ai.info/awac> (تاريخ الاسترداد ٢٤ أكتوبر، ٢٠٢٢).

السُّورَ المَدَنِيَّة (المُدَوَّنة الرئيسة)، ومدونة السُّورِ المَكِّيَّة (المُدَوَّنة المرجعية)، ثم سننصّح عن القيم التي نُخبرنا بتميُّز الكلمة أو التّصاحب اللَّفْظِيّ في مُدَوَّنةٍ دون أخرى. تُمكن أداة غواص حفظ النَّتَاج في ملف أكسل، وسأذكر هنا أربعة أمثلة من الكَلِمَات، كُلٌّ مثالي يُعبّر عن مفهوم مهمّ، فبعد إدراك هذه المفاهيم الأربعة؛ سيُصبح اتخاذ قرار أيّ الكَلِمَات تُعدّ مفتاحيّةً، وأيّها لا تُعدّ؛ سهلاً، وهذه الكَلِمَات هي: لفظ الجلالة (الله)، و(كلاً)، و(طاغون)، و(مولاكم). أما القياسات التي أوصي بها فهي: الدايس، واللوغ دايس، ومعامل الغرابة (weirdness coefficient) - الجدول ١١-. سنوضح هذه المفاهيم من خلال هذه الكَلِمَات الأربعة، وقبل ذلك سنوضّح قيم معامل الغرابة ودلالاتها، وتكون قيم معامل الغرابة إمّا (0)، أو (1)، أو قيمة أقلّ من (١)، أو قيمة أعلى من (1)، وإما قيمة (Infinity).

- القيمة (1): تدلّ على أن الكلمة قد وردت وروداً متساوياً في المدوّنتين الرئيسة والمرجعية.
 - قيمة تكون أقلّ من (1): تدلّ على أن الكلمة قد وردت في المدوّنة الرئيسة أكثر من المدوّنة المرجعية.
 - قيمة تكون أعلى من (1): تدلّ على أنّ الكلمة قد وردت في المدوّنة المرجعية أكثر من المدوّنة الرئيسة.
 - القيمة (0): تدلّ على أنّ الكلمة لم ترد في المدوّنة أبداً، سواءً كانت في المدوّنة الرئيسة أم في المدوّنة المرجعية، وإن كانت في إحدى المدوّنتين؛ فقيمة المدوّنة الأخرى ستكون (Infinity) وستكون دالّة على أن الكلمة قد وردت فيها فقط.
- **لفظ الجلالة (الله):** تَكَرَّرَتْ في السُّورِ المَدَنِيَّة أكثر من السُّورِ المَكِّيَّة، وتكون القيمة الأقلّ لكلّ من الدايس واللّوغ دايس للكلمة التي جاء ورودها أقلّ في إحدى المدوّنتين، ونُخبرنا معامل الغرابة بأنّ ورود لفظ الجلالة في المدوّنة الأولى أعلى من المدوّنة الثانية.
- **لفظ (كلاً):** على عكس لفظ الجلالة (الله)، وورودها في المدوّنة الثانية (السُّورِ المَكِّيَّة) أكثر دلالة.

— **لفظ (طاغون):** يُخبرنا معامل الغرابة بالقيمة (Infinity)، وهي تدلُّ على أن الكلمة خاصّة بالمدوّنة الثانية (السُّور المكيّة).

— **لفظ (مولاكم):** يُخبرنا معامل الغرابة بالقيمة (Infinity)، وهي تدلُّ على أن الكلمة خاصّة بالمدوّنة الأولى (السُّور المدنيّة).

كيف يُمكن فرز الكَلِمات المميّزة والكَلِمات المفتاحيّة؟ الجواب: في ملف أكسل، أعد ترتيب الصفوف بناءً على عمود (معامل الغرابة) للمدوّنة الأولى، واجعل التّرتيب من الأقلّ إلى الأعلى رقماً، ويُمكن تطبيق ذلك على بقيّة أعمدة المعاملات؛ لتسهيل قراءة القيم وتفسيرها. لاحظ أن إجراء استخراج الكَلِمات المفتاحيّة ينطبق على استخراج التّصاحبات اللفظيّة.


جدول ١١: المقاييس الموصى بها لاستخراج الغريب

الكلمة	الله	كلا	طاغون	مولاكم
تكرار (مدنية)	1547	4	0	5
تكرار (مكية)	820	45	2	0
التكرار الكلي	2367	49	2	5
دايس (مدنية)	0.0852	0.0002	0	0.0003
دايس (مكية)	0.0297	0.0017	0.0001	0
لوغ دايس (مدنية)	10.4474	1.9473	0	2.2711
لوغ دايس (مكية)	8.9093	4.7828	0.2922	0
الغرابة (مدنية)	2.9751	0.1402	0	Infinity
الغرابة (مكية)	0.3361	7.134	Infinity	0

ثانياً: شبكات التّصاحب اللفظي

تتميّز هذه التقنية بمعرفة أدق لشبكات التّصاحب اللفظي، التي فيها يقوم المحلّل بضبط مقاييس التّصاحب بخطوة واحدة، وتُعتمد هذه التقنية على تحديد

شبكة التّصاحب للكلمة بسلسلة ثابتة من المقاييس، ويُعبّر عنها في لغويّات المدوّنة بمجموعة مقاييس التّصاحب (collocation parameters notation). يُجرى ذلك من خلال أداة صندوق (لانكستر) (النسخة ٦,٠)^(١)، ويمكن تحميل هذه الأداة من صندوق علم الدلالة والخطاب Semantics and discourse كما هو في الشّكل (٣٦).



شكل ٣٦ أداة صندوق لانكستر

(١) هي أداة قائمة بذاتها، وليست شبكيّة، وهي مصاحبة لأدوات (لانكستر) الإحصائيّة، ومن مميّزاتها خاصيّة (GraphColl) شبكات التّصاحب). ويشار عند الإشارة إلى أداة صندوق (لانكستر LancsBox) إلى المراجع الآتية:

Brezina, V., Weill-Tessier, P., & McEnery, A. (2020). #LancsBox v. 5.x. [software]. Retrieved October 24, 2022, from <http://corpora.lancs.ac.uk/lancsbox>.

Brezina, V., Timperley, M., & McEnery, T. (2018). #LancsBox v. 4.x [software]. Retrieved October 24, 2022, from <http://corpora.lancs.ac.uk/lancsbox>.


Brezina, V., McEnery, T., & Wattam, S. (2015). Collocations in context: A new perspective on collocation networks. *International Journal of Corpus Linguistics*, 20(2), 139173-.


يعمل المحلّل اللُّغَوِيّ على تحديد مجموعة مقاييس (بارامترات) التّصاحب بالأسلوب الخطّي الآتي:

الكلمة: الرّسول (المعلومات المتبادلة: قيمة النّقطة الفاصلة cut-off point : ٥، التّكرار: ٣ فأفكر، يم-٥-يس٥، تصفية: لا يوجد، أي: لم تُستخدم كلمات إيقاف)

لننظر إلى نتيجة هذا التّرميز في (ب) من الشّكل (٣٧)؛ ما الذي يُمكن ملاحظته؟ الملحوظ هو أنّ بهذا التّرميز قد تمّ التّصديّ لمتصاحبات مهمّة جاءت مع الكلمة (الرسول) على حجم النافذة المحدّدة، كما أنّ قيمة المعلومات المتبادلة قد حدّدت من (٥) فأعلى؛ لاستبعاد التّصاحب ذي القيمة (٥) فأقل. ومن المتصاحبات المهمّة؛ المتصاحب (وأطيعوا)، و(شهيدا)، و(البلاغ)، و(أنزل)، و(آمنوا). ماذا لو لم نضع تصفيات لمقاييس التّصاحبية؟ النّتيجة ستكون كما في (أ) من الشّكل (٣٧)، إذ ظهرت كلّ التّصاحبات، ومنها الكثير من التّصاحبات التي لا تدلّ على علاقة معنويّة.

(أ)





(ب)

شكل ٣٧ تمثيل التّصاحب من دون مقاييس مجموعة التّصاحب (أ)
وباستخدام مقاييس مجموعة التّصاحب (ب)

المبحث الثاني: موافقة المقدّر البيئي

يُجرى حساب موافقة المقدّر البيئي (inter-rater agreement) لغرض تقدير التّوافق والاختلاف في فهم المقدّرين، ويُطبّق كثيراً في فهم الخطاب، ويهدف إلى تقريب المقصد قدر الممكن؛ كي يُبنى عليه التّحليل. مثال ذلك: لو أن لدينا خطاباً يحتوي على استخدام كلمة في سياقاتٍ عديدة، ويصعبُ على الفرد أن يُحدّد المقصد من هذه الكلمة في تلك السّياقات، كأن يُطرح سؤالٌ عما إن كانت الكلمة دالّةً على معنى إيجابيٍّ، أم دالّةً على معنى سلبيٍّ، يتطلب هنا من محلّل الخطاب أن يبحث عن مُقدّرين اثنين، وكلما كان عدد المقدّرين أكثر من اثنين كان ذلك أفضل، ويطلب المحلّل من كلّ مقدّر أن يحدّد الاختيارية الثنائية (نعم/لا)، كأن يكون التّحديد عما إن كان معنى الكلمة إيجابياً أو سلبياً، مطابقاً أو غير مطابق، صالحاً أو غير صالح، إلى آخره، ثم بعد الحصول على التّقييمات، يُجمع عددُ الموائم وعدد غير الموائم، ولنفترض أن الكلمة قد جاءت في عشرة سياقات، وطلب من المقدّرين تحديد ما هو إيجابيٍّ وما هو سلبيٍّ، ستكون عندئذ هيكلُ البيانات كما في الجدول (١٢)، وكلّما زاد عددُ المقدّرين زادت موثوقيّةُ نتائج المواءمة.

جدول ١٢ : حساب موافقة المقدّر البيئي

رقم الكشف السِّيَاقِيّ	المقدّر الأول	المقدّر الثاني	مطابق / غير مطابق
	إيجابي (١) سلبي (٢)	إيجابي (١) سلبي (٢)	
1	0	1	غير مطابق
2	1	0	غير مطابق
3	1	0	غير مطابق
4	0	0	مطابق
5	1	0	غير مطابق
6	1	1	مطابق
7	1	0	غير مطابق
8	1	1	مطابق
9	0	0	مطابق
10	1	0	غير مطابق
إيجابي	7	3	-
سلبي	3	7	-
الإجمالي	10	10	-

لتطبيق مثال من مُدَوَّنة القرآن الكريم على التّقدير البيئي؛ سأختار كلمةً، ثم سأعتبر المقدّرَين هنا من أهل التّفسير (كتب التّفسير)، وشرحهم لمعنى الكلمة. في الآتي آيتان كريمَتان تتضمّنان كلمة (الغداة).

• قال الله تعالى: ﴿وَأَصْبِرْ نَفْسَكَ مَعَ الَّذِينَ يَدْعُونَ رَبَّهُمْ بِالْغَدَاةِ وَالْعَشِيِّ يُرِيدُونَ وَجْهَهُ ۖ وَلَا تَعْدُ عَيْنَاكَ عَنْهُمْ تُرِيدَ زِينَةَ الْحَيَاةِ الدُّنْيَا وَلَا تُطِعْ مَنْ أَغْفَلْنَا قَلْبَهُ عَنْ ذِكْرِنَا وَاتَّبَعَ هَوَاهُ وَكَانَ أَمْرُهُ فُرُطًا ۝٢٨﴾ [سور الكهف: ٢٨].

• قال الله تعالى: ﴿وَلَا تَطْرُدِ الَّذِينَ يَدْعُونَ رَبَّهُمْ بِالْغَدَاةِ وَالْعَشِيِّ يُرِيدُونَ وَجْهَهُ ۚ مَا عَلَيْكَ مِنْ حِسَابِهِمْ مِنْ شَيْءٍ وَمَا مِنْ حِسَابِكَ عَلَيْهِمْ مِنْ شَيْءٍ فَتَطْرُدَهُمْ فَتَكُونَ مِنَ الظَّالِمِينَ ۝٥٢﴾ [سورة الأنعام: ٥٢].

في الجدول (١٣) معنى كلمة (الغداة) في بعض التفسيرات، مع الإشارة إلى المطابقة من عدمها في شرح المقصود بهذه الكلمة.

جدول ١٣ : حساب موافقة تفسير كلمة (الغداة) في بعض التفسيرات

المعنى السياقي	ابن عباس	ابن كثير	القرطبي	المطابقة
صلاة الصبح	1	0	0	غير مطابق
بين الفجر وطلوع الشمس	1	1	1	مطابق
أول النهار	1	1	1	مطابق

تطابقت التفسيرات في شرح كلمة (الغداة) في المعنيين السياقيين: (الوقت المحدد بين الفجر وطلوع الشمس)، و(أول النهار)، ولم يتطابق تفسير ابن كثير وتفسير القرطبي في المعنى السياقي (صلاة الصبح) مع تفسير ابن عباس. وسيكون شكل البيانات التي تتضمن السياقات والمقَدَّرين حسب الشَّكْل (٣٨)؛ نظراً إلى ضرورة الترميز. الحالة (Case) تشير إلى المعنى السياقي، و(A) تشير إلى تفسير ابن عباس، و(B) تشير إلى تفسير ابن كثير، و(C) تشير إلى تفسير القرطبي. ونُسخ هذه البيانات، ثم تُلصق في موضع حاسبة التوافق (Agreement calculator) كما في الشَّكْل (٣٩). يُختار نوع المتغير التقييمي، والمتغير التقييمي في هذا المثال فنوي ثنائي (٠) أو (١)، وحالته كحالة (نعم/لا).

Case	A	B	C
1	1	0	0
2	1	1	1
3	1	1	1

شكل ٣٨ : ترميزات التفسيرات الثلاث

ظهرت نتيجة الموافقة بنسبة (77.78)، وهي نتيجة قسمة (حالات الموافقة) على (إجمالي عدد الحالات). النتيجة في الأساس تظهر بنسبة 0.7769، ثم تُحوّل إلى نسبة مئوية. ونسبة الموافقة هنا ليست عاليةً، وأيضاً ليست منخفضةً، ويُنصح في نتائج موافقة المقدّر البيئي أن تكون النسبة ٨٠٪ فأعلى.

3 Semantics and discourse Collocations, keywords and lockwords

Collocation calculator #LancsBox Agreement calculator Videos

1. Paste tab delimited data including header row and id column. For help click [here](#).

2. Select the type of judgement variable.

☐ Nominal variable (categories) ☐ Ordinal variable (ranks) ☐ Interval/ratio variable (scale)

Calculate agreement Clear R code

شكل ٣٩: واجهة حساب الموافقة في (علم الدلالة والخطاب)

الفصل الثالث

الارتباط والتجميع ومقارنة المجموعات

يحتوي هذا الفصل على تطبيقات إحصائية؛ لكشف (الارتباط) بين المتغيرات، وتبيان العلاقة بينها، ولتمثيل (التجميع) الذي يبحث في العلاقة من حيث تصنيف المتغيرات وتحديد المسافات بينها، ثم لعرض إحصاءات المقارنة بين المجموعات، ويُقصد بالمجموعات هنا المتغيرات الاسمية أو الترتيبية؛ بوصفها مجموعات، كأن تُقارَن مجموعتان؛ الأولى: للذكور، والثانية: للإناث، في استخدامهما لضمائر المتكلم. يُجرى حساب الارتباط (Correlation calculator) والتجميع (Clusters) في مربع تنوع السجل اللغوي (Register variation) في أدوات (لانكستر) الإحصائية كما في الشكل (٤٠)، أما إحصاء مقارنة المجموعات (Group comparison)؛ فيُجرى في مربع اللغويات الاجتماعية (Sociolinguistics) كما في الشكل (٤١). ولكل إحصاء من هذه الإحصاءات شكل من البيانات يُهيأ في جداول محدّدة الشكل.

Register variation Correlation, clusters and factors

Correlation calculator Clusters MD analysis Videos

1. Paste tab delimited data including header row and id column. For help click [here](#).

2. Select options.

☒ Parametric ☐ Non-parametric

☐ Visualize correlation

Correlate Clear

[R code](#)

شكل ٤٠ : واجهة حساب الارتباط في (تنوع السجل اللغوي)

شكل ٤١ : واجهة مقارنة المجموعات في (اللُّغَوِيَّاتِ الاجْتِمَاعِيَّةِ)

المبحث الأوَّل: الارتباط

يكشف أسلوبُ تحليل الارتباط العلاقة بين المُتَغَيَّرَاتِ، وَيُخْتَلَفُ تحليل الارتباط عن تحليل الانحدار الخطِّي، فالأوَّل يكشف ما إن كان هناك ارتباط أم لا بين المُتَغَيَّرَاتِ اللُّغَوِيَّةِ، أما الثَّاني فيجعلنا نفهم ونُفسِّر هذا الارتباط، كما يجعلنا نتنبأ بحالاتٍ مشابهةٍ له، وسيَتَّضِحُ الفرقُ بينهما في سياق مناقشة تحليل الانحدار الخطِّي في الفصل الرابع.

يُكتشف الارتباط من عدمه بين متغيَّرين أو أكثر بالصَّيْغِ الآتية:

١. هناك ارتباطٌ إيجابيٌّ، ويعني ذلك أنَّ تزايد المتغيِّر الأول مرتبطٌ بتزايد المتغيِّر الثاني في المَدَوْنَةِ اللُّغَوِيَّةِ.

٢. هناك ارتباطٌ سلبيٌّ، ويعني ذلك أنَّ تزايد المتغيِّر الأول مرتبطٌ بتناقص المتغيِّر الثاني في المَدَوْنَةِ اللُّغَوِيَّةِ.

٣. عدم وجود ارتباطٍ أو علاقةٍ، سواءً كان إيجابياً أم سلبياً.

لوجمعنا مُدَوْنَةً تَتَّصَمَنُ رواياتٍ كتبها روائيون، ومدَوْنَةً ثَانِيَةً تَتَّصَمَنُ رواياتٍ كتبتها روائياتٌ، وأردنا مثلاً أن نبحث عن إجابةٍ لأسئلة الارتباط من عدمه لمتغيّر معيّن، وليكن هذا المتغيّر مثلاً استخدام الضّمائر، فإن النتيجة ستتحقق فرضيّة واحدة من ثلاث فرضيات:

الأولى: كلما تزايد استخدام الضّمائر من الروائيين تزايد استخدامها من الروائيات (علاقة الارتباط إيجابية).


الثانية: كلما تزايد استخدام الضّمائر من الروائيين تناقص استخدامها من الروائيات (علاقة الارتباط سلبية).

الثالثة: لا يوجد اتجاه تزايد أو تناقص (لا توجد علاقة ارتباط).

لتطبيق تحليل الارتباط في مُدَوْنَةِ القرآن الكريم؛ تبادر إلى ذهني موضوعُ الارتباط من عدم الارتباط بين استخدامات الأسماء والصفات والأفعال والأدوات والضّمائر بين سور القرآن الكريم، أُختيرت السُّور الطويلة الآتية: البقرة، وآل عمران، والنساء، والمائدة، والأعراف.

سأقف على النوعين المعروفين من تحليل الارتباط؛ ويُعرف الأول بارتباط بيرسون (Pearson)، ويُعرف الثاني بارتباط سبيرمان (Spearman). تُفسّر نتائج الارتباط إما بقيم لا تكون إلا بين (1- و1). وقد جرى في الإفصاح عن وجود الارتباط من عدم الارتباط على أنّ القيمة التي تكون (0.8) فأعلى دالّة بقوة على الارتباط، وهذا ليس بالضرورة ممكناً في البيانات اللّغويّة، إذ تكون القيمة (0.2) دالّة على الارتباط، وعلى أيّ حال؛ فالقيم بين (1-) و(1)، ولنا أن نتصوّر القيم بينها على المسطرة المرسومة أدناه، التي تنتصف عليها القيمة (0)، وفيما قبل الصّفير تكون القيم سالبةً، وتُعبّر عن ارتباطٍ سلبيٍّ، وفيما بعد الصّفير تكون القيم موجبةً، وتُعبّر عن ارتباطٍ إيجابيٍّ. ضع في ذهنك أنّ القيمة بعد الصّفير

كلما زادت واقتربت إلى (1) دلّ ذلك على زيادة الارتباط إيجابياً، ويشير الارتباط الإيجابي إلى علاقة مطردة بين متغيرين أو أكثر، والارتباط السلبي يشير إلى علاقة غير مطردة.



يقترح كوهن^(١) أحجام التأثير الآتية:

● (0) لا تأثير-بدون قيمة

● (±0.1): تأثير صغير

● (±0.3): تأثير متوسط

● (±0.5): تأثير كبير

أولاً: ارتباط بيرسون

يعمل ارتباط بيرسون مع مُتَغَيَّرَات المقياس (scale variables)، ولتهيئة البيانات من أجل معالجتها في أدوات (لانكستر) الإحصائية، تُدخَل البيانات كما في الشَّكْل (٤٢). علماً بأنَّ أرقام الملفات تعكس أرقام ترتيب السُّور في المصحف الشريف، وقيم التَّكرار تعكس التَّكرارات النَّسَبِيَّة في كُلِّ سورة.

Sura	Nouns	Adjectives	Verbs	Particles	Pronouns
2	52.209	3.887	19.406	23.19277	1.305
3	53.024	3.755	18.800	23.23589	1.134
4	53.116	4.134	19.731	22.36142	0.626
5	54.145	4.848	18.735	21.96721	0.304
7	52.193	3.253	19.983	22.91606	1.656

شكل ٤٢: بيانات التَّكرارات النَّسَبِيَّة لأقسام الكلام الرئيسة بين خمس سور طويلة

(1) Cohen, J. (1988). Statistical power analysis for the behavioral sciences. Hillsdale, NJ: Erlbaum, pp. 7980-.


بعد لصق جدول البيانات كما في الشَّكْل (٤٠) في أدوات (لانكستر) الإحصائية في المربع الخاص بحساب ارتباط بيرسون؛ ستظهر النتائج في جدولين؛ في الجدول (١٤) أُخْرِجَت الأداة معامل الارتباط بين المتغيرات (أقسام الكلام)، وفي الجدول (١٥) أُخْرِجَت القيم الاحتمالية للمتغيرات (الأقسام النحوية). أما الشَّكْل (٤٣) فيُمثِّل خريطة حرارية لمعاملات الارتباط بين المتغيرات.

جدول ١٤ : معامل ارتباط بيرسون بين أقسام الكلام

المتغيرات	الأسماء	الصفات	الأفعال	الأدوات	الضمائر
الأسماء	1.00	0.89	-0.69	-0.80	-0.93
الصفات	0.89	1.00	-0.63	-0.78	-0.95
الأفعال	-0.69	-0.63	1.00	0.16	0.54
الأدوات	-0.80	-0.78	0.16	1.00	0.84
الضمائر	-0.93	-0.95	0.54	0.84	1.00

جدول ١٥ : القيم الاحتمالية

المتغيرات	الأسماء	الصفات	الأفعال	الأدوات	الضمائر
الأسماء	-	0.0448	0.1944	0.1052	0.0240
الصفات	0.0448	-	0.2534	0.1176	0.0137
الأفعال	0.1944	0.2534	-	0.7986	0.3487
الأدوات	0.1052	0.1176	0.7986	-	0.0767
الضمائر	0.0240	0.0137	0.3487	0.0767	-



شكل ٤٣ : الخريطة الحراريّة لارتباط أقسام الكلام

كيف تُفسّر قيم الارتباطات؟

يُنظر إلى القيم التي تكون فوق (٠) كونها قيمًا تدلُّ على وجود ارتباطٍ إيجابيٍّ، ثم إلى القيم التي تكون أقلَّ من (٠) كونها تدلُّ على وجود ارتباطٍ سلبيٍّ، ويمثل خريطة الحرارة الارتباط الإيجابي بدرجات اللون الأزرق، والارتباط السلبي بدرجات اللون الأحمر.


ما المتغيّرات التي ترتبط إيجابياً والتي ترتبط سلبياً؟ لا ننظر إلى القيمة (١) بين كلِّ مُتَغَيِّرٍ يقابل نفسه، فلا ننظر إلى ارتباط الأسماء مع الأسماء، فذلك لا معنى له، بل ننظر إلى الارتباطات بين الأقسام النحويّة المختلفة، سيُرتَّب الارتباط الإيجابيُّ، ثم الارتباط السلبيُّ بين الأقسام النحويّة من الأقوى إلى الأضعف لكل الحالات، وفق العرض في الجدول (١٦).

جدول ١٦: الارتباط الإيجابي والارتباط السلبي بين الأقسام النحويّة

الارتباط السلبي من الأقوى إلى الأضعف	الارتباط الإيجابي من الأقوى إلى الأضعف
ارتباط الصفات مع الضمائر والعكس: -0.95	ارتباط الأسماء مع الصفات والعكس: 0.89
ارتباط الأسماء مع الضمائر والعكس: -0.93	ارتباط الأدوات مع الضمائر والعكس: 0.84
ارتباط الأسماء مع الأدوات والعكس: -0.8	ارتباط الأفعال مع الضمائر والعكس: 0.54
ارتباط الصفات مع الأدوات والعكس: -0.78	ارتباط الأفعال مع الأدوات والعكس: 0.16
ارتباط الأسماء مع الأفعال والعكس: -0.69	
ارتباط الصفات مع الأفعال والعكس: -0.63	

الارتباط الإيجابي يعني أنّ تكرار المتغيّر النسبي يزيد مع تكرار المتغيّر النسبي الآخر، والارتباط السلبي يعني أنّ تكرار المتغيّر النسبي عندما يزيد ينقص التكرار النسبي للمتغير الآخر. هذه طبيعة الأقسام النحويّة في النصوص اللغويّة، فالأسماء أكثر ارتباطاً بالصفات، والأفعال أكثر ارتباطاً بالضمائر والأدوات، وذلك في أحوال التكرارات الملحوظة أو التكرارات النسبيّة. في الجدول (١٦) الذي يحتوي على القيم الاحتماليّة؛ دائماً ستلاحظ بأنّ القيم التي تكون أقل من ٠,٠٥، والتي تكون دالّة إحصائيّاً؛ تظهر مع قيم الارتباط الدالّة على الارتباط الإيجابي بقوة (٠,٨ فأعلى)، أو الدالّة على الارتباط السلبي بقوة (-٠,٨ فأعلى).


لنقلص حساب الارتباط ليكون بين الأسماء والصفات للسور المذكورة، وبين الأسماء والأفعال للسور المذكورة. في الشّكل (٤٤) تفسير لنتيجة ارتباط الأسماء والصفات، وفي الشّكل (٤٥) تفسير لنتيجة ارتباط الأسماء والأفعال.



شكل ٤٤: ارتباط الأسماء مع الصفات

التفسير: الارتباط $r = 0.887$ قيمة الاحتمال: 0.0449 (مجال الثقة ٩٥٪: من 0.022 إلى 0.993

الارتباط الخطي: إيجابي



شكل ٤٥: ارتباط الأسماء مع الأفعال

التفسير: الارتباط $r = 0.693$ قيمة الاحتمال: 0.1944 (مجال الثقة ٩٥٪: من -0.978 إلى 0.487

الارتباط الخطي: سلبي

تنبّه إلى الآتي:

- عندما يكون الخطُ غير منحدِرٍ إلى الأعلى أو إلى الأسفل، ويكون مستقيماً في خطّ عرضي؛ فذلك دلالةٌ على عدم وجود ارتباطٍ إيجابيٍّ أو سلبيٍّ.
- يُفيدك حسابُ الارتباط لمعرفة الارتباطات بين المُتغيّرات القياسيّة وبين المُتغيّرات التأويليّة، وقِس ذلك على كثيرٍ من الحالات التي يُمكن تطبيقُ حساب الارتباط عليها.

ثانياً: ارتباط سبيرمان

يعمل ارتباط سبيرمان مع المُتغيّرات الترتيبيّة (ordinal variables)، والتفسير هنا يكون بكشف الارتباط بين السُّور (ترتيب السورة في المصحف الشريف) بدلا من الأقسام النحويّة. إذن، فهية البيانات ستكون كما في الشّكل (٤٦).

POS	2	3	4	5	7
Nouns	52.209	53.024	19.406	54.145	52.193
Adjectives	3.887	3.887	4.134	4.848	3.253
Verbs	19.406	19.406	19.731	18.735	19.983
Particles	23.1928	23.1928	22.3614	21.9672	22.9161
Pronouns	1.305	1.305	0.626	0.304	1.656

شكل ٤٦: بيانات التكرارات النسبيّة لخمس سور طويلة بين أقسام الكلام الرئيسيّة


تظهرُ النتائجُ في جدولين؛ وفي كل جدول عرضٌ للمتغيرات x^2 ، و x^3 إلخ، التي تشير إلى رقم السورة حسب ترتيبها في المصحف الشريف. يتضمّن الجدول الأوّل قيم الارتباط كما في الجدول (١٧)، والثاني يتضمّن قيم الاحتمال كما في الجدول (١٨)، وفي الشّكل (٤٧) خريطة حراريّة عن قيم الارتباط.

جدول ١٧ : معامل ارتباط سبيرمان للمتغيرات الترتيبية

المتغيرات	X2	X3	X4	X5	X7
X2	1.0	1.0	0.7	1.0	1.0
X3	1.0	1.0	0.7	1.0	1.0
X4	0.7	0.7	1.0	0.7	0.7
X5	1.0	1.0	0.7	1.0	1.0
X7	1.0	1.0	0.7	1.0	1.0

جدول ١٨ : القيم الاحتمالية

المتغيرات	X2	X3	X4	X5	X7
X2	-	0.0000	0.1881	0.0000	0.0000
X3	0.0000	-	0.1881	0.0000	0.0000
X4	0.1881	0.1881	-	0.1881	0.1881
X5	0.0000	0.0000	0.1881	-	0.0000
X7	0.0000	0.0000	0.1881	0.0000	-



شكل ٤٧ : الخريطة الحرارية لارتباط أقسام الكلام

كيف نفسّر هذه القيم؟ ظهرت كُلّ القيم (١) بين السُّور، وهي دلالةٌ ارتباطٍ كاملٍ، عدا سورة المائدة التي ظهر ارتباطها بقيمة (٠,٧)، وهي قيمةٌ تظلُّ ذات تأثير كبير. أما قيم الاحتمال فيها فدالةٌ بقوةٍ، عدا سورة المائدة مع بقيّة السُّور، يُفسّر ارتباط سيرمان مثل التفسير المعروض في ارتباط بيرسون.

المبحث الثاني: التّجميع


يُقصد بالتّجميع (clustering) إيجاد المسافات، والوصول إلى إنشاء التّجميعات للكلمات ذات العلاقة. لقد نظرنا في المبحث الأوّل (الارتباط) إلى العلاقة بين الخصائص، وكانت تلك الخصائص أقسام الكلام. وفي التّجميع، سيكون البحث عن العلاقة بين الموضوعات أو المسافات، وكيف تنتمي الكلمات إلى بعضها البعض على أساس ما من حيث قُرب الانتماء أو بُعده.

كيف يُمكن تصنيف الكلمات في المدوّنة اللُّغويّة بناءً على ما نعرفه عن عدد مرّات تكراراتها؟ نعمل على تهيئة البيانات في جداول أكسل بجعل العمود الأوّل محتويًا على المُتغيّرات التأويليّة التي نريد قياس المسافات بينها، بناءً على المُتغيّرات القياسيّة لها. اخترتُ للمُتغيّرات القياسيّة في العمود الثاني (التكرار Frequency) وفي العمود الثالث (التكرارات النسبيّة في كل ١٠٠ كلمة $\text{Relative Frequency} \times 100$)، وفي الشّكل (٤٨) هيئة البيانات التي أدخلت في خيار التّجميع (Clusters) في مربّع تنوُّع السّجل اللُّغويّ (Register variation) في أدوات (لانكستر) الإحصائيّة (الشّكل ٤٩).

ID	Frequency	Relative Frequency (x100)
Moses	136	0.175
Ibrahim	69	0.089
Noah	43	0.055
Joseph	27	0.035
Adam	25	0.032
Jesus	25	0.026
Haroon	20	0.026
David	16	0.021
Soliman	17	0.022
Jacob	16	0.018
Isaac	15	0.017
Ishmael	12	0.014
Saleh	7	0.008
Zakariya	7	0.008
Yahya	7	0.008
Hud	4	0.005
Yunus	4	0.005
Mohammad	4	0.005
Job	4	0.005
Shuaib	4	0.005
Edris	2	0.002
Ilyas	2	0.002
Dhu_Al_kifl	2	0.002
Elisha	2	0.002

شكل ٤٨: بيانات التكرار المطلق والتكرار النسبي لأسماء الأنبياء في القرآن الكريم^(١)

(١) مرة أخرى، لا يمكن تمثيل الكلمات العربية في أعمدة وصفوف جداول البيانات عندما نستخدم لغة آر أو أداة لانكستر الشبكية القائمة بذاتها والمصممة من أكواد لغة آر، وعليه فقد نقلت أسماء الأنبياء إلى الحروف اللاتينية. ينطبق هذا أيضاً على شكل (٥٠). في الآتي ترجمة رؤوس الجدول: التكرار (Frequency)، والتكرار النسبي في كل ١٠٠ كلمة ((Relative Frequency (x100)، وتكرار قيمة زد (Frequency z score)، والتكرار النسبي لقيمة زد (Relative Frequency z score).



شكل ٤٩: واجهة حساب الارتباط في (تنوع السجل اللغوي)

تُقاس المسافات بناءً على نقاط البيانات، فيتمُّ تجميع النقاط ذات القيم الصغرى أولاً، فالكبرى ثانياً. هناك أربعة مناهج للتجميع؛ الأول الربط المنفرد (single linkage)، الذي يعتمد في منطقته من التجميع على أقرب نقطة. الثاني: الربط التام (complete linkage)، الذي يعتمد في منطقته من التجميع على أبعد نقطة. الثالث: الربط المتوسط (average linkage)، الذي يعتمد في منطقته من التجميع على النقاط المتوسطة. الرابع: طريقة وارد (Ward)، التي تعتمد على مراعاة مسافات كل النقاط، وتحسب مجموع المسافات المربعة. يُنصح في المَدَوَّنَات اللُّغَوِيَّة بإجراء طريقة وارد^(١).

لتوضيح أسلوب الإحصاء في نمذجة المسافات؛ يُشار هنا إلى أهمَّ أسلوبيين؛ وهما المسافة الإقليدية (Euclidian Distance)، ومسافة منهاتن (Manhattan Distance). لنأخذ

(1) Gries, S. Th., Newman, J., Shaoul, C. & Dilts, P. (2009). N-grams and the clustering of genres. Presented at workshop on Corpus, Colligation, Register Variation at the 31st Annual Meeting of the Deutsche Gesellschaft für Sprachwissenschaft, March. Divjak, D. & Gries, S. Th. (2006). Ways of trying in Russian: clustering behavioral profiles. Corpus Linguistics and Linguistic Theory, 2(1), 23–60.

على سبيل المثال كلمة (موسى) وكلمة (هارون). يعمل التجميع على البدء بالخطوة الأولى التي بها يُحدّد موقع الكلمة بين محور (س) ومحور (ص) y . تُمثّل قيمة كل كلمة في كل محور وفق ما يُراد قياسه من المسافات. لنفترض أنّ القيمة التي يُراد قياسها للكلمتين هي التكرار لمحور (س)، والتكرار النسبي لمحور (ص): (موسى): [١٧٥:١٣٦]؛ (هارون): [٢٠٠:٢٠٦]. تُحوّل هذه القيم إلى قيمة z (z-score) كما في الشكل (٥٠). تُستخرج هذه القيمة بـ (القيمة) - المتوسط ÷ (الانحراف المعياري للعينة)؛ أي: قيمة التكرار للكلمة - قيمة متوسط التكرارات لكل الكلمات ÷ (الانحراف المعياري لمتوسطات التكرارات لكل الكلمات محلّ التحليل)، لتكون على النحو الآتي:

$$\text{(موسى Moses): } [4.067:3.978]$$

$$\text{(هارون Haroon): } [0.036:0.014]$$

تُستخرج المسافة الإقليدية بين كل كلمة وكلمة أخرى بالحصول على ناتج الجذر التربيعي لـ (مربع مجموع قيمة س للكلمتين) + (مربع مجموع قيمة ص للكلمتين)، وتُستخرج مسافة مناهاتن بالحصول على الناتج لـ (طرح قيمتي س لكل كلمة) + (طرح قيمتي ص لكل كلمة).



$$\text{المسافة الإقليدية: } \sqrt{(4.067 - 0.036)^2 + (3.978 - 0.014)^2}$$

$$\text{مسافة مناهاتن: } |4.067 - 0.036| + |3.978 - 0.014|$$



يُجرى هذا ألياً عند نمذجة المسافات بين المتغيرات، فيعمل النموذج على استخراج نتيجة المسافة الإقليدية أو مسافة مناهاتن، ثم يقيس المسافة بين كل كلمة وكلمة، ثم يجمع الكلمات ذات النقاط الأقرب من بعضها البعض لتكون ضمن تجميع تفريعي واحد كما في الشكل (٥١) للمسافة الإقليدية، والشكل (٥٢) لمسافة مناهاتن، وفي كلا الشكلين؛ مُثّل الرّسم التخطيطي في الجهة اليمنى بدون التحويل إلى قيم z ؛ ومُثّل الرّسم التخطيطي في الجهة اليسرى باختيار التحويل إلى قيم z ، وينتج عن اختيار التحويل تجميعاً أكثر دقة في الحالات التي تكون قيم التكرارات فيها متطرفة، أو التي تكون للمقارنة بين عينات مختلفة تتباين فيها القيم التكرارية.

ID	Frequency	Relative Frequency (x100)	Frequency_z_score	Relative Frequency_z_score
Moses	136	0.175	3.978	4.067
Ibrahim	69	0.089	1.689	1.739
Noah	43	0.055	0.800	0.835
Joseph	27	0.035	0.253	0.279
Adam	25	0.032	0.185	0.210
Jesus	25	0.026	0.185	0.052
Haroon	20	0.026	0.014	0.036
David	16	0.021	-0.122	-0.103
Soliman	17	0.022	-0.088	-0.069
Jacob	16	0.018	-0.122	-0.165
Isaac	15	0.017	-0.157	-0.196
Ishmael	12	0.014	-0.259	-0.288
Saleh	7	0.008	-0.430	-0.443
Zakariya	7	0.008	-0.430	-0.443
Yahya	7	0.008	-0.430	-0.443
Hud	4	0.005	-0.533	-0.536
Yunus	4	0.005	-0.533	-0.536
Mohammad	4	0.005	-0.533	-0.536
Job	4	0.005	-0.533	-0.536
Shuaib	4	0.005	-0.533	-0.536
Edris	2	0.002	-0.601	-0.597
Ilyas	2	0.002	-0.601	-0.597
Dhu_AlKifl	2	0.002	-0.601	-0.597
Elisha	2	0.002	-0.601	-0.597

شكل ٥٠ : حساب التكرارات المطلقة والنسبية المتعددة لأسماء الأنبياء في القرآن الكريم



شكل ٥١: نتائج التجميع بالمسافة الإقليدية



شكل ٥٢: نتائج التجميع بمسافة منهاتن

سؤال سيتبادر حتماً إلى الأذهان؛ وهو ما فائدة التجميع؟ يعتمد التجميع على وضع صورة عامة للمتغيرات اللغوية وفق قيمها، إذ قد تكون هذه المتغيرات بالمئات، وتتضمن قيماً مختلفة، والتجميع يعمل ألياً على وضع كل مجموعة من المتغيرات في تجميع واحد ليكون معيناً في تحليلات لاحقة تروم فهم العلاقات بين المتغيرات اللغوية أو تفسيرها، فلو نظرنا إلى الشكل (٥١)، والشكل (٥٢)؛ سنجد خمس مجموعات في كل رسم تخطيطي من الرسوم الأربعة، تتضمن كل مجموعة منها جميعاً لأسماء الأنبياء المتقاربة، ويعتمد تحديد عدد هذه المجموعات على المحلل البشري، إذ يمكن أن يُحدّد المجموعات لتكون مجموعتين،

أو ثلاث، وقد اخترت خمس مجموعات بتفكير إحصائي أولي؛ كون عدد المتغيرات (أسماء الأنبياء) خمسة وعشرين اسماً، ولأجل توضيح المجموعات؛ كان الهدف أن يكون عدد التجميعات خمسة، التي ستفيد بطبيعة قرب وبعد نقاط أسماء الأنبياء.

المبحث الثالث: مقارنة المجموعات اللغوية

سأناقش هنا تطبيق الإحصاءات المتعلقة بمقارنة المجموعات اللغوية من المدونات اللغوية، وتنقسم هذه الإحصاءات إلى قسمين رئيسيين.

القسم الأول: الاختبارات البارامترية وغير البارامترية.

تنقسم الاختبارات البارامترية (المعتمدة على مقاييس أولية من المتوسطات والانحرافات المعيارية) إلى نوعين من الاختبارات؛ الأول: اختبار-ت (ويلش Welch) للمقارنة بين مجموعتين مختلفتين في استخدامهما متغيراً لغوياً واحداً (التكرار في كل مجموعة). والثاني: تحليل التباين (ANOVA) للمقارنة بين مجموعتين مختلفتين (أو أكثر) في استخدام متغير لغوي (التكرار والرتب في كل مجموعة). وتنقسم الاختبارات غير البارامترية إلى نوعين من الاختبارات؛ الأول: اختبار مان-ويتني U، المعروف أيضاً- باسم اختبار مجموع رتب ويلكوكسون (Wilcoxon rank-sum test) للمقارنة بين مجموعتين مختلفتين في استخدام متغير لغوي (التكرار في كل مجموعة) أو اختبار مجموع رتب ويلكوكسون للمقارنة داخل مجموعة واحدة فيها حالات مختلفة. والثاني: اختبار كروسكال-والاس للمقارنة بين مجموعتين مختلفتين (أو أكثر) في استخدام متغير لغوي (التكرار والرتب في كل مجموعة). يعني مصطلح غير بارامترية، أو (غير مقياسي non-parametric)، أننا لسنا بحاجة إلى أي معرفة عن البارامترات كالتوسط أو الانحراف المعياري للمتغير المعني بالتحليل في المجموع اللغوي⁽¹⁾. لا تحتوي هذه الاختبارات على

(1) Dodge, Y. (2008). The concise encyclopedia of statistics. New York: Springer.

افتراضاتٍ عن التوزيع الطبيعيّ الأساسي للمتغير اللغوي الاجتماعي في المجموع اللغوي، وعن تجانس التباين، ويمكن استخدامها في حالات بيانات المقياس الشديدة الانحراف، أو في حالات البيانات الترتيبية، وبدلاً من التكرارات النسبية يعمل هذان الاختباران بصيغة (الرتب)، ويمكن بسهولة تحويل التكرارات النسبية (متغير المقياس) إلى رتب، على الرغم من أن هذا يأتي على حساب فقدان بعض المعلومات عن الاختلافات الدقيقة بين الحالات للمتحدثين.

تتضمن المجموعتان اللتان ستقارنان بهذه الاختبارات البارامترية وغير البارامترية من مُدَوَّنة القرآن الكريم ما يأتي:

المجموعة الأولى: السُّور المكيّة.

المجموعة الثانية: السُّور المدنيّة.

وتحتوي كل مجموعة على التكرارات النسبية لكلمة (الناس)، وبواقع ١١٦ مرة في السُّور المكيّة و١٢٢ مرة في السُّور المدنيّة^(١). اعتمد على أداة غواص لاستخراج التكرارات النسبية لكلمة (الناس) بين السُّور المكيّة والسُّور المدنيّة، وتكونت النصوص الخام من مجلدين؛ الأول: ويحتوي على ١٣ ملفاً نصياً، وفي كل ملف نصي الجزء الذي يُمثل تقريباً سنة نزول الآيات على مر ١٣ سنة (السُّور المكيّة). الثاني: ويحتوي على ١٠ نصوص، وفي كل ملف نصي الجزء الذي يُمثل تقريباً سنة نزول الآيات على مر ١٠ سنوات (السُّور المدنيّة). في (أ) من الشّكل (٥٣) التكرارات النسبية لكلمة (الناس) على فترة ٢٣ سنة، وهي هيئة البيانات بين المجموعتين التي تُستخدم من أجل إظهار اختبار-ت البارامتري، واختبار مان-ويتني غير البارامتري، أما في (ب) من الشّكل (٥٣)؛ فهي التكرارات النسبية لتلك الفترة، بالإضافة إلى رتبة الحالات من أجل إظهار تحليل

(١) وردت صيغة (الناس) في السُّور المكيّة ٩٢ مرة، وفي السُّور المدنيّة ٩٢ مرة. أُستعمل أداة ستانفورد للتقطيع الآلي من أجل دقة نتائج البحث. ظهرت التابع (ل الناس) ٢٣ مرة في السُّور المكيّة و٢٨ مرة في السُّور المدنيّة، ثم التابع (ب الناس) مرة واحدة في السُّور المكيّة ومرتان في السُّور المدنيّة، ليكون مجموع تكرار الكلمة ١١٦ مرة في السُّور المكيّة و١٢٢ مرة في السُّور المدنيّة.

التباين (ANOVA) البارامتري، واختبار كروسكال-والاس غير البارامتري، وتوضع الرُّتب بشكلٍ تصاعديٍّ بالتَّطابق مع تصاعد التَّكرارات، فمثلاً؛ أعلى تكرارٍ نسبيٍّ هو ٠,٨٩٦٠٦، ورتبته (١)، وأقلُّ تكرارٍ نسبيٍّ هو ٠,١٤٦٩٤، ورتبته (١٦)، أما القيم الصِّفريَّة فهي تُشير إلى عدم ظهور الكلمة بين الآيات الكريمة في رقم السَّنة في عمود (ID).

(أ) بيانات اختبار-ت واختبار مان-ويتني (ب) بيانات تحليل التباين واختبار كروسكال-والاس

ID	MK	Rank_MK	MD	Rank_MD
1	0.00000	0	0.00000	0
2	0.00000	0	0.00000	0
3	0.00000	0	0.00000	0
4	0.00000	0	0.00000	0
5	0.89606	1	0.00000	0
6	0.40161	6	0.00000	0
7	0.14694	16	0.00000	0
8	0.00000	0	0.00000	0
9	0.23271	10	0.00000	0
10	0.22211	11	0.00000	0
11	0.33351	7	0.00000	0
12	0.29775	8	0.00000	0
13	0.15051	15	0.00000	0
14	0.00000	0	0.15473	14
15	0.00000	0	0.00000	0
16	0.00000	0	0.00000	0
17	0.00000	0	0.64725	2
18	0.00000	0	0.52619	3
19	0.00000	0	0.43380	5
20	0.00000	0	0.21834	13
21	0.00000	0	0.45934	4
22	0.00000	0	0.23962	9
23	0.00000	0	0.21952	12

ID	MK	MD
1	0.00000	0.00000
2	0.00000	0.00000
3	0.00000	0.00000
4	0.00000	0.00000
5	0.89606	0.00000
6	0.40161	0.00000
7	0.14694	0.00000
8	0.00000	0.00000
9	0.23271	0.00000
10	0.22211	0.00000
11	0.33351	0.00000
12	0.29775	0.00000
13	0.15051	0.00000
14	0.00000	0.15473
15	0.00000	0.00000
16	0.00000	0.00000
17	0.00000	0.64725
18	0.00000	0.52619
19	0.00000	0.43380
20	0.00000	0.21834
21	0.00000	0.45934
22	0.00000	0.23962
23	0.00000	0.21952

شكل ٥٣: بيانات اختبارات المجموعة البارامتريّة وغير البارامتريّة

يحتوي اختبار-ت على افتراضاتٍ ينبغي مراجعتها قبل إجراء الاختبار، والافتراض الأهم هو استقلال الملاحظات (independence of observations)، ويشير هذا الاستقلال في السياق اللُّغَوِيّ الاجتماعيّ إلى كُلِّ ملاحظةٍ تنتمي إلى متحدثٍ واحدٍ أو مجموعةٍ لُّغَوِيَّةٍ واحدةٍ، شرط أن تكون كُلِّ ملاحظةٍ من متحدثٍ معيّنٍ أو مجموعةٍ معينةٍ غير متأثرةٍ بمتحدثٍ آخر، أو بمجموعةٍ لُّغَوِيَّةٍ معينةٍ.

نتيجة اختبار-ت

- ت $t(43.9) = -0.15$ ، القيمة الاحتمالية = 0.878 (غير دالٍ إحصائياً)
- كوهن د (حجم الأثر) = -0.05 (مجال الثقة ٩٥٪ $[-0.64, 0.55]$ الأثر متوسط)
- الارتباط (حجم الأثر) = -0.02 (مجال الثقة ٩٥٪ $[-0.32, 0.28]$ الأثر متوسط)

تشبه افتراضات تحليل التباين (ANOVA) اختبار-ت، وهذه الافتراضات هي استقلال الملاحظات، والحالة الطَّبيعية، والتَّفاوت المتماثل، والأهم من بينها هو استقلال الملاحظات.

نتيجة تحليل التَّباين (ANOVA) اتجاه أحادي One-way

- التباين الاتجاه الأحادي: $F(٣, ٨٨) = ٥,٠٥$ ، القيمة الاحتمالية = $٠,٠٠٣$ (دالٍ إحصائياً)
- قياس حجم الأثر (أوميغا w) = $٠,٣٤١$ (حجم الأثر متوسط)
- الاختبار البعديّ (post-hoc tests) الذي يهدف إلى تقليل احتمالات الدلالة الإحصائية عند استعمال فرضيات اختبارية عديدة): اختبارات المعدل (القيم الاحتمالية).

المجموعات	المدنيّة	المكيّة	رتب المدنيّة
المكيّة	1.000	-	-
رتب المدنيّة	0.092	0.090	-
رتب المكيّة	0.023	0.022	1.000

نتيجة اختبار مان-ويتني

- اختبار مان-وتني = 258.5، والقيمة الاحتمالية = 0.887 (غير دال إحصائياً)
- حجم الأثر (الارتباط r) - 0.209 (الأثر صغير)

نتيجة اختبار كروسكال-والاس

- اختبار كروسكال-والاس = 1.39، والقيمة الاحتمالية = 0.707 (غير دال إحصائياً)


القسم الثاني: تحليل التناظر

هو لتحليل المُتَغَيَّرَات اللُّغَوِيَّة التي تتقارب أو تتباعد، ويهدف إلى الكشف عن التفرد الأسلوبيّ اللُّغَوِيّ من المصدر اللُّغَوِيّ لتلك المُتَغَيَّرَات اللُّغَوِيَّة، سواءً كان هذا المصدر جنس المتحدّث، أو طبقات المتحدثين الاجتماعيّة، أو أوعية نصيّة مختلفة (المُتَغَيَّرَات التَّأْوِيلِيَّة) إلخ، وبالنسبة للمُتَغَيَّرَات التي ستُحلَّل فهي التَّكَرَّرات المطلقة لأقسام الكلام الأربعة (الأسماء، والصفات، والأفعال، والأدوات)، بين السُّوَر السبع الطوال: (البقرة، وآل عمران، والنساء، والمائدة، والأنعام، والأعراف، والأنفال-التوبة).

الهدف هنا هو الكشف عن تفرّد الأسلوب اللُّغَوِيّ بين أقسام الكلام الأربعة، وستُطبّق هنا المقارنة بين السُّوَر السبع الطوال، وملاحظة تجمّع هذه السُّوَر كسبع عِيَنَات، وحجم تفرّد كلّ عِيَنَةٍ في استخدام الأسماء والصفات والأفعال والأدوات (الشكل ٥٤).

File	Nouns	Adjectives	Verbs	Particles
1	3640	271	1353	1617
2	2104	149	746	922
3	1207	132	630	714
4	2312	207	800	938
5	1696	132	630	714
6	1797	112	688	789
7	4099	372	1636	1793

شكل ٥٤: بيانات أقسام الكلام الرئيسة بين السور الطويلة



شكل ٥٥: تحليل التناظر

نلاحظ في الشَّكْل (٥٥) أنَّ العامل الأول هو عامل السُّور السبع الطوال، ونسبة التَّنَاطُر بينها ٤٩,٦، والعامل الثاني هو عامل أقسام الكلام، ونسبة التَّنَاطُر بينها ٤١,٢، ويُقصد بالتناظر هنا مستويات التماثل من عدمه. كيف نفسر هذا التَّمثيل البياني؟ نقول الآتي:

- تميزت السُّور ٤ و٥ بالأسماء أكثر من بقية السور السبع.
- كان تميز السُّور ٤ ثم ٥ بالأسماء أعلى من السُّور ٢ ثم ١ ثم ٦.
- تميزت السُّور ٣ بالصفات أكثر من بقية السُّور.
- تميزت السُّور ٧ بالأفعال والأدوات.

يُستنتج من هذا التفسير بأن الأسماء بين السُّور السبع الطوال قد ظهر بُرُوز استخدامها في سورة المائدة والأنعام أكثر من سورة البقرة وآل عمران والأعراف، كما يُستنتج بأن الصفات في سورة النساء أكثر بروزاً من بقية السور، أما السورة السابعة (الأنفال-التوبة) فأكثر أقسام الكلام فيها بروزاً هو الأفعال والأدوات.

الفصل الرَّابِع الانحدار

بما أنَّ الارتباط يُخبرنا بالعلاقة غير السببية بين المُتغيَّرات، وبنسبة هذا الارتباط فيما إن كان إيجابياً أم سلبياً أم منعدماً؛ فإنَّ الانحدار يُخبرنا عن العلاقة السببية بين المُتغيَّرات، وعن شكل هذا الخطِّ الانحداريّ، بين المُتغيَّر المُستقلِّ (المتنبّي) والمتغيَّر التَّابع (النَّاتج)، الذي يفيدُ إما بوجود علاقة حَظِيَّة، أو بعدم وجود علاقة حَظِيَّة. وتُفيدُ هذه العلاقة الحَظِيَّة بأنَّ هناك علاقة سببيَّة، أي أنَّ المُتغيَّر المُستقلِّ (المتنبّي) يؤثرُ في المُتغيَّر التَّابع (النَّاتج) وبأنَّه من الممكن التنبُّ بهذا التأثير، أو تُفيدُ بعدم وجود علاقة حَظِيَّة سببيَّة. ويُبنى نموذجُ الانحدار لأغراض التفسير والتنبُّ، وهو من أهم النماذج في التنبُّ، وينقسمُ الانحدار إلى نوعين: الأوَّل: الانحدار الحَظِيّ (المبحث الأوَّل)، والثَّاني: الانحدار اللُّوجسْتِيّ (المبحث الثَّاني)، وسأتناول هذين النوعين من الانحدار، وكيفيَّة الاستفادة منهما في تحليل البيانات اللُّغويَّة، وذلك بالتَّطبيق على مُدوَّنة القرآن الكريم.

المبحث الأوَّل: الانحدار الحَظِيّ

لم يضع مصمِّم أدوات (لانكستر) الإحصائيَّة أداة جاهزة تُنسَخُ فيها البيانات لاستخراج نتائج تحليل الانحدار الحَظِيّ، ولذلك سأشيرُ هنا إلى مفهوم الانحدار الحَظِيّ، وطبيعة شكل البيانات اللُّغويَّة، وما تتضمَّنُه هذه البيانات من مُتغيَّرات، مع أكواد التَّحليل من الآر للتَّطبيق (الملحق ج: الفصل أكواد الفصل الرَّابِع).

يُستخدم تحليلُ الانحدار الحَظِيّ في مهمَّتين؛ الأولى: أن يتعلَّم كيف يتنبَّأ بالقيمة مقابل قيم حقيقيَّة، وهذا يُطبق في تعلُّم الآلة. والثَّانية: التنبُّ بقيمة مُتغيَّر بناءً على قيمة مُتغيَّرٍ آخر، وهذا يُسمى باختيار السَّمة (feature selection)، وهو ما يُطبَّق في اللُّغويَّات التجريبيَّة والنَّفسيَّة كثيرًا، ويكون المُتغيَّر الذي يراد التنبُّ به هو المُتغيَّر التَّابع، ويكون المُتغيَّر الذي يُعتمدُ عليه في التنبُّ هو المُتغيَّر (أو المُتغيَّرات) المُستقلِّ (المتنبّي)، وتكون العلاقة حَظِيَّةً عند تأثُّر المُتغيَّر التَّابع (النَّاتج) بالمُتغيَّر المُستقلِّ.

الانحدار الخطّي إما انحدار خطّي بسيط (متغير مستقل واحد ومتغير تابع واحد)، أو انحدار خطّي متعدّد (متغيرات مستقلة ومتغير تابع واحد)، ودائماً يكون المتغير التابع واحداً، ويُفيد الانحدار الخطّي دقّة الاستدلال فيما إن كانت هناك علاقة سببية واضحة بين المتغير المستقل والمتغير التابع.

يجب أن تكون المتغيرات المستقلة مستمرة (continuous)، وفي حال كانت هناك متغيرات مستقلة فئوية فلا يتعامل معها الانحدار الخطّي، ويُحتاج في هذه الحال إلى تحويلها إلى مستمرة عن طريق الترميز (encoding)، الذي يُحول البيانات الفئوية إلى بيانات رقمية بواسطة ما يعرف بـ (label encoding)، أو (one hot encoding)، أو (dummy variable trap)، ولن أقف على المتغيرات الفئوية، وكيفية تحويلها إلى متغيرات رقمية^(١)؛ والسبب يعود إلى عدم فائدتها في اللغويات التجريبية والمُدونات اللغوية، إذ يكون البديل الأمثل لها هو باستعمال الانحدار اللوجستي (المبحث الثاني من هذا الفصل).

هِيئَت بيانات الانحدار الخطّي من مُدَوّنة القرآن الكريم كما في الشّكل (٥٦) على النّحو الآتي:

- الزمن chronology (ترتيب السّورة حسب نزولها زمنياً): متغير مستقل مستمر.
- الوقت time (نزول السّور المكيّة ونزول السّور المدنيّة): متغير مستقل فئوي.
- الآيات verses (عدد آيات كلّ سورة): متغير مستقل مستمر.
- الكلمات words (عدد الكلمات في كلّ سورة): متغير مستقل مستمر.
- السّجدة prostration (السّور التي تتضمّن سجدة): متغير مستقل فئوي.

(١) لمن يطلب الفائدة في التّعامل مع المتغيرات الفئوية في الانحدار الخطّي:

Kumar, Sudhir. 2020. Linear Regression Tutorial (Medical Cost Personal Datasets). Retrieved October 24, 2022, from <https://www.kaggle.com/sudhirn17/linear-regression-tutorial>

- الطول length (سور قصيرة، وسور متوسطة، وسور طويلة): مُتَغَيِّرٌ مُسْتَقِلٌّ فَنَوِيٌّ.
- الحروف characters (عدد الحروف في كُلِّ سورة): مُتَغَيِّرٌ تَابِعٌ مُسْتَمِرٌّ.

أسلفنا القولَ عن عدم تعامل الانحدار الخطي مع المُتَغَيِّرَاتِ المُسْتَقِلَّةِ الفُنَوِيَّةِ، إذ لها حالةٌ خاصَّةٌ غير مهمَّةٍ في تحليلِ البَيِّنَاتِ اللُّغَوِيَّةِ، ولذلك تُستبعد من البَيِّنَاتِ، ويُطرح السُّؤال المتعلِّق بإمكان التنبُّو من عدم الإمكان على النحو الآتي: هل يُمكن التنبُّو بوجود علاقة سببٍ تُفيد بتأثر المُتَغَيِّرِ التَّابِعِ (النَّاتِج) من المُتَغَيِّرَاتِ المُسْتَقِلَّةِ (المتنبَّئة)؟ لننظر إلى المُتَغَيِّرَاتِ المُسْتَقِلَّةِ (المتنبَّئة): الزَّمن (chronology)، وعدد الآيات (verses)، وعدد الكلمات (words)، ثم إلى المُتَغَيِّرَاتِ التَّابِعَةِ (النَّاتِج): عدد الحروف (characters). ويتطلَّب كشف الارتباط بين هذه المُتَغَيِّرَاتِ قبل بناء نموذج الانحدار الخطي. والسُّؤال المصوغُ هنا: (هل تأثر المُتَغَيِّرِ التَّابِعِ يُمكن تفسيره والتنبُّو به بقيم المُتَغَيِّرَاتِ المُسْتَقِلَّةِ؟).

نتيجة الارتباط: ترتيب الارتباط الإيجابي والسلبي بدءاً من الأقوى حتى الأضعف:


- ارتباط عدد الكلمات مع عدد الحروف: 1.0
- ارتباط عدد الكلمات مع عدد الآيات: 0.970
- ارتباط عدد الآيات مع عدد الحروف: 0.966
- ارتباط الزَّمن مع عدد الحروف: 0.048
- ارتباط الزَّمن مع عدد الكلمات: 0.048
- ارتباط الزَّمن مع عدد الآيات: -0.34

نتيجة النموذج الخطي: بناءً على الشَّكْل (٥٧) الذي يتضمنُ تمثيلاً للارتباط بين المُتَغَيِّرَاتِ؛ لا يُمكن التنبُّو بتغير عدد الحروف (المتغير التَّابِعِ والنَّاتِج)، وفقاً للمُتَغَيِّرَاتِ


المُسْتَقْلَة (المتنبئة)، ولكن كيف يُعرف فيما إن كانت هناك علاقة حَظِيَّة أم لا؟ بالنظر في المتبقّيات -أو المختلفات- (residuals) من النّموذج الموفّق -أو المتوائم- (fitted model) وفي الاختلافات بين قيم المُتغيّر النَّاتج الملحوظ في كلّ مجموعة من قيم المُتغيّرات المُستقلّة (الشّكل ٥٨)؛ يُشير التّمثيل البيانيّ في الجهة اليسرى إلى الأنماط غير الحَظِيَّة في القيم المتبقّيّة (residuals)، والعلاقة هنا غير حَظِيَّة، وعندما تكون العلاقة حَظِيَّة؛ فإنّ الخطّ باللون الأزرق سيكون منحدرًا أو مائلًا (slope) من الأسفل إلى الأعلى، ومتراكبًا مع قيم الـ (residuals). إذن؛ عندما يكون الخطّ باللون الأزرق متراكبًا مع نقاط القيم المتبقّيّة بشكلٍ خطّي؛ فذلك يدلّ على العلاقة الحَظِيَّة؛ أي على تأثير المُتغيّرات المُستقلّة (المتنبئة) على المُتغيّر النَّاتج (النّاتج)، وعندما يظهر هذا التأثير فذلك يُمكن أوّلاً من تفسير التأثير؛ كونه واقعًا، ومن التّنبؤ ثانياً بأنّ هذا المُتغيّر المُستقلّ، أو تلك المُتغيّرات المُستقلّة، لها تأثيرٌ سببيّ في تعيّر قيم المُتغيّر النَّاتج التّابع. ومثل هذا الأسلوب الإحصائيّ يُطبّق بالدرجة الأولى على البيانات اللّغويّة المرتبطة باللّغويّات النفسيّة، وباكتساب اللغة، كأن تُقيّم وجودَ العلاقة الحَظِيَّة من عدم وجودها بين مُتغيّراتٍ مستقلّة من قبيل (عدد ساعات التعلّم والأعمار)، وبين المُتغيّر التّابع من قبيل (الزّمن المستغرق في قراءة واستيعاب فقرة في قطعة نصّيّة للقراءة)، في التّمثيل البيانيّ الأيمن ما يُسمّى بـ (Q-Q plot)، وهو اختصارٌ لـ (quantile-quantile plot)، الذي يُقارن الكميّات النّظريّة والكمّيّات التّجريبية التي نحصل عليها من البيانات، ونلاحظ في المخطّط الذي ظهر في البيانات المستخدمة، بعد مقارنة توزيع النّقاط للبقايا (residuals) مع التّوزيع الطّبيعيّ (الخط المرجعي reference line)، وجودَ نقاطٍ بعيدة نسبياً على يسار ويمين الخط المرجعيّ، لكنها لا تُشكّل انحرافاتٍ حادّة عن التّوزيع الطّبيعيّ.

chronology	time	verses	words	prostration	length	characters
5	MK	7	10	no	short	139
87	MD	286	1000	no	long	25613
89	MD	200	1000	no	long	14605
92	MD	176	1000	no	long	15937
112	MD	120	1000	no	long	11892
55	MK	156	1000	no	long	12418
39	MK	206	1000	yes	long	14071
88	MD	75	1000	no	long	5299
113	MD	129	1000	no	long	10873
51	MK	109	1000	no	long	7425
...	...		...	...	...	...

شكل ٥٦: بيانات الأنجدار الخطّي



شكل ٥٧: تمثيل الارتباط والنموذج الخطي



شكل ٥٨ : مخطط الرّبعيّات Normal Q-Q والتمثيل الخطي للمتبقّيات residuals مقابل القيم الموفقة للنموذج

المبحث الثَّانِي: الانحدار اللُّوجِسْتِيّ

يعملُ هذا الانحدار مثل التّصنيف، وتَتَضَمَّنُ بياناته مُتَغَيَّرَاتٍ فُتُوِيَّةً للمتغيّر المُسْتَقِلَّ (المتنبّي)، والمتغيّر التّابع (النّاتج)، وعندما يكون المُتَغَيَّرُ التّابع فُتُوِيًّا ثنائيًّا؛ فعندئذٍ يُسمّى بالانحدار اللُّوجِسْتِيّ الثَّنَائِيّ الاتجاه (binomial logistic regression)، وعندما يكون في المُتَغَيَّرُ التّابع أكثر من فئة؛ فعندئذٍ يُسمّى بالانحدار اللُّوجِسْتِيّ متعدّد الاتجاه

(multinomial logistic regression)، وغالباً يُجرى الانحدار اللوجستي الثنائي الاتجاه، ويُجرى على موضوعات النحو المعجمي في المدونات اللغوية، وهدف الانحدار اللوجستي مثل هدف الانحدار الخطي، يُخبرنا عن المتغير المستقل الذي يؤثر أكثر في المتغير التابع، ولا تكون المتغيرات في الانحدار اللوجستي إلافئوية (سنرى في الباب الثاني في الفصل الخامس جانب تعلم الآلة للانحدار). سأطبق مثالين للانحدار اللوجستي لأجل التوضيح.

المثال (أ): تتكوّن فيه البيانات من متغيرين مستقلّين (متنبّات)، ومتغير تابع (نتائج) واحد.

- المتنبّي (الوقت time): (المكي a_MK) و(المدني b_MD)
- المتنبّي (الطول length): (طويلة a_long) و(متوسطة b_medium) و(قصيرة c_short)
- النّاتج (السّجدة prostration): (لا a_no) و(نعم b_yes)

المثال (ب): تتكوّن فيه البيانات من ثلاثة متغيّرات مستقلّة (متنبّات)، ومتغير تابع (نتائج)

- المتنبّي (التنوّع Variety): (سورة النساء a_3) و(سورة الأعراف b_7)
- المتنبّي (التركيب Syntaxt): (جملة الفعل الماضي a_past) و(جملة الفعل المضارع b_present) و(الجملة الاسمية c_nominal)
- المتنبّي (الطول Length): (طول الكلمة الأولى من الجمل وترواح بين ٢ و٧)
- النّاتج (الاسم الموصول Relative): (ما a_mā) و(الذي b_alladhī)

في الشّكل (٥٩)؛ سترى شكل البيانات اللّغويّة للمثال الأوّل كما هو في (أ)، وشكل البيانات اللّغويّة للمثال الثاني كما هو في (ب). يُلصق الشّكل (أ) في خيار الانحدار اللّوجستي (Logistic regression) من مربّع النحو المعجمي (Lexico-grammar) في أدوات (لانكستر) الإحصائية كما في الشّكل (٦٠). في الخيار (١) سؤال يتضمّن الآتي: اختر ماذا

تريد أن تفعل ؟ (Select what you want to do). تظهر قائمة منسدلة فيها (بناء نموذج Build a model)، و(بناء نموذج تدريجي Build a model stepwise). يُظهر (بناء النموذج) نتيجة المتغيرات كلها، ويُظهر بناء النموذج التدريجي أي المتغيرات المتنبئة (المستقلة) أفضل من ناحية تأثيرها في المتغير الناتج (التابع). عند بناء نموذج؛ تلصق البيانات في الخيار (٢)، ثم يُكتب اسم المتغير الناتج (التابع) في الخيار (٣)، ثم يُكتب في الخيار (٤) أسماء متغيرات المتنبئ (المتغيرات المستقلة) مفصولةً بفاصلة منقوطة (؛) من دون مسافات، ثم اختيار (no) في الخيار (٥).

(ب)

ID	Variety	Syntax	Length	Relatives
1	a_3	a_past	3	a_mā
2	a_3	a_past	3	a_mā
3	a_3	a_past	3	a_mā
4	a_3	a_past	3	a_mā
5	a_3	a_past	3	a_mā
6	a_3	a_past	3	a_mā
7	a_3	a_past	3	a_mā
8	a_3	a_past	3	a_mā
9	a_3	a_past	3	a_mā
10	a_3	a_past	3	a_mā
11	a_3	a_past	3	a_mā
12	a_3	a_past	3	a_mā
13	a_3	a_past	3	a_mā
14	a_3	a_past	3	a_mā
...	...	...	...	...
98	b_7	b_present	4	b_alladhī
99	b_7	b_present	4	b_alladhī
100	b_7	b_present	4	b_alladhī
101	b_7	c_nominal	7	b_alladh

(أ)

ID	time	length	prostration
1	a_MK	c_short	a_no
2	b_MK	a_long	a_no
3	b_MK	a_long	a_no
4	b_MK	a_long	a_no
5	b_MK	a_long	a_no
6	a_MK	a_long	a_no
7	a_MK	a_long	b_yes
8	b_MK	a_long	a_no
9	b_MK	a_long	a_no
10	a_MK	a_long	a_no

شكل ٥٩: الانحدار اللوجستي

4 Lexico-grammar From simple counts to complex models

Cross-tab Categories comparison Logistic regression Videos

1. Select what you want to do. For help click [here](#).

Build a model

2. Paste data in the text area.

3. Type in the exact name of the outcome variable.

4. Type in the exact name(s) of the predictor(s) [use ; as separator].

5. Decide if you want to include predictor interactions.

☐ Yes, include all ☐ Yes, include some ☒ No

6. Type in the exact name of the predictor(s) interaction [use ; as separator].

Build model Clear

شكل ٦٠ واجهة الانحدار اللوجستي في (النحو المعجبي)

أولاً: نتيجة المثال (أ)

• بناء النموذج للانحدار اللوجستي

إحصاءات النموذج: الأرجحية اللوغارتمية: 6.11 (القيمة الاحتمالية = 0.106: غير دال)
إحصائياً، C-index: 0.69 (غير مقبول)، ناغليريك R^2 : 1, 0، AIC: 86.82.

جدول ١٩: معاملات النموذج للبيانات (أ)

مجال الثقة ٩٥٪ (الأعلى)	مجال الثقة ٩٥٪ (الأقل)	تقدير الأرجحية	قيمة الاحتمال	قيمة -ز (والد)	خطأ المعيار	تقدير الأرجحية اللوغارتمية	
0.909	0.105	0.335	0.043	-2.026	0.540	-1.093	(Intercept)
1.519	0.053	0.366	0.218	-1.233	0.815	-1.004	timeb_MK
2.103	0.163	0.567	0.375	-0.887	0.640	-0.568	lengthb_medium
0.774	0.005	0.110	0.054	-1.924	1.147	-2.207	lengthc_short

● بناء النموذج التدريجي stepwise (النموذج الأفضل)

الإحصاءات الكليّة: الأرجحية الاحتمالية: 4.3 (القيمة الاحتمالية = 0.116 غيردالّ إحصائياً)، C-index: 0.64 (غيرمقبول)، ناغلكيرك ر: 0.07، AIC: 88.62.

جدول ٢٠: معاملات النموذج الأفضل للبيانات (أ)

مجال الثقة	مجال الثقة	الأرجحية	القيمة	قيمة-ز	خطأ المعيار	تقدير الأرجحية	
90% (الأعلى)	90% (الأقل)	تقدير	الاحتمال	(والد)		اللغوية	lengthb_medium
2.287	0.186	0.627	0.458	-0.742	0.628	-0.466	

● تفسير النتيجة

ما النموذج الأفضل الذي يُبين حجم التأثير الأعلى من المتغيرات المستقلة (المتنبئة) الفئوية على المُعَيَّر التَّابِع (النَّاتِج)؟ بالنظر إلى المثال؛ يكون السؤال كالآتي: ما المُعَيَّر المُستَقِلّ، سواء كان السُّورَة المَكِّيَّة أو السُّورَة المَدَنِيَّة بوصفهما متغيرين فئويين للوقت (time)، أو كان قصراً أو متوسطاً أو طول السُّورَة كما هو في الطول (length)، الذي سيؤثر ويحدد فيما إن كانت هناك سجدة أم لا (yes أو no لـ prostration)؟ لننظر إلى جدول (١٩) لمعاملات النموذج. سنلاحظ أنَّ النموذج قد أظهر لنا المنطلق (intercept)، والوقت (المكّيّة time b_MK)، والطول المتوسط (length b_medium)، والطول القصير (length c_short)، ويُلاحظ أنَّ نموذج المنطلق (intercept) أفضل من نموذج الطول القصير (length c_short)، ونعرف ذلك من تقدير الأرجحية، فقيمة التقدير للمنطلق أعلى من قيمة التقدير لنموذج الطول القصير. نبحث هنا عن أعلى قيمة في عمود تقدير الأرجحية، وسنجدها لنموذج الطول المتوسط (length b_medium)، إذن؛ نقول مبدئياً بأنَّ أفضل نموذج هو نموذج الطول بفئة المتوسط (أي السُّور متوسط الطول). ثقتنا ليست كبيرة؛ لأنَّ مجال الثقة لها يُراوح بين 0.163 و2.103، من المهم أن نذكر مجال الثقة في نتيجة الانحدار اللوجستي، دون أن

نذكر قيم الاحتمال. لا نجد في قيم الاحتمال أي دلالة إحصائية للنماذج عدا المنطلق (كلها أكبر من 0.05)، ويُخبرنا جدول معاملات النموذج الأفضل بأن الطول المتوسط هو أفضل نموذج، وذلك بعد بنائه باستخدام بناء النموذج التدريجي (build a model stepwise) في أدوات (لانكستر) الإحصائية، حتى وإن كانت قيمة الاحتمال غير دالة؛ إلا أن أفضل نموذج يُفسر لنا وجود السجدة من عدم وجودها هو السور المتوسط، ويتجلى هذا في معظم السور المتوسطة التي وردت فيها السجدة، وهي الرعد، والنحل، والإسراء، ومريم، والحج (سجدتان)، والفرقان، والنمل، والسجدة، وص، وفصلت، والنجم، عدا سورة واحدة طويلة، وهي الأعراف، وسورتين قصيرتين؛ وهما الانشقاق والعلق.

ثانياً: نتيجة المثال (ب)

- بناء النموذج للاختدار اللوجستي

إحصاءات النموذج: الأرجحية اللوغارتمية: 6.66 (القيمة الاحتمالية = 0.155: غير دال إحصائياً)، C-index: 0.72 (مقبول)، ناغلكيرك ر: 0.11، AIC: 91.62.

جدول ٢١: معاملات النموذج للبيانات (ب)

مجال الثقة مجال ٩٥٪ (الأعلى)	مجال الثقة مجال ٩٥٪ (الأقل)	تقدير الأرجحية	قيمة الاحتمال	قيمة -ز (والد)	خطأ المعيار	تقدير الأرجحية اللوغارتمية	
0.585	0.004	0.046	0.014	-2.466	1.247	-3.075	(Intercept)
13.308	1.069	3.422	0.050	1.956	0.629	1.230	Varietyb_7
7.047	0.143	1.029	0.977	0.029	0.967	0.028	Syntaxb_present
1.915	0.015	0.303	0.292	-1.053	1.133	-1.193	Syntaxc_nominal
2.393	0.594	1.220	0.558	0.586	0.339	0.199	Length

- بناء النموذج التدريجي stepwise (النموذج الأفضل)

الإحصاءات الكلية: الأرجحية الاحتمالية: 4.04 (القيمة الاحتمالية = 0.0443 دال^٩
إحصائياً)، C-index: 0.63 (غير مقبول)، ناغليريك ر^٢: 0.07، AIC: 88.24.

جدول ٢٢: معاملات النموذج الأفضل للبيانات (ب)

مجال الثقة (الأعلى) ٩٥٪	مجال الثقة (الأقل) ٩٥٪	تقدير الأرجحية	قيمة الاحتمال	قيمة-ز (والد)	خطأ العيار	تقدير الأرجحية اللغائية	
12.247	1.029	3.220	0.058	1.896	0.617	1.169	Varietyb_7

• تفسير النتيجة

ما النموذج الأفضل الذي يُبين حجم التأثير الأعلى من المتغيرات المستقلة (المتنبئة) الفئوية على المتغير التابع (الناتج)؟ بالنظر إلى المثال؛ يكون السؤال كالآتي: ما المتغير المستقل الفئوي؛ سورة النساء (Variety a_3)، أو سورة الأعراف (Variety b_7)، أو الزمن الماضي (Syntax a_past)، أو الزمن المضارع (Syntax b_present)، أو الجملة الاسمية (Syntax c_nominal)؛ الذي يؤثر أكثر على المتغير الناتج (استخدام «ما»^(١) الموصولة، واستخدام اسم الموصول «الذي»؟ بالنظر إلى جدول معاملات النموذج؛ فإن القيمة الأعلى لتقدير الأرجحية هي ٤٢٢، ٣ لنموذج سورة الأعراف، وقيمة احتمال دالة: ٠,٠٥٠، ومجال الثقة كبير. يُكتفى هنا بذكر نتيجة معاملات النموذج الأفضل، وأن سورة الأعراف كمتغير مستقل ذي تأثير أكبر على استخدام (ما الموصولة) أكثر أرجحية

(١) وردت (ما) في سورة الأعراف ٥٨ مرة، منها ٤١ حالة جاءت موصولة، مثل هذه الحالات التي تتطلب تصنيفاً فئوياً دقيقاً؛ يحتاج المحلل إلى أن يهَيئ بياناته وفق الحالات الصحيحة، إذ احتجت إلى تتبع (ما)، واستخراج ما جاءت موصولة منها. كذلك الحال لدى المتغيرات التركيبية، وهل ما جاء بعدها جملة فعلية أم جملة اسمية، وهل الجملة الفعلية قد جاءت على صيغة الماضي أم المضارع، وكم عدد حروف الكلمة الأولى بعد (ما الموصولة)، سواء كانت فعلاً أم اسماً، وهذا ما تتطلبه بيانات الانحدار.

لسورة الأعراف، ولا علاقة لاستخدامها تحديداً في سورة النساء، أو في كون الجملة التي تأتي بعدها جملة فعلية (ماضية أو مضارعة) أو جملة اسمية.

المبحث الثالث: التأثيرات الممتزجة

هو أسلوب مهم، ويعمل مثل الانحدار اللوجستي، ويستخدم لكشف حجم تأثير متغير مستقل نختاره عشوائياً من بين المتغيرات المستقلة الأخرى على المتغير التابع (الناتج)، سنعيد بيانات الانحدار اللوجستي (الشكل ٦١)، لننظر في نتيجة نمذجة التأثيرات الممتزجة (mixed-effects modeling).

- المتغير التابع (الناتج): الأسماء الموصولة (Relatives).
- المتغيرات المستقلة (المتنبئة) للتأثيرات الممتزجة: يعتمد على الاختيار وفق سؤال التحليل.
- المتغير المستقل (المتنبئ) للتأثير العشوائي: يعتمد على تحديد أحد المتغيرات المستقلة (المتنبئة).

ID	Variety	Syntax	Length	Relatives
1	a_3	a_past	3	a_mā
2	a_3	a_past	3	a_mā
3	a_3	a_past	3	a_mā
4	a_3	a_past	3	a_mā
5	a_3	a_past	3	a_mā
6	a_3	a_past	3	a_mā
7	a_3	a_past	3	a_mā
8	a_3	a_past	3	a_mā
9	a_3	a_past	3	a_mā
10	a_3	a_past	3	a_mā
11	a_3	a_past	3	a_mā
12	a_3	a_past	3	a_mā
13	a_3	a_past	3	a_mā
14	a_3	a_past	3	a_mā
...	...	...	...	...
98	b_7	b_present	4	b_alladhī
99	b_7	b_present	4	b_alladhī
100	b_7	b_present	4	b_alladhī
101	b_7	c_nominal	7	b_alladhī

شكل ٦١ : بيانات الانحدار اللُّوجِسْتِيّ

شكل ٦٢ : واجهة الأنحدار اللوجستي للتأثير الممتزج في (اللغويات الاجتماعية)

توضع البيانات في خانة الأنحدار اللوجستي للتأثير الممتزج Mixed effect logistic regression في مربع اللغويات الاجتماعية Sociolinguistics (الخيار ١) في أدوات (لانكستر) الإحصائية كما في الشكل (٦٢)، ثم يكتب اسم المتغير الناتج في الخانة المخصصة له في الخيار (٢)، ثم يكتب اسم المتغيرات المستقلة مفصولةً بفاصلة منقوطة، دون مسافات، في الخانة المخصصة لها في الخيار (٣)، ثم يكتب اسم المتغير المستقل المتنبئ العشوائي في الخانة المخصصة له في الخيار (٤)، ثم يُختار (Yes, include all)، أي: تضمين كل التفاعلات بين كل المتغيرات المستقلة المتنبئة (predictor interactions)؛ من أجل دقة النتيجة، سنستخلص ثلاث نتائج، وذلك بجعل الطول (Length) في المرة الأولى متنبئ الأثر العشوائي، ثم بجعل التنوع (Variety) في المرة الثانية متنبئ الأثر العشوائي، ثم بجعل التركيب (Syntax) في المرة الثالثة متنبئ الأثر العشوائي. لاحظ أننا في كل مرة سنجعل المتنبئات المنضبطة ما يتبقى منها من دون متنبئ الأثر العشوائي. أُنْبَه -أيضاً- إلى أن التحليل قد يعتمد على متنبئ منضبط واحد مع متنبئ عشوائي، وكل ذلك يعتمد على السؤال البحثي الآتي: أي المتغيرات المتنبئة العشوائية أكثر تفاعلاً مع المتغير المنضبط، أو مع المتغيرات المنضبطة في حجم التأثير في المتغير التابع (الناتج)؟ تحديد ذلك هو ما سيحدد المتغير العشوائي، والمتغير أو المتغيرات المنضبطة.

- نتيجة المتغير المستقل المتنبئ العشوائي -الطول Length-: يُلاحظ أنَّ أعلى قيمة لتقدير الأرجحية اللوغارثمية من الطول هو لسورة الأعراف، وللتركيب الاسمي (Variety_7: Syntax_nominal) اللذين كان حجم أثرهما لاستعمال ما (الموصولة) أكبر.

جدول ٢٣ التأثيرات الممتزجة من المتغير المتنبئ العشوائي (الطول Length)

قيمة الاحتمال	قيمة -ز (والد)	الخطأ المعياري	تقدير الأرجحيات اللوغارثمية	
0.0645329	-1.84848025	1.3787328	-2.548560	(Intercept)
0.2191396	1.22881924	0.8959125	1.100914	Varietyb_7
0.2773870	1.08620794	2.2230061	2.414647	Syntaxb_present
0.9723273	-0.03468953	482.7189460	-16.745291	Syntaxc_nominal
0.3396094	-0.95493725	2.2992855	-2.195673	Varietyb_7: Syntaxb_present
0.9743417	0.03216345	482.7190753	15.525913	Varietyb_7: Syntaxc_nominal

- نتيجة المتغير المستقل المتنبئ العشوائي: (التنوع Variety): يُلاحظ بأن أعلى قيمة لتقدير الأرجحية اللوغارثمية من التنوع (سورة النساء أو سورة الأعراف) هو في التركيب الفعلي (المضارع)، الذي كان حجم أثره لاستعمال ما (الموصولة) أكبر.

جدول ٢٤ التأثيرات الممتزجة من المتغير المتنبئ العشوائي (التنوع Variety)

قيمة الاحتمال	قيمة -ز (والد)	الخطأ المعياري	تقدير الأرجحيات اللوغارثمية	
0.0048618444	-2.816047727	2.3180065	-6.527617	(Intercept)
0.0293409037	2.178875697	0.6818446	1.485655	Length
0.0004849041	3.488959759	4.5401480	15.840394	Syntaxb_present
0.9972140875	-0.003491631	7308.5967095	-25.518920	Syntaxc_nominal
0.0006670594	-3.402771926	1.0418110	-3.545045	Length: Syntaxb_present
0.9976367908	0.002961848	1044.0854628	3.092422	Length: Syntaxc_nominal

- نتيجة المُتَغَيِّرِ المُسْتَقِلِّ المتنبئ العشوائي - التركيب Syntax: - يُلاحظ أنَّ أعلى قيمة لتقدير الأَرْجَحِيَّةِ اللوغارثمية من التَّركيب هو لسورة الأعراف، التي كان حجمُ أثرها لاستعمال ما (الموصوليَّة) أكبر.

جدول ٢٥ التأثيرات المترتبة من المُتَغَيِّرِ المتنبئ العشوائي (التركيب Syntax)

قيمة الاحتمال	قيمة-ز (والد)	الخطأ المعياري	تقدير الأَرْجَحِيَّات اللوغارثمية	
0.009721255	-2.5855898	1.6338685	-4.2245138	(Intercept)
0.169232857	1.3746730	1.9472614	2.6768476	Varietyb_7
0.193034059	1.3016558	0.3517511	0.4578589	Length
0.396690975	-0.8475458	0.4403539	-0.3732201	Varietyb_7:Length

الاستنتاج العام: عند استعمال (ما الموصوليَّة) يغلبُ مجيءُ المركَّبِ الاسميِّ،
ويغلب عند استعمال (الذي) مجيءُ المركَّبِ الفعليِّ.

الفصل الخامس

تحليل البيانات اللغوية التاريخية

يُطبَّق أسلوبان لتحليل التَّغْيِير اللُّغَوِيِّ عبر الزَّمن؛ الأوَّل: تحليل القمم والقُصور. والثَّاني: تحليل التَّغْيِير اللُّغَوِيِّ في الدَّرَاسَاتِ اللُّغَوِيَّةِ التَّارِيخِيَّةِ، كأن يكون وجه التَّغْيِير اللُّغَوِيِّ تَكَرُّراً (أي: زيادة أو نقصان أو اختفاء ظهور الكلمة عبر الزَّمن)، أو أن يكون وجه التَّغْيِير اللُّغَوِيِّ في البنية اللُّغَوِيَّةِ (أي: البنية الصَّوتِيَّة، أو البنية الصَّرْفِيَّة، أو البنية التَّركِيبِيَّة، أو البنية الدَّلَالِيَّة). لا شك أن وجه التَّغْيِير اللُّغَوِيِّ في البنية من حيث تهيئة بياناته أصعب من وجه التَّغْيِير اللُّغَوِيِّ في تذبذب الاستخدام للكلمة، وعلى أيِّ حال؛ أُعيدَ أَهَمِّيَّةُ تَأْسِيسِ البَيِّنَاتِ اللُّغَوِيَّةِ من حيث الجمع والإعداد والتَّهيئة والعناية؛ كونها المسألة التي تنالُ الجهدَ الأكبر في مجال عِلْمِ البَيِّنَاتِ (اللُّغَوِيَّة).

المبحث الأوَّل: القمم والقُصور

في هذا المبحث الأوَّل؛ احتجبتُ إلى تفكيرٍ إحصائيٍّ عما يُمكن تحليله في مُدَوَّنَةِ القرآن الكريم. ظهرت لي فكرةُ النَّظَر في استعمال كلمة (رحمة) واشتقاقاتها، واستعمال كلمة (عذاب) واشتقاقاتها^(١) عبر سور القرآن الكريم، حسب نزولها زمنياً. في القرآن الكريم ١١٤ سورة، نزلت على النَّبِيِّ مُحَمَّدٍ -صَلَّى اللهُ عَلَيْهِ وَسَلَّمَ- على مدى ٢٣ سنةً. عملتُ


(١) اشتقاقات رحمة: (رحمة)، و(رحمته)، و(ترحمون)، و(الرحمة)، و(رحمتنا)، و(أرحم)، و(رحمت)، و(رحم)، و(ارحمنا)، و(يرحمكم)، و(رحمته)، و(يرحم)، و(رحمناهم)، و(الرحمة)، و(سيررحمهم)، و(ارحمهما)، و(ارحم)، و(ارحمنا)، و(رحمه)، و(رحما)، و(ترحمني)، و(ترحمنا)، و(رحمتي)، و(يرحمنا)، و(رحمنا)، و(رحماء). واشتقاقات عذاب: (عذاب)، و(يعذب)، و(يعذبكم)، و(معذبين)، و(أعذبه)، و(يعذبه)، و(معذبهم)، و(عذب)، و(تعذبهم)، و(معذبوها)، و(سنعذبهم)، و(عذبناها)، و(يعذبهم)، و(عذبهم)، و(عذبنا)، و(معذبين)، و(يعذبنا)، و(تعذب)، و(نعذب)، و(المعذبين)، و(أعذبه)، و(العذاب)، و(بعذاب)، و(لعذاب)، و(عذابه)، و(عذابها)، و(أفيعذابنا)، و(بعذابكم)، و(عذابهما)، و(كعذاب).

على تصنيف السور، ووضع كل خمس سورٍ توالى بالتراتب في نزولها زمنياً في كل سنة، ليكون عددُ المجلدات التي عولجت ٢٣ مجلداً، واستعنتُ بأداة غواص في استخراج تكرارات الكلمتين من كل مجلدٍ. يُبين الشكل (٦٣) شكلَ البيانات المهيأة، وتُلصق كما هي في خانة القمم والقعور (Peaks and troughs) في مربع التغيّر عبر الزمن (Change over time)؛ لاستخراج تمثيل الانحدار غير الخطّي، وفي مربع التجميعات المتجاورة (Neighbour clusters) لاستخراج تمثيل مسافات نقاط ورود الكلمة عبر الزمن في أدوات (لانكستر) الإحصائية كما في الشكل (٦٤). ظهرت النتائج كما في الشكل (٦٥)، وذلك بتمثيل الانحدار غير الخطّي لكلمة (رحمة) على مدى ٢٣ عامًا كما في (أ)، وتمثيل مسافات نقاط ورودها عبر الزمن كما في (ب)، ثم كما في الشكل (٦٦)، وذلك بتمثيل الانحدار غير الخطّي لكلمة (عذاب) على مدى ٢٣ عامًا كما في (أ)، وتمثيل مسافات نقاط ورودها كما في (ب).

بيانات كلمة (عذاب)		
ID	time	Variable
1	1	3
2	2	3
3	3	0
4	4	0
5	5	0
6	6	2
7	7	1
8	8	22
9	9	21
10	10	20
11	11	36
12	12	34
13	13	26
14	14	25
15	15	16
16	16	13
17	17	10
18	18	52
19	19	15
20	20	6
21	21	24
22	22	2
23	23	42


بيانات كلمة (رحمة)		
ID	time	Variable
1	1	0
2	2	0
3	3	0
4	4	0
5	5	0
6	6	0
7	7	1
8	8	17
9	9	8
10	10	17
11	11	29
12	12	7
13	13	10
14	14	10
15	15	8
16	16	1
17	17	8
18	18	13
19	19	7
20	20	1
21	21	5
22	22	1
23	23	6

شكل ٦٣ : بيانات (رحمة) و(عذاب)




شكل ٦٤ : واجهة القمم والقعور في (التغير عبر الزمن)

(ب)




(أ)




شكل ٦٥ : تمثيل نتيجة استعمال (رحمة) عبر الزمن في سور القرآن الكريم

(أ)



(ب)



شكل ٦٦: تمثيل نتيجة استعمال (عذاب) عبر الزمن في سور القرآن الكريم

كيف نفسّر القمّم والقصور لاستخدام الكلمتين عبر الزمن في القرآن الكريم؟ في الشكل (٦٣) سيلاحظ بأن المتغير اللغوي قد مُثّل بالتكرار الملحوظ من دون تحويل، ويقصد بالتحويل إمكانية تحويل التكرار إلى قيم لوغاريتمية، أو باستخدام التكرارات النسبية، وتتمثّل فائدة التحويل عندما تكون قيم التكرارات الملحوظة متطرفة أو متباينة، ولم يُحتج إلى مثل هذا التحويل؛ نظراً إلى قلة التكرارات الملحوظة. وبالنظر إلى الانحدار غير الخطّي للكلمتين عبر الزمن؛ فإن كل نقطة تمثّل التكرار الأعلى أو الأقل، والذي يمكن قوله من خلال هذه النقاط التي نراها أنّ كلمتي (رحمة) و(عذاب) في آيات السور التي نزلت في السنوات السبعة الأولى متقاربة الورد، ثم ازدادت في السنوات التي تلت، واستقرّ الورد لكلمة (عذاب)، وبدأ ورود كلمة (رحمة) في النزول في بقيّة السنوات، ونلاحظ -أيضاً- في الخطّين البيانيين أنّ أعلى قيمة لورد كلمة (رحمة) قد كانت في السنة الثانية قبل الهجرة، (التي تمثّل السنة ١١ من السنوات الـ ٢٣)، وأنّ أعلى قيمة لورد كلمة (عذاب) قد كانت في السنة الثانية والثالثة قبل الهجرة، (التي تمثل السنة ١١ والـ ١٢ من السنوات الـ ٢٣)، ثم بين السنة الخامسة والسادسة من

الهجرة (التي تُمثل ما بين السنة الـ ١٨ والـ ١٩ من السّنوات الـ ٢٣)، ويُقصد بنقطة القمّة تلك النّقطة التي ظهرت خارج الانحدار غير الخطّي، ويُلاحظ من هذا كلّهُ أنّ نتاج تحليل القمم والقعور في هاتين الكلمتين عبر الزّمن في القرآن الكريم متقاربةً نوعاً ما، عدا نقاط القمم المتفاوتة نسبياً بينهما.

المبحث الثاني: التّأرجح الاستعماليّ

يهدف هذا النّوع من التّحليل إلى كشف تطوّر معاني الكلّيات، أو تطور استعمالاتها، وهو تطوّر يطرأ من تأرجح المتصاحبات اللفظيّة مع الكلّيات عبر الزمن. ولتبسيط طريقة تحليل هذا النوع؛ لنفترض أنّ الكلمة هي (س)، وأن هذه الكلمة قد تصاحبت معها الكلّيات (أ)، و(ب)، و(ج)، و(د)، ونريد كشف التّقلّب الاستعماليّ لهذه الكلمة في مُدّة تراوح بين نقطتين، تُمثّل عامين، أو أعواماً، أو قرونًا من الزّمن، ويتطلّب هذا بناء مجموعة بياناتٍ لكشف حالات بداية الظّهور، والثّبات، والانقطاع، والتحوّل للمتصاحبات اللفظيّة (أ) و(ب) و(ج) و(د) مع (س).

يُخَيّر المحلّل بين طريقتين لتحليل التّأرجح الاستعماليّ؛ وهما على النّحو الآتي:

الأوّل: التّحليل النّوعيّ القائم على ما يُقيّمه المحلّل البشري (الشكل ٦٧ والشكل ٦٨).

الثّاني: التّحليل الكميّ القائم على ما يُقيّمه المحلّل الآليّ (الشكل ٦٩ والشكل ٧٠).

بالنسبة للطريقة الأولى؛ سننظر إلى كلمة (رحمة) وكلمة (عذاب) من ناحية التّأرجح الاستعماليّ لهما مع متصاحباتهما اللفظيّة على نافذة تصاحب (يم-يس١). تصدّيتُ لتلك المتصاحبات عبر الزّمن، ثم صنفْتُها إلى تلك التي لوحظت بدايتها، والتي لوحظ ثباتها، والتي لوحظ انقطاعها، والتي لوحظ تحوّلها. يُمكن فهم بداية التّصاحب زمنيّاً، وثبات التّصاحب زمنيّاً، وانقطاع التّصاحب زمنيّاً، لكن ماذا عن تحوّل المتصاحب؟ الجواب: هو تحوّل المتصاحب إلى مصاحبة كلمة أخرى زمنيّاً، ويُستخرج بوضع متصاحبات الكلمة المعنية في قائمة شمول، ثم استخراج التّتابع (2n-grams)

[نافذة التَّصَاخُب: يم-يس١]، ثم الوقوف على المتصاحبة مع الكَلِمَات التي جاءت معها من غير كلمة (رحمة) و(عذاب).

٢٣ سنة (كل رقم مع المتصاحب يشير إلى السَّنة)

الكلمة: (رحمة). نوع التحليل: تحليل التَّأرجح الاستعمالي للمتصاحبات

المتصاحبات التي بدأت: «خزائن» (٨)، «ذكر»، «ربك» (٩)، «ابتغاء»، «ربي» (١٠)، «واسعة»، «ريه» (١١)، «الله» (١٢)، «للعالمين» (١٥)، «الناس» (١٧).

المتصاحبات التي ثبتت: لم ينطبق.

المتصاحبات التي انقطعت: «ذكر» (٩).

المتصاحبات التي تحوَّلت: «خزائن» (١١) (٢١)، «ابتغاء» (١٩) (٢٠)، «للعالمين» (٩) (١١) (١٥) (١٧) (١٨).

شكل ٦٧: تمثيل نتيجة استعمال تصاحبات (رحمة) عبر الزمن في سور القرآن الكريم

٢٣ سنة (كلُّ رقم مع المتصاحب يشير إلى السَّنة)

الكلمة: (عذاب). نوع التحليل: تحليل التَّأرجح الاستعماليِّ للمتصاحبات

المتصاحبات التي بدأت: «سوط» (٢)، «الحريق»، «جهنم» (٦)، «شديد»، «بكرة»، «مستقر» (٨)، «أليم» (٩)، «ريك» (١٠)، «الله»، «الخلد»، «الآخرة»، «مقيم»، «الهون»، «غليظ»، «قريب» (١١)، «السعير»، «مهين»، «النار»، «الحكيم»، «واصب»، «مقيم» (١٢)، «عظيم»، «الحميم»، «الخزي» (١٣)، «الهون» (١٤)، «ريهم»، «يومئذ»، «السموم» (١٦).

المتصاحبات التي ثبتت [ثبات منقطع]: «شديد» (٨) (٩) (١٢) (١٣) (١٥) (١٨)، «أليم» (٩) (١١) (١٤) (١٥) (١٦) (١٧) (١٨). [ثبات متصل]: لا ينطبق.

المتصاحبات التي انقطعت: «سوط» (٢)، «بكرة» (٨)، «مستقر» (٨).

المتصاحبات التي تحوَّلت: «قريب» (١١)، «عظيم» (١) (١٨) (٢٢) (٢٣)، «الخلد» (٩) (١٣)، «شديد» (١٠) (١٩) (٢٣).

شكل ٦٨: تمثيل نتيجة استعمال تصاحبات (عذاب) عبر الزَّمن في سور القرآن الكريم

لنتذكَّر في (شبكات التَّصاحب اللَّفْظِيّ) في المبحث الأوَّل من الفصل الثَّاني إجراء مجموعة مقاييس التَّصاحبِ (collocation parameters notation)، إذ لا بدَّ من تطبيقه على تحليل التَّأرجح الاستعماليِّ بين الكَلِمَات والمتصاحبات؛ من أجل ضبط المخرجات بدقَّة في حال ظهور كمِّ هائلٍ من المتصاحبات في المَدُونَات اللَّغَوِيَّة الكبيرة.

أما بالنَّسبة إلى الطَّريقة الثَّانية، التي تعتمد على ما يُقيِّمه المحلِّل الآليُّ؛ فيتطلَّب ذلك إعداد بيانات مهيكلة، كما في الشَّكل (٦٩)، تَتضمَّن سبعة أعمدة، وعنوان كلِّ عمود هو: التَّسلسل (No.)، ثم الكلمة (Word) المتصاحبة، ثم تكرارها لوحدها في كامل المَدُونَة

(Total no. in whole corpus)، ثم التكرار المتوقع للتصاحب (Expected collocate frequency)، ثم التكرار الملحوظ للتصاحب (Observed collocate frequency)، ثم تكرار النص للتصاحب (In no. of texts)، ثم قيمة معامل المعلومات المتبادلة (Mutual information value). ولإتمام المعالجة في أدوات (لانكستر)، أو باستخدام الأكواد المذكورة في الملحق (ج)، لا بد أن يكون المجلد مضغوطاً، ويتضمن ملفات عديدة، وفي كل ملف مجموعة المصاحبات اللفظية لكلمة (رحمة)، أو (عذاب)، أو أي كلمة أخرى معنية بالتحليل لمدة زمنية محددة. وفي مثالنا هنا؛ تمتد المدة الزمنية لثلاث وعشرين سنة لتلك الكلمتين، وعليه يكون عدد الملفات ٢٣ ملفاً، ثم تُترك الخطوات التالية بعد تحميل الملف في خانة تحليل التآرجح الاستعمالي (UFA) في مربع التغير عبر الزمن (Change over time) في أدوات (لانكستر) الإحصائية كما في الشكل (٧٠).

No.	Word	Total no. in whole corpus	Expected collocate frequency Observed collocate frequency	In no. of texts	Mutual information value
1	خزائن	0	1	1	6.0747
2	ذكر	0	2	2	6.0747
3	ريك	0	3	3	6.0747
4					
5					
6					

شكل ٦٩: بيانات استخدام منهج تحليل التآرجح الاستعمالي

شكل ٧٠ : واجهة تحليل التآرجح الاستعمالي UFA في (التغير عبر الزمن)

لهذا الأسلوب الآلي قوّة متينة في استخراج خارطة التّصاحبات، وتآرجحها، وتقلّبها الاستعماليّ عبر الزمن، من حيث المصاحبة التي بدأ استعمالها، والتي ثبت استعمالها، والتي غاب استعمالها، والتي تحوّل استعمالها، وهي معالجة قويّة تُستخدم في بناء المعاجم التّاريخيّة، صحيح أنّ إعداد البيانات يأخذ جهداً؛ ولكنه لا يأخذ زمناً طويلاً؛ إذ كلما زاد الجهد في إعداد البيانات قلّ زمن الإعداد، والعكس صحيح، فلو افترضنا أنّ الهدف من بناء معجم تاريخيّ هو الوقوف على التّأرجحات والتقلّبات الاستعماليّة عبر ١٤ قرناً، ولدينا مدوّنة عربيّة تاريخيّة تتضمّن مليار كلمة، وأن كلّ نقطة تاريخيّة نوّد تصميم الخارطة بناءً عليها تمتدّ لكلّ عشر سنوات، أو لكلّ مائة سنة، فسنحتاج إلى إعداد ١٤٠ ملفاً للسّنوات العشر، أو ١٤ ملفاً فقط للسّنوات المائّة، وذلك لا يستغرق زمناً، إذ يُمكن إعدادها في غضون شهر من محلّ بشريّ واحد (هذه تجرّبة مؤلّف الكتاب)، ولكّ أن تصوّر ما ستظهره الآلة بهذه الأداة أو بأكوادها في الآر في ثوانٍ معدودة من قوائم الكلمات ومتصاحباتها من بداية الظهور زمنيّاً، وهل ثبتت زمنيّاً، وهل غابت في نقطة زمنيّة، أو في نقاط زمنيّة معيّنة، وهل تحوّلت في نقطة أو في نقاط زمنيّة معيّنة.

المبحث الثالث: حوسبة المعجم

تُجرى حوسبة المعجم في مجالين مختلفين؛ الأول: صناعة المعجم الحاسوبي (computational lexicography)، والثاني: علم الوجود (ontology)، وتقنيات دلالة الويب (web semantic technologies).

يهدف المجال الأول إلى تصميم وإخراج معاجم إلكترونية في تطبيقات ومواقع شبكية، ويعتمد التصميم والبناء على مدونة لغوية، وهو الأساس والمنطلق، ويتحدد مجال المدونة اللغوية وزمانها بتحديد غرض المعجم، فإن كان تاريخياً؛ فالمدونة بطبيعة الحال ستكون تاريخية^(١)، وإن كان معاصراً؛ فالمدونة بطبيعة الحال ستكون معاصرة. ولما هج لغويات المدونات دور مهم قد بات أساسياً في عصرنا اليوم لأي مشروع يُبنى لغرض صناعة المعاجم وإخراجها، كما أن لدور علم المعلومات أهمية أساسية في الصناعة المعجمية الرقمية (e-lexicography)، فيشير تارب^(٢) إلى أن دور الحاسب الآلي، وعلم الإحصاء، وتعلم الآلة الموجه وغير الموجه في المدونات اللغوية؛ قد ابتكر بيئة عملية وتطبيقية تطوّر من صناعة المعاجم، وأن المعجم في الأساس ما هو إلا حقل معلوماتي، ويحتاج في العصر الحالي إلى الأدوات الرقمية التي تكون فيه المنطلق. وكل معجم ورقّي يحول إلى منصة رقمية في الإنترنت أو في التطبيقات الذكية سيُعدّ معجماً مرقماً digitized، ولن يُعدّ معجماً مُشَفَرًا digitalized أو مُعتمداً على أدوات التحوّل الرقمي؛ لأن المنطلق لم يكن معتمداً على ما يسميه تارب بالأدوات الرقمية (e-tools)، وهي أدوات تُبنى لغرض الاستفادة المعلوماتية المعجمية من المدونات اللغوية الحية والطبيعة، مثل التي طبّقها -وما زالت تُجري تطبيقاتها- مجموعة (Pearson) ومجموعة (Longman)

(١) من أمثلة هذا النوع ما يُعمل عليه في معجم الدوحة التاريخي للغة العربية: <https://www.dohadictionary.org> (تاريخ الاسترداد ٢٤ أكتوبر، ٢٠٢٢).

(2) Tarp, S. (2011). Lexicographical and Other e-Tools for Consultation Purposes: Towards the Individualization of Needs Satisfaction. In P. A. Fuertes-Olivera & H. Bergenholtz (Eds.), e-Lexicography: The Internet, Digital Initiatives and Lexicography, (pp. 5479-). London, New York: Continuum.

في الأعوام العشريّة الأخيرة في بناء المعاجم العامّة والأكاديميّة والخاصّة التي تَعكّس واقع الاستعمال اللّغويّ المتنوّع.

أما المجال الثّاني: (الويب الدلالي وتقنياته)؛ فيعتمد على أدوات وتقنيات اتّحاد شبكة الويب العالميّة (World Wide Web Consortium)، وتُعرف بالاختصار الشائع لها: (W3C)^(١)، وتُمكن تقنيات هذا الاتحاد من إنشاء قواعد بيانات لبناء المفردات، وتصميم قواعد بيانات لتلك المفردات بصيغ استعلاميّة وهياكل بيانيّة حاسوبيّة، وتعمل مجموعة هذا الاتحاد على بناء مصادر المفردات المعجميّة في الويب، من خلال صيغ حاسوبيّة محدّدة، تُبنى عليها مصادر الكلّيمات المعجميّة، مثل بروتوكول بنية المعجم (DICT) الذي يُبنى بصيغة لغة الترميز الموسعة (Extensible Markup Language XML)، ومثل إطار وصف المصادر (Resource Description Framework) الذي يُستخدم لوصف البيانات المعجميّة، ثم يُدمج مع الإطار المنهجيّ النظريّ الذي يُسمّى إطار الترميز المعجميّ (Lexical Markup Framework). ومن أدوات مصادر الويب الدلالي وسحابة البيانات ما يُعرف بـ: ليمون المعجم الوجوديّ (OntoLex Lemon)، وهو نموذج يعمل على حوسبة مفردات الويب؛ بهدف بناء معاجم أنطولوجيّة، ويتضمّن هيكله من الإدخالات المعجميّة التي تتكوّن من بُنيّتين أساسيّتين: بنية مفردات تُبنى لها الشبكات الدلاليّة، وبنية مفاهيم تُربط فيها الكلمات المتعلّقة بكلّ مفهوم على حدة^(٢).

(١) من أمثلة هذا النوع للغة العربيّة مشروع (الأنطولوجيا العربيّة) من جامعة بيرزيت، وهو مشروع لشبكة الكلّيمات العربيّة، وصنفت الكلّيمات فيها حسب المعاني والعلاقات الدلالية: <https://ontology.birzeit.edu> (تاريخ الاسترداد ٢٤ أكتوبر، ٢٠٢٢).

(2) Bosque-Gil, J., et al. (2019). The OntoLex Lemon Lexicography Module.

الباب الثاني

تنقيب النصوص والبيانات العربية^(١)

(١) يمكن للقارئ تطبيق كل المعالجات الآلية الواردة في فصول هذا الباب، باستخدام أدوات أورانج وباستخدام البيانات اللغوية التي أعدها المؤلف، من أجل تكرار التحليل والتدريب والتأكد من تطابق النتيجة. ولتسهيل العودة إلى بيانات كل معالجة آلية في فصول هذا الباب، فقد جمعتها في ملف واحد (إكسل Excel)، وسُميت كل ورقة sheet داخل هذا الملف برقم الشكل الوارد في فصول هذا الباب. موقع البيانات اللغوية: www.kaggle.com/datasets/sultanalmujaiwel/quran-mining



الإحصاء وتقنيات الذكاء الاصطناعي
للبيانات اللغوية

هذه الطبعة **إهداء من المجمع**

ولا يُسمح بنشرها ورقياً أو تداولها تجارياً

التمهيد

من الضروريّ التمهيدُ لمفاهيمٍ أساسيّةٍ في ممارساتِ تنقيب النصوص والبيانات والمعالجة الآليّة للغة قبل الوقوف على أدواتِ المعالجة المدمجة في أداة (أورانج). وكما أسلفنا في مقدمة الكتاب؛ فالهدفُ من شرح تطبيقاتِ هذه الأداة هو إفادة الباحث اللغويّ بما امتازت به من أدواتٍ مفيدةٍ في تحليل النصّ العربيّ ومُعالجته، وفق تقنياتِ الذكاء الاصطناعيّ.

وهناك هدفٌ آخر لا يقلُّ أهميةً عن الأوّل، وهو أنّ الممارسةَ على استخدامِ تقنيّاتِ هذه الأدواتِ في التحليل والمعالجة دون برمجة؛ ستجعلُ منها عوناً للباحث اللغويّ في فهمِ أسسِ معالجة اللغة العربيّة الطّبيعيّة، وفي التّألفِ مع تطبيقاتها في المشاريع اللّغويّة-التّقنيّة.

وبما أن هذا الكتابَ مُوجّهٌ إلى اللّغويّين وإلى المهتمين بتحليل النصوص في العلوم الإنسانيّة والاجتماعيّة؛ فبرنامج (أورانج) بمكتباته المدمجة فيه لتنقيب النصوص والبيانات لا يتطلّبُ معرفةً برمجيّةً؛ كونه برنامجاً قائماً بذاته^(١). وسأبيّن ما يتوفّر في هذه الأداة من أدواتٍ تحليليّةٍ في الفصل الأوّل، وهي الأدوات التي ستتناول بالتطبيق في الفصل الثاني والثالث والرّابع والخامس. أما ما لا يتوفّر فيها من أدواتٍ لبعضِ المعالجات؛ فتتطلّبُ استخدام لغة البرمجة (البايثون)، وقد زودتُ القارئَ بأكوادها في الملحق (د) والملحق (و).

(١) لأدوات تنقيب النصوص (text mining) وتنقيب البيانات (data mining) التي سنذكر في هذا الباب في أدوات (أورانج)؛ ملفاتُ أكواد في البايثون، فلمن يرغبُ في استخدامها الرجوعُ إلى هذين الرابطين: أكواد تنقيب النصوص (Scripting). تاريخ الاسترداد ٢٤ أكتوبر، ٢٠٢٢، من: <https://orange3-text.readthedocs.io/en/latest/>. أكواد تنقيب البيانات. تاريخ الاسترداد ٢٤ أكتوبر، ٢٠٢٢، من:

https://orange3.readthedocs.io/projects/orange-data-mining-library/en/latest/_modules/index.html.

نسمعُ عن ثلاثة مجالات في نطاق تقنيات اللغة^(١)؛ وهي تنقيب النُصوص (text mining)، واللُّغويات الحاسوبية (computational linguistics)، ومعالجة اللغة الطبيعية (natural language processing).

يعتمدُ تنقيبُ النُصوص على جمع البيانات اللُّغوية، وكشط الويب، واستخراج المفاهيم، واستخراج المعلومات، وتصنيف المستندات، ومعالجة اللغة الطبيعية. ويُعدُّ تنقيبُ النُصوص من المراحل الأولى لجمع البيانات اللُّغوية، وتصنيفها، واستخراج المعلومات منها، واستبعاد ما ليس مهماً فيها في مهمةٍ لاحقةٍ، وإعدادها لمعالجات متعددة في مجال اللُّغويات الحاسوبية التطبيقية ومعالجة اللغة الطبيعية.

ويُعدُّ اللُّغويات الحاسوبية حقلاً متداخلاً الاختصاصات بين اللُّغويات وحوسبة اللغة والذكاء الاصطناعي والرياضيات التطبيقية وعلم الإدراك، ويهتم بكل ما يتعلق بالتمذجة الحاسوبية للغة، ودراسة أفضل المناويل الحاسوبية للأسئلة اللُّغوية، وينقسم إلى اللُّغويات الحاسوبية النظرية، واللُّغويات الحاسوبية التطبيقية، وفي الجانب النظري؛ يُهتم بالنظريات الصارمة التي تعمق من فهم النحو والدلالة، أما الجانب التطبيقي فهو متعلق بتعلم الآلة الذي بدأ باستخدام المناهج الإحصائية، ثم تطور باستخدام الشبكات العصبية التي بدأت تأخذ حيز التطبيق الجاد منذ عام ٢٠١٥م في تحسين معالجة اللغة الطبيعية. ويصبُّ اختصاص اللُّغويات الحاسوبية التطبيقية في تحسين أداء فهم الآلة لنماذج مُعجم الكلمات (ردّها إلى الأصل المعجمي)، ولنماذج وُسوم أقسام الكلام،

(1) Miner, G., Elder, J., Fast, A., Hill, Th., Nisbet, R., & Delen, D. (2012). Practical Text Mining and Statistical Analysis for non-Structured Text Data Applications. Elsevier, pp. 3-28.

كل مجال مرتبط بالآخر، وقد أوضحتُ شكل الارتباط توضيحاً مختصراً، بناء على مسح سبع عشرة دراسة منشورة في دليل أكسفورد:

Mitkov, R. (ed.), (2022). The Oxford Handbook of Computational Linguistics. Oxford University Press, 2nd edition.

Tsujii, J. (2021). Natural Language Processing and Computational Linguistics. Computational Linguistics, 47(4).

ولنماذج المحلّلات النحويّة، ولنماذج شبكة الدلالات للكلمات، ولنماذج الترجمة الآليّة، وساعدت هذه التحسينات على تطوّر تطبيقات معالجة اللغة الطّبيعيّة.

أمّا مجال معالجة اللغة الطّبيعيّة، فهو نفسه اللّغويات الحاسوبية التّطبيقيّة. وتُستعمل مصطلحات (اللّغويات الحاسوبية التّطبيقيّة)، و(معالجة اللغة الطّبيعيّة)، و(تقنيات اللغة language technologies) لمفهوم واحد، ويعود اختلاف الاستعمال إلى جهويّة المرجعيّة المؤسسيّة، فالأكاديميون يستعملون مصطلح (اللّغويات الحاسوبية التّطبيقيّة)، والمبرمجون والمطورون يستعملون مصطلح (معالجة اللغة الطّبيعيّة)، والحكومات والمؤسسات السياسيّة تستعمل مصطلح (تقنيات اللغة).

يُعتبر مجال معالجة اللغة الطّبيعيّة مجالاً متنوّعاً بتنوّع تطبيقاته، وهو مجالٌ يقوم على التّجريب (praxis) المستمرّ في تحسين أداء تعلّم الآلة لأنظمة اللغة البشريّة. سأقدم لمحة عن بداية معالجة اللغة الطّبيعيّة، وعما وصلت إليه في الآونة الأخيرة من مخرجات المطوّرين والمبرمجين في بناء نماذج تعمل على معالجة اللغة، وتصنيفها، وفهمها، وتوليدها.

بدأت فكرة معالجة اللغة الطّبيعيّة من عالم التّشفير آلن تيورنج (Alan Turing)، عندما أوجد للآلة طريقة خاصّة بها للتّفكير في عام ١٩٤١م، ليبرهن على فكرة ما إن كانت الآلة تفكر مثل الإنسان. تطوّرت نماذج الترميز التي تُساعد الآلة على فهم أقيسة التّفكير المنطقيّ عند الإنسان، ووصلت في مطلع القرن الحادي والعشرين إلى مرحلة عميقة من فهم الآلة، ومعالجتها، وتوليدها لما فهمت. قامت معالجة اللغة الطّبيعيّة على ثلاثة مناهج متتابعة زمنياً؛ المنهج الأوّل: تعلّم القواعد (rule-based method). والثّاني: تعلّم الآلة (machine learning). والثّالث: التعلّم العميق (deep learning).

قام منهج تعلّم القواعد على محدّدات قطعيّة من القواعد، التي تُبنى لتعليم الآلة عليها، وتتضمّن جملة من التّعبيرات الشرطيّة (إن if، إذن then)، فيقوم النظام بالتخزين

والتطبيق بناء عليها، وطُبّق هذا المنهج مثلاً على المحلّل الصرّفي؛ كون شروط التحليل والتوليد محدودةً.

تغيّر التعلّم على القواعد إلى تعلّم الآلة الذي قام على الاحتمالية (probabilistic)، فأنظمة تعلّم الآلة ونماذجها التقليدية قد صارت تعتمد على قواعد إحصائية بدلاً من القواعد الحتمية، وهناك فروقات أساسية بين أنواع تعلّم الآلة^(١)، وهي على النحو الآتي:

• تعلم الآلة التقليدي

بدأ هذا النوع في خمسينيات القرن العشرين في علم الاحتمالات الإحصائية البحتة، ويقوم التعلّم هنا على البحث عن الأنماط في البيانات، وتقييم نقاط القرب فيها، وحساب فضاء المتجهات، الذي يعرف بالشُعاع أو المصفوفة (array or matrix). معظم الخوارزميات اليوم تعمل على هذا النوع من التعلّم، فاقترح مُحرك البحث جوجل لكلمات بحثية، أو اقترح منصة اليوتيوب لمقاطع فيديو أخرى، أو اقترح منصة تسوق إلكتروني لأصناف معينة؛ ما هو إلا نتيجة لكشف أنماط سلوك المستخدم في تلك المواقع، وستتضح نقطة الأنماط والنقاط والمتجهات من خلال شرح نوعين من أنواع تعلّم الآلة فيما يتعلق باللغة؛ وهما: التعلّم الموجه، والتعلّم غير الموجه.

في التعلم الموجه؛ تُزوّد الآلة بالإجابات، فمثلاً؛ يعمل المحلّل البشري على تقطيع الكلمات في النصّ، ثم تصنيف أقسام الكلام فيها، ثم تتعلّم الآلة من هذه الأمثلة، ثم تُختبر على بيانات لم ترها ليُقيم بها أداء فهمها. ينقسم تعلّم الآلة الموجه إلى التصنيف والانحدار، وفي التصنيف تكون السمات (features) فئات (مثل: اسم وفعل وضمير وأداة إلخ)، أما في الانحدار فتكون السمات أرقاماً (مثل التكرارات الحقيقية أو التكرارات النسبية).

(١) لتفاصيل أنواع التعلم وخوارزمياتها العودة إلى: لحج، محمد. (٢٠٢٠). مدخل إلى الذكاء الاصطناعي وتعلم الآلة. أكاديمية حاسوب، المملكة المتحدة، الطبعة الأولى. الشروحات في هذا الكتاب مختصرة ومبسطة ومقروءة ومفهومة.

في التعلّم غير الموجه الذي جاء متأخراً في نهاية التسعينيات من القرن العشرين؛ دعت حاجة التعامل مع بيانات ضخمة يصعب تصنيف خصائصها وسماتها بشرياً بسبب الكلفة البشرية والزمنية إلى بناء نماذج خاصة لها. والمهم في هذا النوع من التعلّم هو أن نُعطي الآلة بيانات منظمة على الأقل، ومهيكلّة بصيغة منطقيّة من الناحية الشكليّة، لتعمل على معالجتها - على الوجه الأفضل - بالتجميع (clustering)، أو بتقليل الأبعاد (dimensionality reduction)، أو بالتعميم (generalization)، أو بتعلم قواعد الربط (association rule learning). خذ على سبيل المثال: استخراج الموضوعات من النصوص، إذ تحتاج هذه النصوص إلى تنظيم يُعين على تحقيق نتيجة جيدة، ومن أشكال التنظيم مثلاً اختيار أو توزيع النصوص حسب مجالاتها أو حسب أزمنتها، فلو كان النص مثلاً يتضمّن مئات الآلاف من النصوص؛ فمن المهم أن نفصل مجالاتها المختلفة لتوضيح كل نص، أو أن نعيد صياغة توزيعها وفق الزمن، أو وفق الكتاب، أو وفق السياق الذي يمكننا الاعتماد عليه لتحقيق غرض التنظيم. وبحسب جودة البيانات النصيّة، سنلاحظ أنّ استخراج الآلة للموضوعات ذو مغزى، وتمكّنها هذه الجودة من تحديد الموضوعات، فتعمل على فصل النصوص أو المستندات بناء على كلّ موضوع، ثم على تحديد الكلمات ذات العلاقة بكلّ موضوع. فكيف لها أن تقوم بذلك؟ (الفصل الثالث).

• التعلّم المعزّز

يقوم على ترك الآلة تفكّر بنفسها، فتتدرب على تعزيز ذاتها بفهم المحيط والسلوك، ونجد هذا النوع من التعلّم في التطبيقات العمليّة المستخدمة في السيارات ذاتيّة القيادة، وفي روبوتات تنظيف الأرضيات، وفي الألعاب، وفي أتمتة التداول الماليّ، وأيضاً في بناء تطبيقي شعريّ يقوم على السّجال والردّ والنقائض، ويعتمد هذا التعلّم على معيار المكافأة (award)، أو العقوبة (penalty)، فكلما تحسّن التعلّم ارتفعت المكافأة، وكلما قلّ التعلّم ارتفعت العقوبة.

• الشبكات العصبية والتعلم العميق

تتضمن الشبكات العصبية مجموعة من الخلايا العصبية الاصطناعية ذات الطبقات، وتعمل الطبقة الأولى (الدخل) على فهم عناصر وسمات ما تريد تعلمه، ثم تنتقل إلى (الطبقة الخفية)، التي تحول تلك العناصر إلى أوزان رقمية، ثم تنتقل إلى الطبقة الأخيرة (الخرج)، التي تعد نهاية ما تم تعلمه. يُحدد المبرمج عدد الطبقات (layers)، وعدد العصبونات (neurons) من بداية التعلم، أما التعلم العميق فهو عبارة عن شبكية عصبية اصطناعية كبرى، ويتضمن بنيات عديدة من الشبكات العصبية^(١)، ففي نماذج التعلم العميق؛ تُحدد بنية شبكة التعلم العميق، ولكل شبكة وظيفة تعليمية.

إذا كان هناك مئات الآلاف من المدخلات في طبقة الدخل؛ فستتضاعف أوزانها في الطبقة الخفية بأرقام كبيرة جداً؛ نتيجة عمليات الضرب، فكل طبقة دخل ستحتوي على متغيرات $x_1, x_2, x_3, \dots$ ، وفي الطبقة الخفية سيتعامل كل عصبون مع متغير واحد، وينتج من هذا التعامل التعرّف لكل متغير قيمة كبيرة، نتيجة ضرب x_1 على الوزن w_1 ، ثم تُؤتمت هذه الطريقة على بقية المتغيرات، وصولاً إلى طبقة الخرج y ، الذي سيضمن قيمة ناتجة من عملية $x_1w_1 + x_2w_2 + x_3w_3 + \dots \times b$. ولتفادي هذه القيم الضخمة؛ يُستعمل ما يُسمى بنماذج التنشيط (activation functions)، وتُعرف بالـ (RELU)، و(Sigmoid)، و(Softmax)، و(Tanh)، التي تمارس دور تقليص الأوزان، فيجعل النموذج الأول الأوزان بين (0) و(1)، ويجعل النموذج الثاني الأوزان بين (0) و(1) عندما يكون المتغير ذا صنف واحد، ويجعل النموذج الثالث الأوزان بين (0) و(1) عندما يكون المتغير متعدد الأصناف، ويجعل النموذج الرابع الأوزان بين (-1) و(1). يصل التعلم في المخرجات إلى أن الآلة قد تعرّفت إلى الأشياء، فصارت تنظر وتنتطق وتسمع وتفهم مثل الإنسان، بعد أن تعلّمت كل السمات لتلك الأشياء عن طريق القيم الرقمية، وكل هذه الدوال

(١) لحج، محمد. مدخل إلى الذكاء الاصطناعي وتعلم الآلة. أكاديمية حاسوب، المملكة المتحدة، الطبعة الأولى، ٢٠٢٠، صفحة ١٠٨.

التَّشْطِيطِيَّةُ أَساسِيَّةٌ في تحسين نماذج التعلُّم العميق، وتُقيَّم باستخراج نسبة الخطأ عن طريق ما يُعرف بدالة الخسارة (Loss Function)، وتُحسَّن عن طريق خوارزميات عديدة كـ (Gradient Descent)، و (MiniBatch)، و (ADAM).

يكون هذا التعلُّم على مستوى اللغة النَّصِّيَّة، أما على مستوى مقاطع الفيديو؛ فتُدمج الشبكات العصبِيَّة التلافيفية (Convolutional Neural Networks CNN)، التي تُستخدم لفهم الصور ومقاطع الفيديو مع الشبكات العصبِيَّة المتكرَّرة (Recurrent Neural Networks RNN)، التي تُستخدم للتعرف إلى الكلام في تلك المقاطع. وينتج عن ذلك تزييف لمقاطع يتحدث فيها أشخاص، وهم في الحقيقة ليسوا هم أنفسهم. تخيل هنا الحجم الهائل من العمليَّات العميقة التي بها تتعلم الآلة جزئيات عناصر الأشياء؛ لتكتسب معرفة ماهيتها وصورتها، سواءً كانت صورةً (رؤية الحاسب)، أو كانت كلاماً شفهيّاً (التعرُّف إلى الكلام)، أو كانت نصّاً مترجماً منه، ونصّاً آخر مترجماً إليه (الترجمة الآلية)^(١).

وبالنسبة لمعالجة اللغة الطَّبِيعِيَّة التَّطْبِيقِيَّة؛ فساقف على مرحلتين متتابعين فيها؛ الأولى: المعالجة الأساسية التي تُعرف باسم (CoreNLP)، وهي منطلق المعالجة الآليَّة للغة الطَّبِيعِيَّة، والثَّانية: تطبيقات معالجة اللغة الطَّبِيعِيَّة، وهي نتاج المعالجة، وما تُفيد به من مهامّ متعددة.

(١) حول المداخل النظرية لمستويات معالجة اللغة الطَّبِيعِيَّة أولاً، والتعلم العميق وتطبيقاته في معالجة اللغة الطَّبِيعِيَّة ثانياً، والترجمة الآلية ثالثاً؛ انظر إلى المراجع الآتية:

الصانع، وليد. طرق ومستويات معالجة اللغة في الذكاء الاصطناعي. في: خوارزميات الذكاء الاصطناعي في تحليل النص العربي، ٢٠١٩، الصفحات ١٥-٤٤.

القنيعر، فارس. التعلم العميق وتطبيقاته في معالجة اللغة. في: خوارزميات الذكاء الاصطناعي في تحليل النص العربي، ٢٠١٩، الصفحات ٤٤-٦٨.

الراجح، عبدالله. الترجمة الآلية. في: خوارزميات الذكاء الاصطناعي في تحليل النص العربي، ٢٠١٩، الصفحات ٦٩-٩٣.

أولاً: معالجة اللغة الطَّبِيعِيَّة (المعالجة الأساسيَّة)

تعتمد كلُّ المعالجات الأساسيَّة؛ سواءً التَّابعة لستانفورد أم غيرها مما تضافرت معاً لأغراض التَّحسين، على قياس أداء أنظمتها الآليَّة. يُقاس أداء هذه الأنظمة بمقاييس مصفوفة الارتباك (confusion matrix): الصَّحَّة (accuracy)، والدَّقَّة (precision)، والاسترجاع (recall) ومقياس -F (F-score). تُستخدم هذه المقاييس لمعرفة دقة أداء النظام الآلي أو النموذج في بيانات الاختبار (أي: بيانات لم يَرها النظام بعد التَّدريب) في مَهَامُ معالجة اللغة الطَّبِيعِيَّة المتعلَّقة بالتَّصنيف. تعملُ مصفوفة الارتباك على اختبار نماذج تعلم الآلة ونماذج التَّعلم العميق، باستخراج نسبة الصَّحَّة، والدَّقَّة، والاسترجاع، ومقياس -F التي يتم حسابها وفق معادلة كلِّ مقياس: الصَّحَّة $\left(\frac{TP+TN}{TP+TN+FP+FN}\right)$ ، والدَّقَّة $\left(\frac{TP}{TP+FP}\right)$ ، والاسترجاع $\left(\frac{TP}{TP+FN}\right)$ ، ومقياس -F $\left(\frac{\text{الدقة} \times \text{الاسترجاع}}{\text{الدقة} + \text{الاسترجاع}} \times 2\right)$ ، حيث يشير (TP) إلى الإيجابيات الصحيحة true positives و (TN) إلى السُّلبات الصحيحة true negatives و (FP) إلى الإيجابيات الخطأ false positives و (FN) إلى السُّلبات الخطأ false negatives. على سبيل المثال، لو كان لدينا مُنَّة كلمة، ثُمَّ وَسَّمنَا يدوياً ٥٠ كلمةً منها على أنها أسماء؛ لأنها في الحقيقة أسماء، ثم وَسَّمنَا يدوياً الخمسين الأخرى على أنها أفعال؛ لأنها في الحقيقة أفعال، ثم درَّينا نموذجَ النظام الآليَّ على بيانات الاختبار، وذلك بعد تطبيق أشهر تقنية من تقنيات تقسيم البيانات (بيانات تدريب 80% - بيانات اختبار 20%)، ثم اختبرنا أداء فهم النموذج بعد التدريب على بيانات الاختبار، ستكون مُحصَّلة الكلمات في بيانات الاختبار ٢٠ كلمة، أي: ٢٠٪ من الكلمات المُنَّة (١٠ أسماء و ١٠ أفعال). إذن، يتكوَّن جدولُ مصفوفة الارتباك من القيم الحقيقيَّة للتَّصنيف الحقيقي ومن القيم التي تنبأ نموذج النظام الآليَّ بها في نتيجة تصنيفه لعشرة أسماء وعشرة أفعالٍ في بيانات الاختبار (الجدول ٢٦). وباستخدام معادلات مقاييس الارتباك الأربعة المذكورة سابقاً، ستكون نسبة الصَّحَّة $\left(\frac{8+6}{8+6+4+2}\right)$: 0.7، وبمعدَّل خطأ (0.3)، وستكون نسبة الدقة في فئة الأسماء $\left(\frac{6}{8+4}\right)$: 0.67، وستكون نسبة الاسترجاع في فئة الأسماء

$\left(\frac{6}{8+2}\right): 0.8$ ، وستكون نسبة مقياس -ف $\left(2X \frac{0.536}{1.47}\right): 0.67$. ويُعطينا مقياس -ف متوسط التوافق لنسبة الدقة والاسترجاع. أما نسبة الدقة والاسترجاع للتنبؤ بفئة الأفعال فهي (0.75) و(0.6)، ونسبة مقياس -ف: (0.67). ولا يُكتفى بنسبة الصحة؛ لأنَّ نسبة الدقة والاسترجاع مهمّة لكشف جودة أداء تصنيف النظام الآلي في بيانات الاختبار. ومهما كَثُرَتْ حالات الأصناف والفئات، فخوارزميات الآلة في قياس أداء النموذج الآلي في التصنيف تعمل آلياً على استخراج قيمة واحدة لكل مقياس من مقاييس مصفوفة الارتباك.

تُفيد الدقة بنسبة حالات الإيجابيات الخطأ (FP) إلى حالات الإيجابيات الصحيحة (TP). المثال على ذلك: أسماء صنّفها النظام الآلي في بيانات الاختبار على أنها أفعال (التصنيف: خطأ False)، والفئة الحقيقية ظهرت سلبية [أفعال] negative لكنَّ النموذج تنبأ على أنها إيجابية [اسم positive]. أمّا الاسترجاع فيُفيد بنسبة حالات السلبات الخطأ (FN) إلى حالات الإيجابيات الصحيحة (TP). والمثال على ذلك: أسماء صنّفها النظام الآلي في بيانات الاختبار على أنها أفعال (التصنيف: خطأ False)، والفئة الحقيقية ظهرت إيجابية [أسماء positive] لكنَّ النموذج تنبأ على أنها سلبية [أفعال negative].

جدول ٢٦: جدول مصفوفة الارتباك للقيم الحقيقية والقيم التنبؤية

التصنيف الحقيقي	التصنيف التنبؤي (نتيجة تصنيف نموذج النظام الآلي)		الاسترجاع
	أداء النموذج لتصنيف الأسماء	أداء النموذج لتصنيف الأفعال	
عشرة أسماء	8 (PT)	2 (NF)	10 أسماء تنبأ منها بـ 8 صحيحة (0.8)
عشرة أفعال	4 (PF)	6 (NT)	10 أفعال تنبأ منها بـ 6 صحيحة (0.6)
الدقة	12 اسمًا، تنبأ بـ 8 أسماء صحيحة (0.67)	8 أفعال، تنبأ بـ 6 أفعال صحيحة (0.75)	

تقومُ المعالجةُ الآليّةُ الأساسيّةُ للغة الطّبيعيّة على مَهَامٍّ أوليّة، وهي مهام ضروريّة، تُمكنُ المعالجة من فهم اللغة، وتُسمّى هذه المعالجة الأساسيّة بالمعالجة القبليّة (preprocessing)، ويُعتمد على معالجات ستانفورد، التي تتطوّر في بنائها منذ بداية تصميمها في عام ٢٠١٠، وصدور النّسخة الأولى 1.0، وصولاً إلى آخر إصدار 4.4.0 في ٢٠ يناير ٢٠٢٢م. وتعمل معالجات ستانفورد على بياناتٍ برمجيّة متعدّدة؛ مثل البايتون، والآر، والجافا، وجافا سكريبت، وبيرل، وسكالا، وغيرها، كما أنها تغطي اللغات الأساسيّة، ومن ضمنها اللغة العربيّة^(١). ويُعتمد كثيراً على (البايتون) في تعلّم الآلة للنصوص. إذا اخترت غير البايتون؛ فلن تجد كلّ المكتبات المهمة لمعالجة اللغة، ولنركّز هنا على التوكيد بـ (كلّ). تُعتبر لغة (البايتون) من أفضل لغات البرمجة لمعالجة اللغة الطّبيعيّة؛ نظراً لتوفر مكتبات عدّة للمعالجة، ومن أهمّها^(٢): مكتبة (Spacy)، ومكتبة (nltk)، ومكتبة (AllenNLP)، ومكتبات المعالجة الأساسيّة لستانفورد، ومكتبة المحوّلّات (Huggingface)، ومكتبة جينسم (Gensim) للتضمينات (Embeddings)، ومكتبة (Rasa) لفهم اللغة الطّبيعيّة (Natural Language Understanding) ولروبوتات المحادثة (chatbots).

(١) يُمكن استعمال معالجة اللغة الطّبيعيّة الأساسيّة لستانفورد في سبع عشرة لغة برمجيّة. انظر إلى الرابط الآتي:

Stanford NLP Group. (2020). Using CoreNLP with other programming languages and packages. Retrieved October 24, 2022, from <https://stanfordnlp.github.io/CoreNLP/other-languages.html>.

(٢) هذه مقدمة مفيدة في معالجة اللغة الطّبيعيّة بلغة البايتون:

Duque, Tiago. (2020). Peeling Natural Language Processing Layer by Layer: An Introductory Overview. In Medium [web source]. Retrieved October 24, 2022, from <https://tfduque.medium.com/dissecting-natural-language-processing-layer-by-layer-an-introductory-overview>.

لتعلّم (البايتون) من الصفر في الموقع الآتي مقدمة أساسيّة مختصرة وسهلة:
<https://www.kaggle.com/learn/python> (تاريخ الاسترداد ٢٤ أكتوبر ٢٠٢٢).

ممّ تتكون معالجات ستانفورد للغة الطّبيعيّة؟^(١) سأشيرُ في الآتي إلى مكونات معالجة اللغة الطّبيعيّة التي تُعرف بـ (Stanford CoreNLP). بعض ما سيُشار إليه ليس من ضمن حزمة معالجة اللغة العربيّة الطّبيعيّة الأساسيّة لستانفورد، كالمحلّل الصوتي، والدّلالي، والمقايي، وما تتكوّن منه هذه الحزمة هو: المقطّع (segmenter)، والموسّم النحويّ (postagger)، والمحلّل النحويّ (parser)، والتعرف على أسماء الكيانات (Named-Entity Recognition). وفيما يلي عرضٌ تفصيلي لمكوّنات المعالجة الآليّة للغات الطّبيعيّة.

المكون الأوّل: الترميز الذي يُستخدم لتقسيم وحدات النّص إلى وحداتٍ صغرى. تتفرّع وحدات النّص من أصغر وحدةٍ متمثّلة من الوحدة الصّوتيّة، إلى أكبر وحدةٍ متمثّلة من الوحدة التّداوليّة. والسؤال الذي يترتّب طرحه هو: ما الوحدة اللّغويّة التي يُمكنُ معالجتها آلياً؟ من خلال النّظر في المحلّلات اللّغويّة الآليّة؛ سنجد أنّ التّطبيقات التي تُصمّم لها منقسمةٌ إلى ما هوأت:

- **محلّل صرّفِيّ ونحويّ**، ونجد أنّهما في بعض الأنظمة يُعاملان على مُستوى واحد، وفي بعضها يُعاملان على أنّهما مستويان منفصلان. يعمل المحلّل الصرّفِيّ على معالجة الكلمة بالتّوليد والتّحليل، فبالتّوليد يستخرجُ المحلّل كلّ اشتقاقٍ الكلمة، وبالتّحليل يستخرجُ المحلّل جذرَ المشتقّات. مثل هذا العمل يكون لمحلّلاتٍ صرفيّةٍ منفصلةٍ عن التّحليل أو التّوسيم النّحويّ. أمّا ما يكون مدمجاً

(١) لا تندهش من كثرة أدوات المعالجة الأساسيّة، أو من كثرة مكتباتها، أو من كثرة نماذجها التي ستجد منها ما قد ظهر بمنهج القواعد، وما قد ظهر بمنهج تعلّم الآلة، وما قد ظهر بمنهج التّعلم العميق. تأكد من تتبّع الجديد (novelty) في كلّ مرحلة يُعلن فيها عن أداء أعلى للنماذج، وتتاح للاستخدام. كثرة النماذج الآليّة المطوّرة للغة هي العامل الرئيس الذي يُحقّق التّطوير المستمرّ في البناء والتحسين، والكثرة هنا مع عوامل التحسين سمةٌ ملتصقةٌ بكلّ ما يتعلق بتطور التقنيّات اللّغويّة. تجنّب في البحث العلميّ وفي العلوم اللّغويّة والإنسانيّة والاجتماعيّة النماذج القديمة ذات الأداء الأقل، واكتشف النماذج الجديدة ذات الأداء الأعلى، والمنشورة مع بياناتها اللّغويّة.

بينهما فنجده في بعض الأنظمة^(١) التي تعمل على استخراج السمات المورفيمية (morphemes) من الكلمات، ثم تعمل على التفريق ثم التوسيم النحوي حسب حالتها النحوية (اسم، فعل، ضمير).

● مُحللات للمعالجة الصوتية والدلالية والتداولية لبعض الأنظمة الآلية للغات الطبيعية، كالمحلل الصوتي الذي يعمل على تحليل الوحدات الصوتية (الفونيمية) للكلمة، ثم يعمل على تحويل الكلمات إلى توصيف صوتي خاص بها. يليه المحلل الدلالي الذي يعمل على بناء العلاقات الدلالية (الوجودية ontological) بين الكلمات كعلاقة الترادف^(٢)، ثم المحلل المقامي الذي يعمل على استكشاف المعاني السياقية، وما يعتور هذه المعاني من نمو، أو تغير، أو تخصيص، بناء على التأثير الفردي-النفسي أو البيئي أو الاجتماعي أو الثقافي على اللغة.

المكون الثاني: التفريق (tokenization)، والتقطيع (segmentation)، والتعجيم (lemmatization)،
فالتفريق يعمل بوظيفة الفاصل بين المكونات النصية التي تتطلب الفصل والتسوية

(١) (كلمة-ستار): مولّد ومحلّل صرفي للغة العربية، ويعمل على استخراج السمات المورفيمية القائمة على الصيغة والوظيفة، بالإضافة إلى التفريق بين الوحدات المورفيمية ووحدات الصيغة. وللمولّد الصرفي محرك متين، يمكن دمجه في أنظمة عديدة، بالإضافة إلى واجهة شبكية، وواجهة برمجة التطبيقات API:

Taji, D., Khalifa, S., Obeid, O., Eryani, F., Habash, N. (2018). An Arabic Morphological Analyzer and Generator with Copious Features. Proceedings of the Fifteenth Workshop on Computational Research in Phonetics, Phonology, and Morphology, October (pp. 140150-). Brussels (Belgium): Association of Computational Linguistics.

(٢) من المشاريع التي ظهرت بالصورة المطلوبة لبناء محلل دلالي للغة العربية هو مشروع (الأنطولوجيا العربية) من جامعة بيرزيت، وهو مشروع لشبكة الكلمات العربية، وصنفت الكلمات فيها حسب المعاني والعلاقات الدلالية. تاريخ الاسترداد ٢٤ أكتوبر، ٢٠٢٢، من: <https://ontology.birzeit.edu/>. وانظر أيضاً: Jarrar, M. (2021). The Arabic Ontology – An Arabic Wordnet with Ontologically Clean Content. Applied Ontology 16(1), 1-26.

الهجائية؛ مثل فصل علامات الترقيم، والأرقام، والرموز التي تتطلب أن تكون في حيز خاص بها بمسافة بينها وبين الكلمة، أو فصل العبارات أو الجمل إن كان التحليل سيُطبق على مستوى العبارات أو الجمل، وتحدد مهمة التفريق بتحديد مهمة المعالجة. أما التقطيع فيعمل على فصل المباني النحوية والصرفية؛ والمبنى النحوي مثل: حروف العطف (و، ف، ثم، بل)؛ لأن لمبانيها حالة نحوية خاصة بها، والمبنى الصرفي مثل: (أل) التعريف؛ لأن للتعريف والتأكيد حالة صرفية خاصة بها. هناك نماذج أو أنظمة للتوسيم النحوي تعمل على فصل المباني الصرفية، ولا أجد ذلك مفيداً؛ لأن المهم هو المبنى النحوي، أما المبنى الصرفي فهو متعلق بالكلمة، وقد صيغت الكلمة منه، وبناءً عليه، وفصله خطأ؛ لأننا بفصله نكون قد نزعنا من الكلمة المعالجة حالة التصريف الخاصة بها، والتقطيع مهم على مستوى المباني النحوية؛ من أجل دقة المعجم، والمعجم يعني أن ترد كل كلمة في النص إلى مادتها المعجمية (وليس الجذرية)، فمثلاً: لو عجمنا كلمة (تطعمون)، فالدقيق أن تكون المادة المعجمية (أطعم)، قد يتساءل أحد ويقول لماذا لم تكن المادة المعجمية هي (نطعم)، والجواب: أن أصل المادة المعجمية للأفعال هي الماضي، وتحت هذه المادة ترد كل صيغ الفعل المضارع الأربعة التي تبدأ بأحد حروف المضارعة (أ، ن، ي)، ولا يصلح أن نضع مادة معجمية مستقلة للفعل المضارع (نطعم). كذلك الحال مثلاً مع كلمة (أستاذة)، فمادتها المعجمية هي (أستاذ)، فترد صيغ المؤنث إلى الأصل المذكور.

المكون الثالث: التوسيم النحوي، وبه يعمل النظام على توسيم النص كلمة كلمة، بعد تهيئتها بالتفريق والتقطيع، وتختلف مجموعة التوسيم من حيث الوصف وعدد الواسمات النحوية من نظام إلى نظام. في نظام ستانفورد ثلاثة وثلاثون وسماً نحوياً، أئينها في الجدول (٢٧).

جدول ٢٧ : وسوم ستانفورد النحوية للغة العربية


الواسم	التعريف به	أمثلته
1	FW	كلمات أجنبية
2	CC	كلمات أجنبية
3	RB	أدوات الربط
4	WRB	الظروف
5	CD	أدوات الاستفهام
6	DT	كيف، لماذا، أين، متى
7	PRP	الأعداد
8	\$PRP	أسماء الإشارة
9	WP	الضمائر المتصلة والمنفصلة
10	IN	الضمائر الملكية المتصلة
11	RP	الأسماء الموصولة
12	UH	حروف الجر
13	PUNC	الأدوات
14	VBG	التعابير العاطفية
15	VBD	علامات الترقيم
16	VDN	المصدر العامل
17	VBP	الفعل التام
18	VB	الفعل المبني للمجهول
19	VN	الفعل المضارع
20	NN	فعل الأمر
		أسماء تشبه الأفعال
		أسماء شائعة

الواسم	التعريف به	أمثله
21	NNS	المثنى جمع المؤنث السالم
22	DTNN	اسم معرف مفرد
23	DTNNS	اسم معرف مثنى أو جمع
24	NOUN	أسماء التوكيد
25	NNP	اسم علم مفرد
26	NNPS	اسم علم جمع
27	DTNNP	اسم علم معرف مفرد
28	DTNNPS	ألفاظ الجموع
29	JJ	الصفات
30	ADJ	الصفات العددية
31	DTJJ	الصفات المعرفة
32	DTJJR	الصفات المعرفة للمقارنة
33	JJR	صفات المقارنة

المكوّن الرابع: التحليل النحوي^(١)، ويعمل على تحديد العلاقة بين كلمة وكلمة أخرى في الجملة، ويبنى بتصميم نماذج شجرية الاعتمادات (dependencies) للمكوّنات النحوية والتركيبية في الجمل؛ لتمثيل شجرة الاعتماد والعلائق النحوية. ومن أمثلة ما يقوم به

(١) سيلاحظ أن بعض الأنظمة تدمج بين المحلّلات الصّرفية والنّحوية، وبعضها تدمج بين المحلّلات النّحوية والتركيبية، وبعضها تنفرد بنظام واحد، إما للتحليل الصّرفي، أو للتّوسيم النّحوي، أو للتحليل التركيبي، وأحيل القارئ الذي يرغب في مزيد من التفاصيل عن البنوك الشجرية النّحوية إلى كتاب: روبي، أحمد محمد. البنك الشجري النّحوي بناؤه وتوظيفه في إطار تقنيات الذكاء الاصطناعي، مركز الملك عبدالله الدولي لخدمة اللغة العربيّة (مركز الملك عبدالله بن عبدالعزيز للتخطيط والسياسات اللّغوية حالياً)، الرياض، الطبعة الأولى، ٢٠١٧.

المعالج في التحليل النحوي للنصوص ما أجريته بمعالجات ستانفورد في (البايثون) على الجملة التالية: (من أقوال ولي العهد السعودي الخالدة الأمير محمد بن سلمان مهما حاولوا كبح جماحنا لن يتمكنوا من ذلك وهمة السعوديين كجبل طويق لن تنكسر إلا إذا تساوى هذا الجبل مع الأرض)، فظهرت نتيجة التحليل كما في الشكل (٧١).



شكل ٧١ : نتيجة تشجير النحو الاعتمادي

المكوّن الخامس: كلمات الإيقاف، وتعمل على إبعاد الكلمات المضمّنة في قائمة الإيقاف، وحرّي أن ينتبه المحلّل اللّغويّ إلى محتوى هذه القائمة المدمجة في بعض المعالجات، إذ قد يجد فيها ما يرغب في إزالته، أو لا يجد فيها ما يرغب في تضمينه. تتضمّن هذه القائمة عادةً الكلمات الوظيفيّة (حروف المعاني) التي يُراد استبعادها لتحقيق نتائج أكثر دقّة لبعض التطبيقات؛ مثل: استخراج الموضوعات. لننظر إلى الشكل (٧٢) الذي يتضمّن قائمة كلمات الإيقاف المدمجة في المعالجة الأساسيّة لستانفورد، سنلاحظ غياب بعض الكلمات التي قد يحتاج المحلّل اللّغويّ إلى تغييبها، على الرغم من إيراد ٢٤٣ كلمة إيقافيّة؛ مثل حرف العطف (و) بعد تقطيع النّص، وفصل المباني النّحويّة المتصلة بالكلمات، والذي يُلاحظ هو أن الواو لم تفصل؛ نظراً لمجيئها ملتصقة مع اسم الموصول «الذين» كما في «والذين»، وقد يوحي ذلك أنّ هذه القائمة معتمدة على النّصوص التي لم تُعالج بالتّقطيع. ونلاحظ -أيضاً- غرابة بعض الكلمات مثل (اللتيا)، التي تجيء في

التعبير الاصطلاحيّ النادر: (بعد اللتيا والتي) في العربيّة القديمة، ويعني: بعد الخصام والجدال. من المهم أن يتنبّه المحلّل إلى محتوى قوائم الإيقاف، فحرفُ العطفِ (و) مثلاً من أكثر الكلمات وروداً في مُدوّنَةِ القرآن الكريم (الشكل ٧٣)، إذ وردت ٩٥٥٢ مرةً، ونسبة تشكل ١٠,٩٪ من مجمل القرآن.


```
import nltk
```

```
from nltk.corpus import stopwords
```

```
", ".join(set(stopwords.words('arabic')))
```

والذين، نحو، لستم، أوه، هؤلاء، ومن، ذاك، كما، لئن، إذما، بما، إما، هما، بمن، فيم، هذي، اللاتي، لا، سوى، فلا، لو، فيما، أيها، اللتيا، لاسيما، وما، لكي، إنما، اللتان، كلا، ليست، لن، له، لكن، لوما، اللذين، لك، ذلك، ذو، كأنما، مما، فإن، ولكن، ذات، عسى، كليهما، وإذ، ليت، بل، إلا، كذا، هاته، خلا، ليسا، حيث، بي، ذي، أولئك، حتى، هذه، كيفما، إن، ولو، كلتا، أتمم، من، هذا، كليكما، سوف، هكذا، هذان، ولا، غير، بخ، أولاء، أه، أتما، هذين، كأين، هيهات، الذين، ذلكما، هنا، إنه، اللائي، لم، منه، عند، أما، على، ليسوا، بهما، كلما، بنا، ذينك، هاتين، هيت، لسن، متى، ذه، قي، إنا، هنالك، دان، حيثما، لست، لكنما، اللتين، ثمة، حين، إي، ليس، فإذا، أكثر، كي، ماذا، وهو، ممن، لستن، عليك، أين، أني، وإذا، لهن، كيت، بماذا، لهم، حبذا، منذ، مه، إذا، التي، بعض، إليكما، حاشا، لنا، بين، الذي، عل، لكما، إليك، بهن، قد، عدا، إيه، شتان، ذانك، ذلكم، هي، كل، إذ، بكما، وإن، لعل، تلكما، ألا، يا، هلا، بك، دون، والذي، اللذان، إليكم، أو، أي، تلك، لي، نحن، عما، كأى، ذواتي، أف، ذا، تينك، كلاهما، لدى، لكم، لما، بعد، ليستا، كأن، آها، بهم، عليه، هاهنا، ذوا، بلى، ما، هيا، هن، ذين، إذن، أن، ها، هم، بيد، فمن، لكيلا، هو، نعم، هاتان، ته، فيه، هناك، لولا، كيف، في، كم، أنا، لها، به، أنت، أقل، كذلك، أينما، إليكن، تلكنم، ثم، مع، اللواتي، أنتن، إلى، أم، بس، لستما، فيها، هاتي، مذ، لسننا، بها، هاك، ذلكن، عن، أي، منها، مهما، ذواتا، بكن، تين، لهما، هل، ريث

شكل ٧٢: قائمة كلمات الإيقاف في مكتبة nltk



شكل ٧٣: أكثر كلمات الإيقاف تكراراً

ثانياً: تطبيقات معالجة اللغة العربيّة الطّبيعيّة

تأتي مرحلة بناء النموذج بعد معالجة اللغة معالجةً أساسيّةً، وتتضمّن استخراج السمات والنّمذجة والاستدلال بالمقارنة مع الأعمال الأخرى، وتقييم الأداء لتطبيقات عديدة نذكرها مع التعريف الموجز لكل تطبيق.

لاستخراج النُصوص عدّة تطبيقات، تعمل على استخراج معلومات محدّدة، منها تلخيص النّص إلى الموضوعات الأساسيّة فيه، ومنها استخراج الكلمات المفتاحيّة للنص، ومنها -أيضاً- التعرّف إلى الكيانات من أسماء الأشخاص والأماكن والمنظّمات والشركات في النّص، أما تصنيف النُصوص فيعمل تطبيقه على نماذج التّصنيف، وتُستخدم هذه النماذج في تحليل المشاعر، واستخراج الموضوعات، وكشف النّيّة، والأخبار الزائفة، وتطبيقات التّصنيف بشكل عامّ. في تحليل المشاعر؛ يُحدّد النّص أو الفقرة أو الجملة فيما إن كانت إيجابيّة المشاعر أم سلبية المشاعر، ويعتمد في هذا التّصنيف على تدريب الآلة على عشرات الآلاف من التّصنيفات مسبقاً للتّعليم، التي حدّد فيها ما هو إيجابيّ وما هو سلبيّ، أو على معجم المشاعر الذي يتضمّن عشرات الآلاف من الكلمات الفصيحة واللهجيّة المصنّفة إلى ما هو إيجابيّ وما هو سلبيّ، ويمكن تطبيقها دون ذلك كلّه في أداة (أورانج)، عن طريق أداة (sentiment analysis)، واختيار اللغات المتعدّدة (multilingual)، ثم اختيار العربيّة (Arabic)، ولن يطبّق تحليل المشاعر على مُدوّنات القرآن

الكریم، تعالی کلام الله عن ذلك. ويُستعمل تصنيفُ النُصوص -أيضاً- في تطبيقات تصنيف الموضوعات، وفق خوارزمية التشابه الدلالي، أو تقليل الأبعاد، التي تستخرج الموضوعات من النصّ المتشابهة، ومن تطبيقات تصنيف النُصوص -أيضاً- ما يُعرف بكشف النية (intent detection)، الذي يساعد على تحديد الهدف من وراء النصّ، والذي يُستعمل كثيراً في التسويق، والمبيعات، والاشتراكات البريديّة، وكذلك كشف الأخبار الزائفة، أو كشف البريد الإلكتروني غير المرغوب فيه، أو كشف خطابات الكراهية، التي تفيدُ كلها العديد من الجهات الإعلاميّة والمؤسّسيّة.

من تطبيقات معالجة اللغة العربيّة الطّبيعيّة ما يُعرف برобوتات المحادثة والدّعم الافتراضيّ، الذي يعتمد على الأسئلة والأجوبة، وتعملُ هذه التّطبيقات على الإجابة الآليّة عن أسئلة المستخدمين، ويبنى هذا التطبيق بواسطة إدخال جميع الأسئلة المحتملة مع إدخال إجاباتها.

من تطبيقات معالجة اللغة العربيّة الطّبيعيّة التّصحیح الآليّ، والتّشكيل الآليّ، ويعتمدان في البناء على بيانات تُدرّب، وعلى معارف الآلة التي عولجت معالجةً أساسيّةً في فهم المكونات التحليلية الصّرفيّة والنّحويّة والتّركيبية للجملي العربيّة، ومعظم المصحّحات الآليّة حتى يومنا هذا مفيدةٌ، ولكن يبدو لي أنها ما زالت لا تعملُ على تصحيح كاملٍ لهمزات الوصل والقطع في بداية الكلمات العربيّة، التي أجدها أكثر أنواع الأخطاء شيوعاً في الكتابات العربيّة المعاصرة.

تُدمج الشّبكات العصبيّة التلافيفيّة (Convolutional Neural Networks CNN)، التي تُستخدم لفهم الصّور ومقاطع الفيديو مع الشّبكات العصبيّة المتكرّرة (Recurrent Neural Networks RNN)، في التّعرّف إلى الكلام في تلك المقاطع، وقد ينتج من ذلك وجود تزييفٍ لمقاطع يتحدّث فيها أشخاص، وهم في الحقيقة ليسوا هم أنفسهم. تخيل هنا الحجم الهائل من العمليّات العميقة التي بها تتعلّم الآلة جزئيات عناصر الأشياء؛ لتكتسب معرفة ماهيتها وصورتها، سواء كانت صورة (رؤية الحاسب)،

أو كانت كلاماً شفهيّاً (التعرُّف إلى الكلام)، أو نصّاً مترجماً منه ونصّاً آخر مترجماً إليه (الترجمة الآليّة). بدأت تطبيقات التّرجمة الآليّة بالاعتماد على منهج القواعد الذي يُحدّد أداء الآلة بقواعد معينة لا يخرج منها، ثم على منهج تعلم الآلة الإحصائيّ وتدريب النّماذج على تحذية الكلمة بالكلمة، والعبارة بالعبارة، والجملة بالجملة، وجميعنا يذكرُ حال التّرجمة الآليّة غير الدّقيقة للنصوص الطّويلة. طُوّرت تطبيقات التّرجمة الآليّة باستخدام نماذج التّعلّم العميق، فأصبح أدائها في الوقت الراهن أفضل بكثير. كذلك الحال في تعلّم الآلة العميق بخوارزميّات الشّبكات العصبيّة المتكرّرة (RNN) في التعرُّف إلى الكلام، الذي ساعد كثيراً تلك التّطبيقات التي نعيشُ معها الآن في التعرُّف إلى اللغة المنطوقة. وصَلَت هذه التّطبيقات في الوقت الراهن إلى مراحل متقدّمة من التّعلّم الآليّ في السّنتين الماضيتين، وبصورة ضخمة دأبت على السّعي في تحسين جودة حياة الإنسان في كثيرٍ من شؤونهِ الحيّاتيّة؛ في التّعليم، والاقتصاد، وذكاء الأعمال، ونجد ذلك بين مجتمعات النماذج المدربة مسبقاً (pre-trained models) بالشّبكات العصبيّة على اللغة والصّور والفيديوهات، وفي كلّ نموذج مجموعة من المطوّرين، الذين يعملون على تدريب الآلة بالتّعلّم العميق على بياناتٍ كبيرة. ومن أفضل هذه النّماذج حتى الآن ما يتعلّق بتضمّن الكلمات مثل (ELMo)، و(Flair)، وما يتعلّق بنماذج متعددة الأغراض مثل (ULMFiT)، و(Transformer)، و(Google's BERT وTransformer-XL)، و(OpenAI's GPT3)، بالإضافة إلى معالجات ستانفورد للغات الطّبيعيّة⁽¹⁾.

سيُعرض في الفصول القادمة تطبيقات أدوات تنقيب النصوص والبيانات (أورناخ) على مدوّنّة القرآن الكريم، وكما أسلفنا القول؛ فالتألف مع هذه الأداة بواجهة استخدامها السهل في الأبحاث اللّغويّة والإنسانيّة والاجتماعيّة ليس ترفاً، بل ضرورة، وحاجة مُلحّة للخروج من الأساليب التّقليديّة في تلك الأبحاث، وسيُحقّق هذا التألف


(1) Qui, X., Sun, T., Xu, Y., Shao, Y., Daj, N., Huang, X. (2020). Pre-trained models for natural language processing: A survey. Science China Technological Sciences 63, 1872-1897.

تمهيد الطريق إلى معرفة عمل تطبيقات الذكاء الاصطناعي في النص اللغوي أولاً، ثم إتاحة سبل إدراك ما يحدث في عالم الثورة الرقمية ثانياً، ثم دخول المهتمين بالعلوم اللغوية والإنسانية والاجتماعية إلى هذا العالم، أسوة بأقرانهم في المراكز البحثية العالمية ثالثاً، فالعلوم الإنسانية والاجتماعية اليوم قد باتت تتمحور في ما يُعرف بالإنسانيات الرقمية (digital humanities)، والمُدونات اللغوية (corpora)، وتقنيات اللغة (language technologies) في معظم أهم المراكز والمؤسسات والجامعات في العالم.

الفصل الأوّل تنقيب النُّصوص


هناك أربعة مصطلحاتٍ تطبيقيةٍ يجبُ معرفتها عندما نقرأ في معالجة اللغة الطَّبِيعِيَّة في منصات البرمجة في البايثون؛ وهي: المكتبة (library)، والحزمة (package)، والوحدة (module)، والإطار (framework)، والنموذج (model). تتضمّن المكتبة مجموعةً من الحزم، وتتضمّن الحزمة الواحدة مجموعةً من الوحدات. هناك كثيرٌ من المكتبات لمعالجة اللغة الطَّبِيعِيَّة، مثل مكتبة (nltk). بعد تنصيب هذه المكتبة في البايثون؛ يُمكن تنصيب حزمة من الحزم التي بداخلها؛ مثل (nltk.corpus)، وهي المُدَوَّنَات اللُّغَوِيَّة، ثم يُمكن مثلاً أن نستدعي وحدة كلمات الإيقاف (stopwords) من الحزمة. أما الإطار فيتضمّن مجموعةً من الحزم والوحدات التي تعمل في مسار بناء التَّطبيقات في (البايثون)، مثل جانغو (Django)، وفلاسك (Flask)، وبوتل (Bottle). أما النموذج فهو مجموعة خوارزميات رياضية من القواعد، والإحصاء، والشبكات العصبية التي تعمل في معالجة اللغة الطَّبِيعِيَّة للاستخراج، والتصنيف، والفهم، والاستيعاب، والاختبار، والتوليد.

ليس هناك واجهة عريضة لأداة أورانج، ولكنها سهلة الاستخدام، ويُمكن الدخول إليها عن طريق تنزيلها مباشرة، أو عن طريق بيئة (anaconda)، ويكون تنزيل الأداة مباشرة من خلال الرابط <https://orangedatamining.com>، ويُختار نظام تشغيل الجهاز الشَّخصي؛ سواء كان ويندوز، أو ماك، أو لينكس. وبعد فتح الأداة؛ لا بُدَّ من تنصيب مكتبة (Text)، وذلك عن طريق الضَّغْطِ على (خيارات Options)، ثم اختيار (الإضافات Add-ons) كما في الشَّكْل (٧٤). بعد تنصيب المكتبة، وإعادة فتح الأداة؛ يتمُّ التأكُّد من تنصيب هذه المكتبة بظهور صندوق أدوات تنقيب النُّصوص (Text Mining).




شكل ٧٤: واجهة أداة (أورانج) وخيارات ونافذة تنصيب مكتبة Text

أشيرُ في الشَّكْل (٧٥) إلى ثلاثة أمثلة لربط الأدوات (widgets) في مسار عمل المعالجة من صندوق تنقيب النصوص (Text Mining)، وكلّ مسار يُعدُّ استخداماً معيّناً لمهمّة من مهامّ المعالجة.



شكل ٧٥: أمثلة لأساليب ربط مسارات العمل للتَّحليل





شكل ٧٧: مثال ترابط الأدوات وتمثيل خرجها داخل أداة (أورانج) لتنصير البيانات واستعراض هيكلتها

يُبدأ العملُ بسحب أداة من أدوات تصدير النصوص من صندوق تنقيب النصوص (Text Mining): كسحب المُدوَّنة، أو تصدير المستندات / المجلدات، أو ويكيبيديا، أو تويتر. أما بقية أدوات التَّصدير (صحيفة الجارديان، وصحيفة نيويورك تايمز، وقواعد بيانات مُلَخَّصات الأبحاث الطَّبَّيَّة) فلا تتعلق باللغة العربية، وأما بقية الأدوات فهي الأدوات التي تُستخدم لتنقيب النصوص ومعالجتها، وهي الأدوات التي ستُستخدم لمعالجة نصوص القرآن الكريم. ولا تعمل كل تلك الأدوات إلا بعد ربطها بالأداة الأخرى عن طريق إخراج مسار بزر الفأرة من أداة المُدخِل (input) إلى أداة المُخرَج (output). ولتجنُّب الإكثار من الأشكال التَّوضيحية؛ سيكتفى بصورتين توضيحتين (الشكل ٧٦ والشكل ٧٧). تُبيِّن صورة الشكل (٧٦) هيئة ترابط الأدوات الآتية: (المُدوَّنة، والمعالجة القبليَّة للنَّص، ومنظار المُدوَّنة، وسحابة الكلمات)، وتُبيِّن صورة الشكل (٧٧) هيئة ترابط الأدوات الآتية: (تصدير المستندات / المجلدات، ومنظار المُدوَّنة، وجدول البيانات)، ويتعامل المستخدم بهذا الأسلوب الذي يُعرف بمسار العمل (workflow) مع جميع الأدوات حسب الاستخدامات المحددة لكل مهمَّة من مهمَّات المعالجة.

تتضمَّن المعالجة القبليَّة للنصوص ستَّ وظائف؛ وهي: التَّحويل (Transformation)، والتَّفريق (Tokenization)، والتَّسوية (Normalization)، والتَّصفية (Filtering)، ومدى التَّتابعات اللَّفْظيَّة أو النِّغمات (N-grams Range)، والوسوم النَّحويَّة (POS Tagger)، وسيُشارف في الآتي إلى الاستخدامات المفيدة فقط للنَّص العَرَبِيَّ من تلك الوظائف.

التَّحويل: يُمكن استخدام التَّحويل في معالجة النصوص العَرَبِيَّة معالجةً قبليَّةً، كأن يتم إزالة الروابط والرموز في حال كان النَّص العَرَبِيَّ من المواقع الشَّبكيَّة.

التَّفريق: وبه يُمكن تفريق ما يردُّ من النَّص من علامات ترقيم، فيعمل التَّفريق هنا على فصل تلك العلامات عن الكلمات، كما يُمكن إجراء التَّفريق على مستوى الجمل، فيعمل التَّفريق على فصل الجملة عن الجملة بمعيَّار وجود النُّقطة.

التسوية: وفيه يختار المستخدم إما المقطع بمنهج (Porter)، أو بمنهج (Snowball)، أو بمنهج مُعْجَم شبكة الكلمات (WordNet Lemmatizer) الذي يعمل على إرجاع الكلمة إلى مادتها المعجمية الأصلية، والذي يعتمد على المعرفة اللغوية - الآلية التي بُنيت في قواعد البيانات المعجمية، أو بمنهج مُعْجَم النحو الاعتمادي الكلي (Universal Dependency Pipe (UDPipe) Lemmatizer). يعمل المنهج الأول والثاني على إرجاع الكلمة إلى جذعها، وتكمن مشكلة هذين المنهجين في التعامل مع بعض الكلمات التي تُعد في صيغتها المستعملة أصلية، فيتعامل معها لشبهها بأسماء أخرى؛ بسبب التشابه في الصيغة، مثل: «الذان» التي يتعامل معها بوصفها مثنى، فيُجري لها تسوية بحذف الألف والنون على اعتبارهما من علامات المثنى، وتنبع هذه المشكلة من بيانات التدريب والاختبار التي اعتمد عليها في هذين المنهجين. أما منهج معجم شبكة الكلمات فليس شمولياً؛ لأنه يعتمد على تسوية محدودة. وأفضل ما يُستعمل للعربية هو معجم النحو الاعتمادي الكلي للعربية؛ لأنه يتضمن التقطيع والتوسيم والتحليل النحوي معاً.

التصفية: وبه يُضيف المستخدم كلمات الإيقاف، أو يُضيف معجمه الخاص الذي يرغب في تصفيته، أو يعتمد على التعبيرات النمطية. ومن أكثر التعبيرات النمطية المفيدة للنصوص العربية استعمال `\bword\b` واستبدال `b` الأولى بكلمة معينة؛ ليعمل هذا التعبير المنطقي على استخراجها دون غيرها، واستعمال `w+` لاستخراج الكلمات فقط في حال كان النص يتضمن علامات ترقيم أو رموز، واستعمال `\b(B|b)w+|b`، واستبدال `b` داخل القوسين بأي حرف ليعمل هذا التعبير المنطقي على استخراج كل الكلمات التي تبدأ بهذا الحرف المحدد، واستعمال `w{5,}|` لاستخراج الكلمات التي تتكون حروفها من أكثر من خمسة أحرف، واستعمال `\b|w+(Y|y)|b` واستبدال `y` داخل القوسين بحرف ما؛ ليستخرج كل الكلمات التي تنتهي بهذا الحرف المحدد.

المدى: اختيار مدى التابع اللفظي (يم-يس).

الوسوم النحويّة: وبها تُوسَّم الكلمات في النصّ، ويعتمدُ على منهجين؛ الأول واسم بيرسبتون المتوسط (Averaged Perceptron Tagger)، وواسم البنك الشجريّ (Treebank POS Tagger)، وأفضل النتائج يُعطيه المنهج الثاني.

المبحث الأول: إعداد البيانات اللغويّة في جدولة بيانات

يتطلّب من المستخدم إعداد البيانات في ملف الأكسل بتهيئة محدّدة؛ لكي تتعامل أداة (أورانج) معها على الوجه الصّحيح، أُشيرُ هنا إلى أسلوب إعداد البيانات اللغويّة للنصوص العربيّة بالصورة الأولى المطلوبة، وسأقف على إعداد البيانات اللغويّة بمُتغيّراتها المتعدّدة من غير النصوص في الفصل الخامس. لإعداد البيانات اللغويّة أساليب محدّدة، لكلّ منها مهمّة، وفي أداة أورانج؛ المطلوب هو عنونة خصائص المتغيّرات فيما إن كانت نصّاً أو كانت فنويّة. في مثالنا عن تنقيب مدوّنة القرآن الكريم، هيأت البيانات على النحو الآتي.

أولاً: حدّد عدد الصفوف بحسب عدد السور ليكون ١١٤ صفّاً فقط، ويتضمّن العمود الأول التصنيف الفئويّ (أسماء السور القرآنية)، ويتضمّن العمود الثاني آيات السورة (الشكل ٧٨)، وستستخدم هذه البيانات في المبحث الثاني من هذا الفصل. أمّا في الشكل (٧٩) فتضمّن العمود الأول -أيضاً- أسماء السور القرآنية، أما العمود الثاني؛ فتضمّن كلّ صفٍّ فيه آية قرآنيّة واحدة؛ ليكون عدد الصفوف في هذه البيانات ٦٢٣٦ صفّاً، وستستخدم هذه البيانات في استخراج الكلمات المفتاحيّة (المبحث الثاني في الفصل الثالث). يتمّ ذكر الفئة (category) على أنه نصّ (Text)، ثم d (المتغيّر الاسمي)، الذي يشير إلى نوع ما سيعالج (سلسلة حرفيّة)، والنصوص توصف على أنّها (string)، ثم الصنف (class) على أنّه حقيقيّ كما هو (True)، ويعني أنّ جميع أسماء السور صحيحة في المدخل المكتوب.

Category	Text
d	string
class	include=True
الفاتحة	بسم الله الرحمن الرحيم الحمد لله رب العالمين الرحمن الرحيم مالك يوم الدين
البقرة	الم ذلك الكتاب لا ريب فيه هدى للمتقين الذين يؤمنون بالغيب ويقيمون الصلاة
آل عمران	الم الله لا إله إلا هو الحي القيوم نزل عليك الكتاب بالحق مصدقاً لما بين يديه وأنزل
النساء	يا أيها الناس اتقوا ربكم الذي خلقكم من نفس واحدة وخلق منها زوجها وبث منهما
المائدة	يا أيها الذين آمنوا أوفوا بالعقود أحلت لكم بهيمة الأنعام إلا ما يتلى عليكم غير محلي
الأنعام	الحمد لله الذي خلق السماوات والأرض وجعل الظلمات والنور ثم الذين كفروا
الأعراف	المص كتاب أنزل إليك فلا يكن في صدرك حرج منه لتنذره وذكرى للمؤمنين
الأنفال	يسألونك عن الأنفال قل الأنفال لله والرسول فاتقوا الله وأصلحوا ذات بينكم
التوبة	براءة من الله ورسوله إلى الذين عاهدتم من المشركين فسبحوا في الأرض أربعة أشهر
يونس	الرتلك آيات الكتاب الحكيم أكان للناس عجباً أن أوحينا إلى رجل منهم أن أنذر الناس
...	...

شكل ٧٨ : شكل هيكلية البيانات لمعالجتها في أداة أورانج

Category	Text
d	string
class	include=True
الفاتحة	بسم الله الرحمن الرحيم،
الفاتحة	الحمد لله رب العالمين،
الفاتحة	الرحمن الرحيم،
الفاتحة	مالك يوم الدين،
الفاتحة	إياك نعبد وإياك نستعين،
الفاتحة	اهدنا الصراط المستقيم،
الفاتحة	صراط الذين أنعمت عليهم غير المغضوب عليهم ولا الضالين،
البقرة	الم،
البقرة	ذلك الكتاب لا ريب فيه هدى للمتقين،
...	...

شكل ٧٩ : شكل هيكلية البيانات لمعالجتها في أداة أورانج

ثانياً: تهيئة بيانات حقيبة الكلمات، وتضمين الكلمات (الفصل الثاني)، واستخراج الموضوعات (المبحث الأول في الفصل الثالث). تطلب ذلك تحديد الصنف (class) -مكية أو مدنية- في العمود الأول، وهي منفصلة (discrete)، وليست متصلة (continuous)؛ لأن كل صنف يتضمّن متغيراً ثابتاً له، ثم العنوان (Title)، الذي يتضمّن اسم السورة في العمود الثاني، ثم المحتوى (Content)، الذي يتضمّن آيات السورة، ثم رقم ترتيب السورة (Numerical). واحتجت هنا إلى أربعة أعمدة بدلاً من عمودين. وعند التعلّم، يُشار إلى عناوينها بشكل عمودي كما في الشكل (٨٠)، وتدخل كل آية في صف واحد، ليكون عدد الصفوف ٦٢٣٦ صفًا. أما الشكل (٨١) فكل سورة كاملة قد وُضعت في صف واحد.

Topic	Title	Content
discrete	string	string
class		include=True
مكية	الفاتحة	بسم الله الرحمن الرحيم
مكية	الفاتحة	الحمد لله رب العالمين
مكية	الفاتحة	الرحمن الرحيم
مكية	الفاتحة	مالك يوم الدين
مكية	الفاتحة	إياك نعبد وإياك نستعين
مكية	الفاتحة	اهدنا الصراط المستقيم
مكية	الفاتحة	صراط الذين أنعمت عليهم غير المغضوب عليهم ولا الضالين
مدنية	البقرة	الم
مدنية	البقرة	ذلك الكتاب لا ريب فيه هدى للمتقين
مدنية	البقرة	الذين يؤمنون بالغيب ويقيمون الصلاة وما رزقناهم ينفقون
مدنية	البقرة	والذين يؤمنون بما أنزل إليك وما أنزل من قبلك وبالآخرة هم يوقنون
مدنية	البقرة	أولئك على هدى من ربهم وأولئك هم المفلحون
مدنية	البقرة	إن الذين كفروا سواء عليهم أأنذرتهم أم لم تنذرهم لا يؤمنون
مدنية	البقرة	ختم الله على قلوبهم وعلى سمعهم وعلى أبصارهم غشاوة ولهم عذاب عظيم
مدنية	البقرة	ومن الناس من يقول آمنا بالله وباليوم الآخر وما هم بمؤمنين
...	...	...

شكل ٨٠: شكل هيكلية البيانات لمعالجتها في أداة أورانج

Topic	Title	Content	Numerical
discrete	string	string	string
class		include=True	
مكية	الفاحة	بسم الله الرحمن الرحيم الحمد لله رب العالمين الرحمن الرحيم ملك يوم الدين	1
مدنية	البقرة	الم ذلك الكتاب لا ريب فيه هدى للمتقين الذين يؤمنون بالغيب ويقيمون الصلاة	2
مدنية	آل عمران	الم الله لا إله إلا هو الحي القيوم نزل عليك الكتاب بالحق مصدقاً لما بين يديه وأنزل	3
مدنية	النساء	يا أيها الناس اتقوا ربكم الذي خلقكم من نفس واحدة وخلق منها زوجها وبث	4
مدنية	المائدة	يا أيها الذين آمنوا أوفوا بالعقود أحلت لكم بهيمة الأنعام إلا ما يتلى عليكم غير	5
مكية	الأنعام	الحمد لله الذي خلق السماوات والأرض وجعل الظلمات والنور ثم الذين كفروا	6
مكية	الأعراف	المص كتاب أنزل إليك فلا يكن في صدرك حرج منه لتنذره وذكرى للمؤمنين	7
مدنية	الأنفال	يسألونك عن الأنفال قل الأنفال لله والرسول فاتقوا الله وأصلحوا ذات بينكم وأطيعوا	8
مدنية	التوبة	براءة من الله ورسوله إلى الذين عاهدتم من المشركين فسيحوا في الأرض أربعة	9
مكية	يونس	الترلك آيات الكتاب الحكيم أكان للناس عجباً أن أوحينا إلى رجل منهم أن أنذر	10
...	...	...	...


شكل ٨١ : شكل هيكلية البيانات لمعالجتها في أداة أورانج

يمكن استخدام متغيرات غير نصية، وفي هذه الحالة؛ تكتب سمة المتغير، فبدلاً من (string)، أو اختصاره (s) التي تشير إلى النصوص؛ نرمز بـ (d) للإشارة إلى المتغيرات الاسمية، أو نكتب (continuous)، أو اختصاره الرمز: (c) للمتغيرات المقياسية المتصلة، أو نكتب (time)، أو اختصاره الرمز: (t) للتواريخ.

المبحث الثاني: الإحصاءات وتكرار الكلمة-تكرار المستند العكسي

تتوفر إحصاءات أولية للمدونة اللغوية، ويمكن اختيارها جميعاً، أو اختيار ما يُراد معرفته منها، وتتكون هذه الإحصاءات من عدد الكلمات، وعدد الحروف، وعدد التتابعات اللفظية (النغراميات)، ومتوسط طول الكلمات في المدونة، وعدد علامات الترقيم إن تركزت في النص دون إزالة في المعالجة القبلية للنص، والنسبة المئوية للكلمات الفريدة، وعدد الكلمات التي يُحدد حروفها الأولى، كأن تكون مثلاً (أل) التعريف، وعدد

الكَلِمَات التي يُحدّد حروفها الأخيرة، كأن تكون مثلاً الألف المقصورة (ى)، وعدد التعبيرات النمطية (regular expressions)، التي تعتمد على رموز تكشف أنماطاً محددة من النصّ، وعدد الوسوم النحويّة إذا أضاف المستخدم في المعالجة القبلية للنّص خيارَ رسم النّص. في الشّكل (٨٢) مساران للمعالجة في أداة المُدوّنَة، وفيهما بيانات الشّكل (٧٨). المسار الأوّل للإحصاء، والثّاني لتجزئة التشابه (similarity hashing). عَرَضْتُ نتاجَ الإحصائيات في الجدول (٢٨)؛ لتوضيح أربعة حساباتٍ فقط لبيانات آيات القرآن الكريم، ثم عَرَضْتُ نتيجةَ تجزئة التشابه في الشّكل (٨٣).



شكل ٨٢ : مسارا العمل للإحصاءات وتجزئة التشابه

Index	ATU Type	Title	Content	ATU Numerical	simhash_1_True	simhash_2_True	simhash_3_True	simhash_4_True	simhash_5_True	simhash_7_True	simhash_9_True	simhash_10_True	simhash_11_True	simhash_12_True
1	ملاحظة	ملاحظة	1	1	1	1	1	1	1	1	1	1	1	1
2	ملاحظة	ملاحظة	2	1	1	1	1	1	1	1	1	1	1	1
3	ملاحظة	ملاحظة	3	1	1	1	1	1	1	1	1	1	1	1
4	ملاحظة	ملاحظة	4	1	1	1	1	1	1	1	1	1	1	1
5	ملاحظة	ملاحظة	5	1	1	1	1	1	1	1	1	1	1	1
6	ملاحظة	ملاحظة	6	1	1	1	1	1	1	1	1	1	1	1
7	ملاحظة	ملاحظة	7	1	1	1	1	1	1	1	1	1	1	1
8	ملاحظة	ملاحظة	8	1	1	1	1	1	1	1	1	1	1	1
9	ملاحظة	ملاحظة	9	1	1	1	1	1	1	1	1	1	1	1
10	ملاحظة	ملاحظة	10	1	1	1	1	1	1	1	1	1	1	1
11	ملاحظة	ملاحظة	11	1	1	1	1	1	1	1	1	1	1	1
12	ملاحظة	ملاحظة	12	1	1	1	1	1	1	1	1	1	1	1
13	ملاحظة	ملاحظة	13	1	1	1	1	1	1	1	1	1	1	1
14	ملاحظة	ملاحظة	14	1	1	1	1	1	1	1	1	1	1	1
15	ملاحظة	ملاحظة	15	1	1	1	1	1	1	1	1	1	1	1
16	ملاحظة	ملاحظة	16	1	1	1	1	1	1	1	1	1	1	1
17	ملاحظة	ملاحظة	17	1	1	1	1	1	1	1	1	1	1	1
18	ملاحظة	ملاحظة	18	1	1	1	1	1	1	1	1	1	1	1
19	ملاحظة	ملاحظة	19	1	1	1	1	1	1	1	1	1	1	1
20	ملاحظة	ملاحظة	20	1	1	1	1	1	1	1	1	1	1	1
21	ملاحظة	ملاحظة	21	1	1	1	1	1	1	1	1	1	1	1
22	ملاحظة	ملاحظة	22	1	1	1	1	1	1	1	1	1	1	1
23	ملاحظة	ملاحظة	23	1	1	1	1	1	1	1	1	1	1	1
24	ملاحظة	ملاحظة	24	1	1	1	1	1	1	1	1	1	1	1
25	ملاحظة	ملاحظة	25	1	1	1	1	1	1	1	1	1	1	1
26	ملاحظة	ملاحظة	26	1	1	1	1	1	1	1	1	1	1	1
27	ملاحظة	ملاحظة	27	1	1	1	1	1	1	1	1	1	1	1
28	ملاحظة	ملاحظة	28	1	1	1	1	1	1	1	1	1	1	1
29	ملاحظة	ملاحظة	29	1	1	1	1	1	1	1	1	1	1	1
30	ملاحظة	ملاحظة	30	1	1	1	1	1	1	1	1	1	1	1
31	ملاحظة	ملاحظة	31	1	1	1	1	1	1	1	1	1	1	1
32	ملاحظة	ملاحظة	32	1	1	1	1	1	1	1	1	1	1	1
33	ملاحظة	ملاحظة	33	1	1	1	1	1	1	1	1	1	1	1
34	ملاحظة	ملاحظة	34	1	1	1	1	1	1	1	1	1	1	1
35	ملاحظة	ملاحظة	35	1	1	1	1	1	1	1	1	1	1	1
36	ملاحظة	ملاحظة	36	1	1	1	1	1	1	1	1	1	1	1
37	ملاحظة	ملاحظة	37	1	1	1	1	1	1	1	1	1	1	1
38	ملاحظة	ملاحظة	38	1	1	1	1	1	1	1	1	1	1	1
39	ملاحظة	ملاحظة	39	1	1	1	1	1	1	1	1	1	1	1
40	ملاحظة	ملاحظة	40	1	1	1	1	1	1	1	1	1	1	1
41	ملاحظة	ملاحظة	41	1	1	1	1	1	1	1	1	1	1	1
42	ملاحظة	ملاحظة	42	1	1	1	1	1	1	1	1	1	1	1
43	ملاحظة	ملاحظة	43	1	1	1	1	1	1	1	1	1	1	1
44	ملاحظة	ملاحظة	44	1	1	1	1	1	1	1	1	1	1	1
45	ملاحظة	ملاحظة	45	1	1	1	1	1	1	1	1	1	1	1
46	ملاحظة	ملاحظة	46	1	1	1	1	1	1	1	1	1	1	1
47	ملاحظة	ملاحظة	47	1	1	1	1	1	1	1	1	1	1	1
48	ملاحظة	ملاحظة	48	1	1	1	1	1	1	1	1	1	1	1

شكل ٨٣: تجزئة التشابه

جدول ٢٨ : نموذج إحصاءات كُلِّ آية من سورة الفاتحة

السورة	الآية	الكلمات	الحروف	التتابع اللفظي	متوسط الكلمة
الفاتحة	بسم الله الرحمن الرحيم	4	19	4	4.75
الفاتحة	الحمد لله رب العالمين	4	18	4	4.5
الفاتحة	الرحمن الرحيم	2	12	2	6
الفاتحة	مالك يوم الدين	3	12	3	4
الفاتحة	إياك نعبد وإياك نستعين	5	19	5	3.8
الفاتحة	اهدنا الصراط المستقيم	3	19	3	6.333
الفاتحة	صراط الذين أنعمت عليهم غير المغضوب عليهم ولا الضالين	10	44	10	4.4

من إحصاءات المُدَوَّنَات اللُّغَوِيَّة في معالجة اللغة الطَّبِيعِيَّة ما يُعرف بتكرار الكلمة - تكرار المستند العكسي (Term-Frequency Inverse Document Frequency)، واختصاره (TF-IDF)، وهو مختلفٌ عن التَّكرَّار المطلق والتَّكرَّار النَّسَبِي الذي تناولته في المبحث الثَّاني من الفصل الأول، فهو لا يَهْتَمُّ بِرَتَبِ الكَلِمَات وتكراراتها المطلقة والنسبية، بل بالكَلِمَات المهمَّة في النُّصوص، فيعطي الكَلِمَات الأكثر تكراراً بين النُّصوص قيمةً أقل بين الصِّفر والواحد، ويعطي الكَلِمَات المهمَّة بين النُّصوص قيمةً أعلى بين الصِّفر والواحد.

تعمل هذه الخوارزمية على إجراء حساب بين تكرار كُلِّ كلمة، وعدد ورودها في كُلِّ نَصٍّ، ومجموع عددِ الكَلِمَات كُلِّها في المُدَوَّنَة، وذلك وفق المعادلة الآتية:

$$\bullet \text{ تكرار الكلمة TF} = \text{تكرار الكلمة} \div \text{إجمالي عدد الكَلِمَات في المُدَوَّنَة}$$

$$\bullet \text{ تكرار المستند العكسي IDF (للكلمة)} = \left(\frac{\text{عدد النُّصوص}}{\text{عدد النُّصوص التي في الكلمة}} \right)$$

- تكرار الكلمة-تكرار المستند العكسي TF-IDF (للكلمة) = لوغ (نسبة تكرار الكلمة × نسبة تكرار المستند العكسي)

يتميّز هذا الإحصاء للكلمات بعدم تركيزه على مبدأ زيف (Zipf) في التنازل الطبيعيّ لورود الكلمات في النصوص اللغويّة، بل على أهميّة الكلمة في النصّ، والأهميّة هنا دلالة على توزّع الكلمة توزّعاً يحمل أهميّة معنويّة لها. ولا تتضمّن أداة (أورانج) حساب تكرار الكلمة-تكرار المستند العكسيّ، وعليه يُمكن تطبيقها باستخدام الأكواد^(١) في (البايثون) كما في الملحق (د). عَرَضْتُ أَوَّلَ خمسين كلمة من نتيجة تكرار الكلمة-تكرار المستند العكسيّ من ملفّ (السُّور المكيّة) وملفّ (السُّور المدنيّة) كما في الملحق (هـ).

(1) Lavin, M. J. (2019). Analyzing Documents with TF-IDF [Online Lessons]. In: Z. LeBlanc (Ed.), The Programming Historian. Retrieved October 24, 2022, from <https://doi.org/10.46430/phen0082>.

الفصل الثاني

حقيقة الكلمات وتضمين الكلمات

عندما تتعامل الآلة مع النصوص؛ أي: عندما تُنمذج الآلة النصوص؛ فهي تُحوّل الكلمات في هذه النصوص إلى أرقام. لُخصت بعض الممارسات التقنية في نمذجة الكلمات العربية، وهو تلخيص جدير بالاطلاع من اللغويين المهتمين^(١).

سألخص فيما يأتي فكرة تحويل الكلمات إلى أرقام، وفق المناهج المطبقة في معالجة اللغة الطبيعية، وذلك من وجهة نظر لغوية. لعمليات التحويل ثلاث مراحل أساسية؛ الأولى: الترميز بالرقم الواحد (One hot encoding)، وهي مرحلة قديمة لا تصلح. والثانية: حقيقة الكلمات (Bag of Words BOW)، التي عالجت مشكلة المرحلة الأولى. والثالثة: تضمين الكلمة (Word Embedding)، أو نماذج الكلمة إلى متجه (word2vec)، التي تعدّ الأفضل في نمذجة الكلمات العربية في النصوص.

يعمل الترميز بالرقم الواحد كالآتي؛ لنفترض أنّ القاموس الذي لدينا يتضمّن الجملة الآتية: (جاء محمد إلى المنزل). يعمل الترميز بتمثيل (جاء) بالرقم (١)، وبتمثيل البقية بالرقم (٠)، ثم في المرة الثانية يعطي الرقم (١) لكلمة (محمد) عند التمثيل في المرحلة الثانية، والرقم (٠) لبقية الكلمات، وهكذا في بقية الكلمات في المرحلتين الأخيرتين.

جاء	محمد	إلى	المنزل
1	0	0	0
0	1	0	0
0	0	1	0
0	0	0	1

(١) العصيمي، عبدالرحمن. نمذجة الكلمة العربية: خوارزميات الذكاء الاصطناعي في تحليل الكلمة العربية لغوياً وتوزيعياً. في: خوارزميات الذكاء الاصطناعي في تحليل النص العربي، ٢٠١٩، الصفحات ٩٥-١٢٤.

لا جدوى من تعلّم الآلة لتمثيل المُدَوّنات اللُّغويّة الضّخمة بهذه الطّريقة، فلو افترضنا أن لدينا ١٠٠ ألف كلمة؛ فذلك سيحتاج إلى تمثيل الكلمة ١٠٠ ألف مرّة، مرّة برقم (1)، ٩٩,٩٩٩ مرّة برقم (0)، وفي ذلك تكلفةٌ حسابيّةٌ عاليةٌ، ناهيك عن عدم جدواها في تمثيل الكَلِمات ذات العلاقة الدلاليّة المتشابهة، وستكون هناك كلمات ليس لها علاقةٌ دلاليّةٌ بينها قد مُثلت بأرقامٍ متقاربةٍ فيما بينها.

جاءت فكرة حقيبة الكَلِمات (Bag of Words (BoW بسبب قصور الترميز بالرقم الواحد، وتُنشئ حقيبة الكلمات أرقاماً عدديّةً للكلمات في النصوص، وتكون هذه الأرقام حقيقيةً أو ثنائيّةً أو لوغاريتميّةً. وهي مهمّةٌ عندما نريد معالجة إثراء الكلمات، ثم جاءت فكرة مطوّرةٌ أكثر، تُعرف بتضمين الكَلِمات (Word Embedding) الذي يُحلّل التّابعات اللَّفْظيّة (النغراميات) في كلّ نصّ في المُدَوّنة، ويُعطي مضموناً عدديّاً لكلّ نغرام واحدٍ، وذلك باستخدام نموذج تدريبٍ تعرّف (pre-trained model)؛ ليكون لكلّ نصّ مُتّجهٌ (vector) يُستنبط من نتيجة التّضمينات التّجميعيّة لكلّ الكَلِمات.

سنعرّف في المبحث الأوّل إلى نموذج حقيبة الكَلِمات، وفي المبحث الثاني إلى نموذج تضمين الكَلِمات، ثم نستعرض تطبيقاتهما على نصوص مُدَوّنة القرآن الكريم.

المبحث الأوّل: حقيبة الكَلِمات

تفيدنا حقيبة الكَلِمات بإنشاء أرقام للكلمات في المُدَوّنة في كلّ مستندٍ أو نصّ، ويُعدّ هذا النموذج من أبسط نماذج المتّجهات. وتبسيط فكرة النموذج، ننظر إلى هذين المستنديين من النصوص:

المستند الأوّل: «الحمد لله رب العالمين».

المستند الثّاني: «وقل الحمد لله سيريكم آياته».

يعمل النموذج أولاً على إنشاء قاموس يتكوّن من تقيم عدد الكلمات على النحو الآتي: [1: "الحمد"، 2: "لله"، 3: "رب"، 4: "العالمين"، 5: "وقل"، 6: "سيريكم"، 7: "آياته"]، ولو كان في النصّ كلماتٌ وظيفيّةٌ مُستبعدةٌ مسبقاً في المعالجة القبلية للنصّ فلن تُضمّن في القاموس. ويحتوي هذا القاموس على سبع كلماتٍ، ولكلّ كلمةٍ رقمٌ م فهرس، ثم يعمل النموذج ثانياً على تمثيل المتّجهات لعدد مرّات ظهور الكلمات في كلّ المستندات، فتتمثّل على النحو الآتي:

المستند الأول: [2، 2، 1، 1، 0]

المستند الثاني: [1، 2، 2، 1، 1]

سنلاحظ أنّ كلمة (الحمد) وكلمة (لله) قد أُعطيتا القيمة (2)؛ لورودهما مرّتين في كلا المستنديّن. الأمر نفسه عندما نبني نموذج حقيبة كلماتٍ لآلاف المستندات أو النصوص. سنلاحظ -أيضاً- أنّ النموذج قد وُضِعَ للمستنديّن في مثالنا خمسة متّجهات، وقد وضع متّجهاً خامساً في المستند الأول بقيمة صفر، وذلك أسلوب عمل حقيبة الكلمات، فالكلمة التي تظهر في مستندٍ، ولا تظهر في الآخر؛ تُمثّل في الآخر بقيمة (0).


في أداة (أورانج) مقاييس نموذج حقيبة الكلمات؛ وهي: حساب تكرار الكلمة، وحساب تكرار النصّ، والضبط (Regularization). يعمل النموذج في حساب تكرار الكلمة على ثلاثة مناهج يختار المستخدم أحدها، وهي: (التكرار)؛ أي عدد تكرار الكلمة في النصّ، و(الثنائي Binary)؛ أي هل الكلمة موجودة في النصّ أم لا، و(الخطّي الفرعي Sublinear)؛ أي تحويل التكرارات إلى اللوغارثم. أما في حساب تكرار النصّ؛ فيعمل النموذج على ثلاثة مناهج أيضاً؛ الأول: لا شيء في حال أراد المستخدم عدم إجراء هذا التكرار، والثاني: تكرار المستند العكسي (inverse document frequency IDF)، والثالث: تكرار المستند العكسيّ المخفّف، الذي يعمل على استبعاد أيّ مستندٍ لا تظهر فيه الكلمة المحسوب تكرارها في المستندات الأخرى؛ من أجل استبعاد أيّ قيمة صفرية. أمّا في الضبط فيمكن للمستخدم

أن يختار (لا شيء None)، أو أن يختار (L1)؛ لمعايرة وتوحيد طول المتّجه (الرقم) إن كان بعيداً جداً عن مُتّجهٍ آخر، أو لمعايرته بعد استخراج المجموع التّربيعي للمُتّجهات.

بعد أن يُنشئ النّموذجُ حقيبة الكلمات؛ نستخدم أداة إثراء الكلمات (word enrichment) جاكارد وجيب التمام، وتُظهر هذه الأداة قائمة الكلمات بالقيم الاحتماليّة الأعلى دلالة (أي: الأقل قيمة عادة من 0.05) لمجموعة تُحدّد بوصفها عيّنة، وتُقارن مع المُدوّنَة كُلّها. تُشير القيمة الاحتماليّة الأقل عادةً من 0.05 إلى احتمال عالٍ بأنّ الكلمة ليست عشوائية في المُدوّنَة. تُظهر الأداة -أيضاً- معدل استكشاف الخطأ (False Discovery Rate FDR)، الذي يُفصح عن النّسبة المتوقّعة من التنبؤ الخطأ في قائمة القيم الاحتماليّة.


وفيما يلي تطبيق على مُدوّنَة القرآن الكريم باستخدام أداة تنقيب النصوص أورانج.

في الشّكل (٨٤) أسلوب ربط أدوات التّحليل، ففي أداة (مدونة Corpus) تُحمّل البيانات (الشكل ٨٠)، ثم تُربط معها الأدوات المتبقّية من المعالجة القبليّة، ثم حقيبة الكلمات، إلى بقيّة الأدوات التي تعرض النّتيجة، وتختبرها، وتقيسها.



شكل ٨٤ : مسار عمل ربط الأدوات لمعالجة البيانات وحقيبة الكلمات والاختبار والقياس والتمثيل

ثمّة حالاتٌ عديدةٌ في خيارِ حقيبةِ الكلماتِ (Bag of Words)، يُمكن الاختيارُ من بينها كما في الشَّكْل (٨٥)، وستُعرض هناك الحالة الأولى والحالة الثانية من تلك الحالات الاثنتي عشرة (الجدول ٢٩)؛ ليتَّضحَ عمل نموذجِ حقيبةِ الكلماتِ في بياناتٍ مُدَوَّنة القرآن الكريم (السُّورة ثم نصّ آيات السُّورة الكريمة).



شكل ٨٥ : نافذة أداة حقيبة الكلمات

جدول ٢٩ : حالات نموذج حقيبة الكلمات

تكرار الكلمة Term Frequency: العدد count، الثنائي binary، الخطي الجزئي sublinear تكرار المستند Document Frequency: لا شيء none، تكرار المستند العكسي IDF، تكرار المستند العكسي الخفيف التنظيم Regularization: لا شيء none، المستوى الأول (مجموع العناصر) L1، المستوى الثاني (الإقليدية) L2: Euclidean			
الحالة الأولى	الحالة الثانية	الحالة الثالثة	الحالة الرابعة
تكرار الكلمة: العدد تكرار المستند: لا شيء التنظيم: لا شيء	تكرار الكلمة: العدد تكرار المستند: تكرار المستند العكسي التنظيم: لا شيء	تكرار الكلمة: العدد تكرار المستند: تكرار المستند العكسي التنظيم: المستوى الأول	تكرار الكلمة: العدد تكرار المستند: تكرار المستند العكسي التنظيم: المستوى الثاني
الحالة الخامسة	الحالة السادسة	الحالة السابعة	الحالة الثامنة
تكرار الكلمة: الثنائي تكرار المستند: لا شيء التنظيم: لا شيء	تكرار الكلمة: الثنائي تكرار المستند: تكرار المستند العكسي التنظيم: لا شيء	تكرار الكلمة: الثنائي تكرار المستند: تكرار المستند العكسي التنظيم: المستوى الأول	تكرار الكلمة: الثنائي تكرار المستند: تكرار المستند العكسي التنظيم: المستوى الثاني
الحالة التاسعة	الحالة العاشرة	الحالة الحادية عشرة	الحالة الثانية عشرة
تكرار الكلمة: الخطي الجزئي تكرار المستند: لا شيء التنظيم: لا شيء	تكرار الكلمة: الخطي الجزئي تكرار المستند: تكرار المستند العكسي التنظيم: لا شيء	تكرار الكلمة: الخطي الجزئي تكرار المستند: تكرار المستند العكسي التنظيم: المستوى الأول	تكرار الكلمة: الخطي الجزئي تكرار المستند: تكرار المستند العكسي التنظيم: المستوى الثاني

يعمل نموذج حقيبة الكلمات وفق اختيار الحالة الأولى على ترقيم الكلمات ترقيمًا لا يفيد تعلّم الآلة إفادةً تتعلّق باللفظ والمعنى؛ كونها تعطي الكلمات قيم تكراراتها. والأدق هنا هو باستخدام الحالة الثمانية، التي بها يعمل النموذج على استخلاص قيمة تكرار الكلمة مع تكرار المستند العكسي (٧٨)، بدلاً من جعل تكرار المستند (لا شيء) كما في الشّكل (٨٦).

AS3 Topic	Title	Content	AS3 Numbered Section include page number
1	مقدمة	1	1
2	الهدف	2	2
3	الهدف	3	3
4	الهدف	4	4
5	الهدف	5	5
6	الهدف	6	6
7	الهدف	7	7
8	الهدف	8	8
9	الهدف	9	9
10	الهدف	10	10
11	الهدف	11	11
12	الهدف	12	12
13	الهدف	13	13
14	الهدف	14	14
15	الهدف	15	15
16	الهدف	16	16
17	الهدف	17	17
18	الهدف	18	18
19	الهدف	19	19
20	الهدف	20	20
21	الهدف	21	21
22	الهدف	22	22
23	الهدف	23	23
24	الهدف	24	24
25	الهدف	25	25
26	الهدف	26	26
27	الهدف	27	27
28	الهدف	28	28
29	الهدف	29	29
30	الهدف	30	30
31	الهدف	31	31
32	الهدف	32	32
33	الهدف	33	33
34	الهدف	34	34
35	الهدف	35	35
36	الهدف	36	36
37	الهدف	37	37
38	الهدف	38	38
39	الهدف	39	39
40	الهدف	40	40
41	الهدف	41	41
42	الهدف	42	42
43	الهدف	43	43
44	الهدف	44	44
45	الهدف	45	45

Data Source: Google				Title		Content	ATU Number
Index element includes		ATU Type	ATU Number	Title		Content	ATU Number
1	1	1	1	1	1	1	1
2	2	2	2	2	2	2	2
3	3	3	3	3	3	3	3
4	4	4	4	4	4	4	4
5	5	5	5	5	5	5	5
6	6	6	6	6	6	6	6
7	7	7	7	7	7	7	7
8	8	8	8	8	8	8	8
9	9	9	9	9	9	9	9
10	10	10	10	10	10	10	10
11	11	11	11	11	11	11	11
12	12	12	12	12	12	12	12
13	13	13	13	13	13	13	13
14	14	14	14	14	14	14	14
15	15	15	15	15	15	15	15
16	16	16	16	16	16	16	16
17	17	17	17	17	17	17	17
18	18	18	18	18	18	18	18
19	19	19	19	19	19	19	19
20	20	20	20	20	20	20	20
21	21	21	21	21	21	21	21
22	22	22	22	22	22	22	22
23	23	23	23	23	23	23	23
24	24	24	24	24	24	24	24
25	25	25	25	25	25	25	25
26	26	26	26	26	26	26	26
27	27	27	27	27	27	27	27
28	28	28	28	28	28	28	28
29	29	29	29	29	29	29	29
30	30	30	30	30	30	30	30
31	31	31	31	31	31	31	31
32	32	32	32	32	32	32	32
33	33	33	33	33	33	33	33
34	34	34	34	34	34	34	34
35	35	35	35	35	35	35	35
36	36	36	36	36	36	36	36
37	37	37	37	37	37	37	37
38	38	38	38	38	38	38	38
39	39	39	39	39	39	39	39
40	40	40	40	40	40	40	40
41	41	41	41	41	41	41	41
42	42	42	42	42	42	42	42
43	43	43	43	43	43	43	43
44	44	44	44	44	44	44	44
45	45	45	45	45	45	45	45
46	46	46	46	46	46	46	46
47	47	47	47	47	47	47	47
48	48	48	48	48	48	48	48
49	49	49	49	49	49	49	49
50	50	50	50	50	50	50	50
51	51	51	51	51	51	51	51
52	52	52	52	52	52	52	52
53	53	53	53	53	53	53	53
54	54	54	54	54	54	54	54
55	55	55	55	55	55	55	55
56	56	56	56	56	56	56	56
57	57	57	57	57	57	57	57
58	58	58	58	58	58	58	58
59	59	59	59	59	59	59	59
60	60	60	60	60	60	60	60
61	61	61	61	61	61	61	61
62	62	62	62	62	62	62	62
63	63	63	63	63	63	63	63
64	64	64	64	64	64	64	64
65	65	65	65	65	65	65	65
66	66	66	66	66	66	66	66
67	67	67	67	67	67	67	67
68	68	68	68	68	68	68	68
69	69	69	69	69	69	69	69
70	70	70	70	70	70	70	70
71	71	71	71	71	71	71	71
72	72	72	72	72	72	72	72
73	73	73	73	73	73	73	73
74	74	74	74	74	74	74	74
75	75	75	75	75	75	75	75
76	76	76	76	76	76	76	76
77	77	77	77	77	77	77	77
78	78	78	78	78	78	78	78
79	79	79	79	79	79	79	79
80	80	80	80	80	80	80	80
81	81	81	81	81	81	81	81
82	82	82	82	82	82	82	82
83	83	83	83	83	83	83	83
84	84	84	84	84	84	84	84
85	85	85	85	85	85	85	85
86	86	86	86	86	86	86	86
87	87	87	87	87	87	87	87
88	88	88	88	88	88	88	88
89	89	89	89	89	89	89	89
90	90	90	90	90	90	90	90
91	91	91	91	91	91	91	91
92	92	92	92	92	92	92	92
93	93	93	93	93	93	93	93
94	94	94	94	94	94	94	94
95	95	95	95	95	95	95	95
96	96	96	96	96	96	96	96
97	97	97	97	97	97	97	97
98	98	98	98	98	98	98	98
99	99	99	99	99	99	99	99
100	100	100	100	100	100	100	100

شكل ٨٧ : تكرار الكلمات (count)؛ تكرار المستند (تكرار المستند العكسي (IDF

يعمل نموذجُ حقيبة الكَلِمَات المعتمد على معادلة تكرار الكلمة وتكرار المستند العكسيّ على محاولة تقريبِ الكَلِمَات ذات الدَلالة المتشابهة، وهذه المحاولة تُعدُّ مرحلةً أوَّليَّةً شبه جيّدة في تعلم الآلة الكَلِمَات في النُّصوص، قبل تصميم نموذج حقيبة الكَلِمَات المستمِرة (continuous bag of words CBOW)، (المبحث الثَّاني: تضمين الكَلِمَات) الذي يُعدّ أفضل. لننظر إلى أسلوب النّموذج في محاولة تقريبِ الكَلِمَات في مثال كلمة (سنة) وكلمة (عام).

المستند الأوّل: "وبلغ أربعين سنة"

المستند الثَّاني: "ثم يأتي من بعد ذلك عام فيه يُغاثُ الناس"

عند النّظر إلى القيمة التي أُعطيت لكلمة (سنة) وكلمة (عام) نجدها متقاربةً فيما بينهما.

السياق	رقم السُورة	السورة	القيمة
وبلغ أربعين سنة قال رب أوزعني أن أشكر نعمتك التي أنعمت علي وعلى والدي	46.txt	الأحقاف	2.9714
ثم يأتي من بعد ذلك عام فيه يغاث الناس وفيه يعصرون	12.txt	يوسف	2.53897

أما نتائج تقييم الاختبار والقياس (Test and Score) لآلة المتّجه الداعمة (Support Vector Machine) لتكرار الكلمة وتكرار المستند العكسي (التدريب - الاختبار ٨٠-٢٠٪)؛ فهي على النّحو الآتي:

الصحة: 0.791؛ الدقة: 0.626؛ الاسترجاع: 0.791؛ مقياس -ف: 0.699

في أداة إثراء الكَلِمَات؛ سنلحظ في النّتيجة أنّ كلّ الكَلِمَات ذات دلالة إحصائية قويّة، وأقلّ من 0.01، ويستحيل أن تكون هناك مدوّنّة لغويّة بشريّة ذات إثراء في الكَلِمَات، وتكون كلّ كلمة فيها ذات دلالة إحصائية أقلّ من 0.01 (الشكل ٨٨).

Word	p-value	FDR
آت	0.0e+00	0.0e+00
آتانا	0.0e+00	0.0e+00
أووا	0.0e+00	0.0e+00
أويناهما	0.0e+00	0.0e+00
آيتين	0.0e+00	0.0e+00
أسجد	0.0e+00	0.0e+00
أبا الله	0.0e+00	0.0e+00
أبلغه	0.0e+00	0.0e+00
أبناؤكم	0.0e+00	0.0e+00
أنتهم	0.0e+00	0.0e+00
أتخشونهم	0.0e+00	0.0e+00
أترفناهم	0.0e+00	0.0e+00
أتصبرون	0.0e+00	0.0e+00
أتوك	0.0e+00	0.0e+00
أتيناهم	0.0e+00	0.0e+00
أناما	0.0e+00	0.0e+00
أجاج	0.0e+00	0.0e+00
أجدر	0.0e+00	0.0e+00
أجعلتم	0.0e+00	0.0e+00
أجلب	0.0e+00	0.0e+00
أخبارهم	0.0e+00	0.0e+00
أحسنتم	0.0e+00	0.0e+00
أحملكم	0.0e+00	0.0e+00
أخباركم	0.0e+00	0.0e+00
أخذتم	0.0e+00	0.0e+00
آخرتن	0.0e+00	0.0e+00

شكل ٨٨ : إثراء الكلمات

وعلى أيّ حال؛ فمشكلة نموذج حقيقة الكلمات تكمن في عدم تدقيق الآلة في الكلمات ذات الدلالة المتشابهة، ووفق المجال الدلالي الواحد (السمة الدلالة)، إذا كانت معتمدة على تكرار الكلمات وتكرار المستند العكسي، دون اعتبار للعبء التوارد (co-occurrences) بين الكلمات الأخرى، وهذا يصعب على نموذج حقيقة الكلمات، ولعالجة هذا العيب؛ ابتكر تضمين الكلمات الذي يعمل في مهمته الأساسية على تقريب أبعاد الكلمات المتشابهة

سياقياً وفق السّمات، وإبعاد تقريب الكَلِمات غير المتشابهة سياقياً، بناءً على السّمات أيضاً، وذلك على مجمل النّص، وبلعبة رَقْمِيَّة ذَكِيَّة من الآلة، تقوم على لعبة التّوارد المستمرّ للكلمات المتشابهة دلاليّاً بعد تقريب أبعادها، ثم تقوم على إبعاد هذا التّقريب لبعض الكَلِمات عندما يكون التّوارد معها غير مستمرّ. سنرى عملَ تضمين الكَلِمات وتضمين المستندات في المبحث الآتي، ويجب أن ندرك أنّ في تضمين الكَلِمات مشكلةً بسيطةً، تتعلق بالمشارك اللّفظي، وستُبين هذه المشكلة في مبحث تضمين الكَلِمات.

المبحث الثاني: تضمين الكَلِمات

يعملُ تضمينُ الكَلِمات على تحويلِ الكَلِمات المتباعدة في النّصوص إلى ناقلاتِ أرقام ذات مُتجهاتٍ متقاربةٍ من أجل تدريبِ سياقاتها، ويُستهدفُ من هذا التّحويل تصنيفُ التّشابه الدّلاليّ بين الكَلِمات، ويتميّزُ تضمينُ الكَلِمات بأنّ المتجهات تكونُ أقلَّ عدداً من الكَلِمات؛ لأنّ المتجهات تعكس متجهات أبعاد السّياقات في النّصوص. يُطبّق نماذج الكلمة إلى المتجه (word2vec) -جوجل- أو نموذج المتجه الكوفي (Global Vector (GloVe) -جامعة ستانفورد- بمكتبة جينسم (Gensim)، أو نموذج تمثيلات المشفر الثنائي الاتجاه من المحوّلّات (Bidirectional Encoder Representations from Transformers BERT) في تدريب البيانات اللّغويّة. وشكّل الأخير ثورةً هائلةً في فهم الآلة اللّغة بشكلٍ أعمق؛ لأن بيرت (BERT) نموذج عميق، تتعلّم منه الآلة على اتجاhein لسلسلة الحروف في النّصوص، وليس على اتجاهٍ واحد مثل النماذج السّابقة، وذلك بنمذجة اللّغة المقنّعة (Masked-Language Modeling)، وقد تطوّر نموذجُ بيرت بأسلوبٍ هندسيٍّ يفهمُ به تتابع الكَلِمات والعبارات، ويفهم هذا التتابع وسياقاته فهمًا ضمنيًّا معمّقًا؛ كونه يتعلّم بأسلوب إخفاء نسبةٍ من الكَلِمات في النّص؛ ليتنبأ باستعمالاتها السياقيّة. ظهرت نماذج اللّغة ذات متانةٍ آليّةٍ تعلّميّةٍ، عُرفت بمحوّلّات التّدريب التعرّفيّ التوليديّ (Generative Pre-trained Transformer GPT)، فظهرَ GPT-1 (تحسين فهم اللّغة بالتدريب التوليديّ)، وGPT-2 (نماذج متعددة التعلّم غير الموجّه)، وGPT-3 (نماذج اللّغة بالتعلّم الأقلّ).

هذه النماذج المطوّرة تعملُ على بلايين المقاييس من الطّبقات الخفيّة والعصبونات المحددة، كما تعملُ على ما يُسمى بالاستدلال (inference)- الذي به يُقارن أداء النماذج بعد كلّ مرة يُحسّن فيها الأداء مع النماذج السّابقة. هذه الطفرة لم تأخذ سنواتٍ طويلة، بل ظهرت في السنتين الأخيرتين فقط، وبشكلٍ سريعٍ ومتراكم، وبصورةٍ تُخبرنا بأنّ الذكاء الاصطناعيّ قد بدأ أوج التّطبيقات المتقدّمة، وبأنّ شكله بعد عشر سنواتٍ سيكون بصورةٍ ستجعل الآلة مثل الإنسان في فهم اللغة وإنتاجها سياقياً (وربما عاطفياً).

نعودُ إلى نموذج (الكلمة إلى متجه word2vec)، فميزته هي أنه يعمل على ما يُسمى بتوزين الكلمات (أي: إعطائها أوزانها)، وفقّ السمات (الميزات أو الخصائص features)، وتصل عدد السمات إلى ٣٠٠ أو ٤٠٠ أو ٥٠٠ للنصوص التي يبلغ حجمها ٥٠ ألف كلمة. وتتميّز هذه السماتُ بتحديد الكلمات ذات السّمة الدلاليّة المشتركة. لو حددنا للآلة عدداً معيّناً من السّمات؛ فإنّها في استخلاص كلّ سمةٍ تعتمد على لعبة التّوارد (co-occurrence)، التي تكشف الكلمات من حيث وضعها الدلالي النّصي. لاحظ أن السمة تُحدّد بالأرقام، فالآلة لن تعتبر سمات كلمة (الرجل): [+ذكر] و- [أنثى] و[+بالغ]، بل بقيمة رقمية تكشف المعاني الضمنية لها. لنفترض هذا المثال: (أنجبت الأميرة ابنة الملك ابناً). ستتحول هذه الكلمات إلى مُتجهات، كلّ متجهٍ يتضمّن شعاعاً رقمياً، وتكون القيم الرّقميّة للسّمة الواحدة متطابقةً أو متقاربةً جداً، وفي المصفوفة الآتية توضيحٌ لهذه النّقطة.


السمات	ابنا	الملك	ابنة	الأميرة	أنجبت
ذكر	0.99	0.99	0.01	0.01	0.01
أنثى	0.01	0.01	0.99	0.99	0.90
العمر	0.20	0.90	0.70	0.70	0.060

تعمل نماذج (الكلمة إلى متجه word2vec) لتعلّم تضمين الكلمات على نموذجين أساسيين. الأوّل: تخطي الكلمة (Skip-Gram Model)، والثّاني: نموذج حقيبة الكلمات


المستمرة (Continuous BOW). والفرق بين هذين النموذجين هو أنّ الأول يتنبأ بالسياق من خلال الكلمة، والثاني يتنبأ بالكلمة من خلال السياق، ويتحدّد سياق الكلمة بالكلمة الواردة معها في نافذة التّصاحب، سواءً كان على مدى كلمة متصاحبة واحدة أو أكثر، وتتحدّد الكلمة بكلمة السياق الواردة معها. لو افترضنا كلمة (أنجبت) فكلّما كان السياق لها تتحدّد بالشّعاع الرّقميّ الأعلى، وتكون عندئذ (الأميرة) و(ابنة).

تمثّلت مشكلة في نماذج (الكلمة إلى متجه word2vec) عند التعامل مع الكلمة الغنيّة بالتّصريف وبالاشرّاك اللفظي، وعليه طوّرت شركة فيسبوك نموذج (FastText)؛ لمحاولة معالجة مشكلة التّشابه اللفظي، ثم طوّرت شبكات الذاكرة القصيرة-الطويلة المدى (Long Short-Term Memory (LSTM))، وكلاهما ليسا مدمجين في أدوات أورنج، علماً بأنّ هذه الأداة قد تدمج بعض النماذج التي تصل إلى المرحلة الأخيرة من التطوير في كلّ مرحلة مستقبلية.

وفيما يلي تطبيق على مُدوّنّة القرآن الكريم باستعمال تضمين المستندات في أداة تنقيب النصوص (أورنج). ويتّضح مسار العمل كما في الشّكل (٨٩)، فتحمل البيانات (الشكل ٨٠) في أداة المُدوّنّة (Corpus) أوّلاً.



شكل ٨٩ مسار العمل لتضمين المستندات



شكل ٩٠: اختيار اللغة وأسلوب الجامع Aggregator لتضمين المستندات

عدد المخرجات: المتوسط mean، والمجموع sum، والأكبر max، والأقل min

mean

يُمكن اختيار الحساب بالمتوسط (mean)، أو بالمجموع (sum)، أو بالأعلى (max)، أو بالأقل (min) من أداة تضمين المستندات (Document Embedding) كما في الشكل (٩٠). يُصنّف تضمين المستند كـ سورة إلى مستند، ثم يُضمّن كلّ كلمة (n-gram) باستخدام نموذج التضمين المدرب والمختبر مسبقاً وفق اللغة، وللغة العربيّة نموذج تم اختبارُه مسبقاً، ثم يتضمّن كلّ مستند على متجهٍ واحدٍ بعدَ تجميعِ كلّ تضمينات الكلمات فيه، وذلك باستخدام المجمع القائم على المتوسط، أو المجموع، أو الأعلى، أو الأقل. في الشكل (٩١) عرضٌ لنتيجة استخلاص تضمين المستندات. يتضمّن الشكل (٩١) تضمين المستندات على ٣٠٠ بُعد، وبمعامل التجميع aggregator القائم على المتوسط (mean). تعلّمت الآلة تضمين نصوص (مستندات) آياتِ سور القرآن بأسلوبِ التعلّم العميق، وبنموذج المستند إلى متجهة (doc2vec)، وعمّمت الآلة هذا التضمين لكل مستند بناءً على الكلمات ومتجهاتها، لكن ماذا عن الكلمة إلى متجه (word2vec) في داخل كلّ مستند؟ سأجري تطبيقاً للكلمة (الهدى) وفق نتيجة حقبة الكلمات المستمرة (CBOW)؛ كونها أحد نماذج تضمين الكلمات.

[illegible]

شكل ٩١: نتيجة تضمين المستندات

جاءت كلمة (هدى) وكلمة (الهدى) في القرآن الكريم بمعانٍ عديدة؛ وهي: الإيمان، والطريق، والكتاب المنزل، ومن أمثلتها من الآيات الكريمة ما يأتي:

قوله تعالى ﴿قُلْ أَدْعُوا مِنْ دُونِ اللَّهِ مَا لَا يَنْفَعُنَا وَلَا يَضُرُّنَا وَنُرَدُّ عَلَىٰ أَعْقَابِنَا بَعْدَ إِذْ هَدَيْنَا اللَّهَ كَالَّذِي اسْتَهْوَتْهُ الشَّيَاطِينُ فِي الْأَرْضِ حَيْرَانٌ لَهُ أَصْحَابٌ يَدْعُونَهُ إِلَى الْهُدَىٰ أَتَيْنَا قُلْ إِنَّ هُدَى اللَّهِ هُوَ الْهُدَىٰ وَأُمِّرْنَا لِلْإِسْلَامِ لِرَبِّ الْعَالَمِينَ﴾ [الأنعام: ٧١]. المعنى: الإيمان.

قوله تعالى: ﴿إِذْ رَأَىٰ نَارًا فَقَالَ لِأَهْلِهِ امْكُثُوا إِنِّي آنَسْتُ نَارًا لَّعَلِّي آتِيكُمْ مِنْهَا بِقَبَسٍ أَوْ أَجْدُ عَلَى النَّارِ هُدًى﴾ [طه: ١٠]. المعنى: الطريق.

قوله تعالى: ﴿إِذْ رَأَىٰ نَارًا فَقَالَ لِأَهْلِهِ امْكُثُوا إِنِّي آنَسْتُ نَارًا لَّعَلِّي آتِيكُمْ مِنْهَا بِقَبَسٍ أَوْ أَجْدُ عَلَى النَّارِ هُدًى﴾ [السجدة: ٢٦]. المعنى: البيان والوضوح.

قوله تعالى: ﴿وَلَقَدْ آتَيْنَا مُوسَى الْهُدَىٰ وَأَوْرَثْنَا بَنِي إِسْرَءِيلَ الْكِتَابَ﴾ [غافر: ٥٣]. المعنى: الكتاب المنزل.

عندما دققت النظر في عمل نموذج حقيبة الكلمات المستمرة، والمتجهات التي مثلتها كلمة (هدى) و(الهدى) من سورة الأنعام وطه والسجدة وغافر؛ ظهر أن بين تلك المتجهات مطابقة، وفقاً للمعنى في السورة الواحدة، وتقارباً وفقاً للمعنى بين هذه السور. وفيما يلي عرض كامل لنتائج نموذج حقيبة الكلمات المستمرة لهذه الكلمات في تلك السور.

المعنى = المتجه vectors	الآية	السورة	رقم السُورَة	سياق الكلمة
الهدى (الإيمان) = ٥,٧٠٨٩٦ هدى (الطريق) = ٣,١٢٦٧٦ هدى* (الكتاب، الفرقان) = ٩,٣٤٨٨٧	٣٥	الأنعام	6.txt	لو شاء الله لجمعهم على الهدى فلا تكونن من الجاهلين
	٧١	الأنعام	6.txt	قل إن هدى الله هو الهدى وأمرنا لنسلم لرب العالمين
	٧١	الأنعام	6.txt	قل إن هدى الله هو الهدى وأمرنا لنسلم لرب العالمين
	٨٨	الأنعام	6.txt	ذلك هدى الله يهدي به من يشاء
	٩٠	الأنعام	6.txt	أولئك الذين هدى الله فبهداهم اقتده
	٩١	الأنعام	6.txt	جاء به موسى نورا وهدى* للناس
	١٥٤	الأنعام	6.txt	وتفصيلاً لكل شيء وهدى* ورحمة لعلهم بلقاء ربهم يؤمنون
	١٥٧	الأنعام	6.txt	جاءكم بينة من ربكم وهدى* ورحمة
	١١	طه	20.txt	أو أجد على النار هدى
الهدى (الكتاب) = ١,٩٠٢٩٩ هدى (الرشاد) = ٧,٧٩٠٧٢	٤٧	طه	20.txt	والسلام على من اتبع الهدى
	٥١	طه	20.txt	أعطى كُلَّ شيء خلقه ثم هدى
	٨٠	طه	20.txt	وأضل فرعون قومه وما هدى
	١٢٢	طه	20.txt	اجتباه ربه فتاب عليه وهدى
	١٢٣	طه	20.txt	فإما يأتينكم مني هدى فمن اتبع هداي فلا يضل ولا يشقى
يهد (الهداية) = ٢,٧٩٠٢٩	٢٦	السَّجْدَة	32.txt	أولم يهد لهم كم أهلكنا قبلهم من القرون
الهدى (الكتاب) = ١,٩٠٢٩٩	٥٣	غافر	40.txt	ولقد آتينا موسى الهدى
هدى (الهداية) = ١,٥٥٨١٤	٥٤	غافر	40.txt	هدى وذكرى لأولي الألباب

الفصل الثالث


استخراج الموضوعات والكلمات المفتاحيّة

المبحث الأوّل: نمذجة الموضوعات

في أداة نمذجة أو استخراج الموضوعات في أداة (أورانج) ثلاث خوارزميّات مستخدمة لإجراء عملية الاستخراج؛ وهي: الفهرسة الدلالية الكامنة (Latent Semantic Indexing)، وتخصيص دركليه الكامن (Latent Dirichlet Allocation)، ومعالجة دركليه الهرميّة (Hierarchical Dirichlet Process).

وفيما يأتي تطبيقٌ على مُدَوَّنَةِ القرآن الكريم باستخدام أداة تنقيب النصوص (أورانج). يُشير الشّكل (٩٢) إلى مسار عمل المعالجة لاستخراج الموضوعات، ويبدأ بتحميل البيانات (الشكل ٨٠) في أداة المُدَوَّنَةِ (Corpus)، ويحتوي الملف على ٣٠ سطراً، وفي كلّ سطر نصّ يُمثّل سورة قرآنيّة كاملة^(١). تضمّن الشّكل (٩٣) ٣٠ موضوعاً استُخرج بنموذج الفهرسة الدلاليّة الكامنة مع عشر كلمات ذات علاقة بكلّ موضوع، واحتوى الشّكل (٩٤) على ٣٠ موضوعاً استُخرج بنموذج تخصّيص دركليه الكامن مع عشر كلمات ذات علاقة بكلّ موضوع. واشتمل الشّكل (٩٥) على ٣٠ موضوعاً استُخرج بنموذج معالجة دركليه الهرميّة مع عشر كلمات ذات علاقة بكلّ موضوع.

(١) لو اُبتغيَتْ تمثيل موضوعات القرآن بدقّة؛ فالأجدر أن يكون كلّ نصّ واحد عبارة عن آية واحدة، وليس سورة كاملة، وتُستخرج الموضوعات على ثلاث مراحل؛ الأولى: استخراج كلّ الموضوعات من كلّ السُّور. والثانية: استخراج كلّ الموضوعات من كلّ سورة واحدة. والثالثة: استخراج الموضوعات من كلّ السُّور المكيّة، وتلك الموضوعات من كلّ السُّور المدنيّة.



شكل ٩٢ مسار عمل استخراج الموضوعات وتمثيلها

أذكرُ هنا أنَّ عدد الموضوعات يتحدَّد بحسب رغبة المحلِّل، غير أن هناك طريقةً أفضل لتحديد العدد الأمثل، غير متوفرة في أداة أورانج، ويمكن الاطلاع عليها في مصدر آخر^(١).

كيف يُمكن استنتاج الموضوعات الثلاثين من كل نموذجٍ من النماذج الثلاثة؟ يُعرف ذلك عن طريق منهجين؛ الأول: أن يُعرف موضوع النّص العام، فالنّص القرآني له موضوعات قد جُمعت في المراجع والمصنّفات التّفسيرية، فمعرفة الموضوعات المتّوعة وأيهما أكثر وأيهما أقلّ سيكون معيّنًا على تحديد موضوع كلّ رقمٍ وفق الكلّيات ذات الارتباط الموضوعي به. والثاني: أن يُعتمد على تحديد الموضوعات لكلّ رقمٍ من ١ إلى ٣٠ وفق الكلّيات الواردة في كلّ موضوع، وهذا يعتمدُ على تفسيرية المحلِّل البشري.

سأضربُ مثلاً مبسّطاً للمنهج الثاني لتوضيح النّقطة قبل أن ننظر في الموضوعات والكلّيات المستخرجة من النّص القرآني؛ لننظر إلى الموضوع الافتراضي (١) والموضوع الافتراضي (٢).

(١) الطلاب، الجامعة، الكلّية، القسم.

(٢) الأطفال، الرّوضة، الحضانة، التّمهيدي.

(١) المجيلول، سلطان. الفهرسة الدلالية الكامنة وتخصيص دركليه الكامن لنمذجة موضوعات الشعر العربيّ عبر العصور، ٨٠-٥٧.

سيتعيّن أن يكون الموضوعُ الأوّل متعلّقاً بالدراسة الجامعيّة، وأن يتعلّق الموضوع الثاني بدراسة الأطفال. وقد يُخطئ نموذج من نماذج الموضوع الآليّة، فيضيف كلمةً للموضوع (١)، تكون بعيدةً نوعاً ما عن الحقل الموضوعي العامّ، فيضيف -على سبيل المثال- كلمة (القطار). وقد تكون كلمة (قطار) غير بعيدةٍ بحسب السّياق النّصّي الواردة فيه مع الكليّات الأخرى، فتكون مرتبطةً موضوعياً بالكليّات الواردة في الموضوع (١)؛ بسبب ارتباطها جميعاً -مثلاً- بسياق ذهاب الطّلاب إلى الأقسام أو الكليّات بالقطار في كلّ صباح ومساءً. تتطوّر نماذج الآلة لاستخراج الموضوعات في كلّ مرحلة زمنيّة لاحقة، وهي تكشف الارتباط الموضوعيّ بين الكليّات بأساليب آليّة مختلفة، ومن أدقّها حتى الآن هو أسلوب (الكلمة إلى متجه word2vec).

Latent Semantic Indexing الفهرسة الدلالية الكامنة

عدد الموضوعات : ٣٠

- 1: الأرض، آمنوا، الكتاب، الناس، شيء، كفروا، بالله، أنزل، لله، خير
- 2: الأرض، آمنوا، بالله، موسى، قوم، فلما، رسوله، ريكم، الكتاب، فرعون
- 3: بالله، قوم، رسوله، عظيما، المؤمنين، عليما، سبيلا، كفى، رحيمًا، خير
- 4: تكذبان، فبأي، ريكما، آلاء، إنس، فاكهة، جان، الميزان، خلق، قوم
- 5: موسى، رسوله، كفروا، عذاب، الناس، قلوبهم، النساء، خير، عظيما، عليما
- 6: رسوله، قوم، الكتاب، موسى، شيء، السماوات، لله، آمنوا، الأرض، قلوبهم
- 7: الكتاب، رسوله، أهل، آمنوا، مريم، موسى، اتقوا، عليم، ربنا، قوم
- 8: آمنوا، الأرض، أنزل، الكتاب، المؤمنين، اتقوا، ربنا، ابن، خير، قالت
- 9: شيء، الأرض، الناس، كذبوا، أنزل، القوم، يؤمنون، الآيات، الكتاب، حرم
- 10: يوسف، فلما، أبانا، أخيه، السجن، نفسه، قالت، الملك، المحسنين، الناس
- 11: قوم، موسى، عذاب، ظلموا، جعلنا، رسوله، أمر، نوح، ربهم، الناس
- 12: العالمين، مؤمنين، الرحيم، لهو، أكثرهم، لآية، أطيعون، فاتقوا، المرسلين، العزيز
- 13: قوم، لقوم، الأرض، جعلنا، جاء، ربهم، للذين، يشاء، لله، شيء
- 14: موسى، جعلنا، فرعون، الحق، الناس، الدنيا، جهنم، الرحمن، الحياة، سبيلا
- 15: كفروا، القيامة، الحق، إله، أمة، لقوم، موسى، الناس، آمنوا، النبي

- 16: النبي، كفروا، القرآن، قليلاً، كبيراً، ربه، أحداً، جاء، خير، وكيلاً
- 17: النبي، شيء، الناس، المؤمنين، بيوت، ملكت، يعلم، أعد، سبيل، حرج
- 18: كفروا، الرحمن، أحداً، البحر، فهم، ريكهم، أرسلنا، مبین، إله، بينهم
- 19: النبي، عليم، بيوت، يشاء، الناس، عذاب، العذاب، الرسول، المؤمنين، موسى
- 20: كفروا، الرحمن، ريكهم، شيء، الكتاب، موسى، أفلا، بيوت، فرعون، سبيل
- 21: الرحمن، كفروا، شيئاً، الجن، فلما، نبيا، ذكر، قبلهم، صالحاً، استضعفوا
- 22: الناس، يشاء، السماوات، العزيز، الكتاب، أمة، النار، العذاب، خير، الأرض
- 23: عذاب، الأرض، الرحمن، آمنوا، النار، آياتنا، فهم، آيات، العذاب، مكان
- 24: الناس، بالحق، جميعاً، أفلا، قالت، الحق، عليم، عباد، بينهم، كفروا
- 25: الرحمن، نبيا، شيئاً، للذين، الأرض، يقول، اذكر، فلما، فرعون، أفلا
- 26: يشاء، أمن، سليمان، فهم، لله، الظالمين، إله، يومئذ، القرآن، تسمع
- 27: الجحيم، كفروا، الآخرين، أكثرهم، أرسلنا، المخلصين، ذكر، يومئذ، يعلم، المحسنين
- 28: القيامة، النار، بالله، بالبينات، المحسنين، قوم، عباد، يقولون، اليوم، أليس
- 29: يشاء، آياته، يومئذ، النار، لآيات، ذكر، آمنوا، الليل، العذاب، ريكهم
- 30: الآخرين، الجحيم، نجزي، المحسنين، المخلصين، لله، المرسلين، يعلم، ألم، تركنا

شكل ٩٣: نتائج الموضوعات باستخدام الفهرسة الدلالية الكامنة

في الموضوعات المستخرجة من الفهرسة الدلالية الكامنة (الشكل ٩٣)؛ سنلاحظ أنَّ هناك موضوعاتٍ متكررةً تتمحور حول قصّة النبيّ موسى مع فرعون، كما في الموضوع (2) و(14) و(20) و(25)، وحول أحوال النبيّ موسى في الموضوع (2) و(5) و(6) و(7) و(11) و(14) و(15) و(19) و(20). لودققنا النّظر في كلّ موضوعٍ من غير هذه الموضوعات؛ لألفينا ارتباطاً كثيراً من كلماتها بموضوع واحدٍ.

لا تُستعمل هذه الخوارزمية لعدم دقّتها، فمن قام بتطويرها (راديم زاهوزيك Radim Řehůřek)؛ قد أكّد على هذه النقطة^(١)، إذ ستُظهر كلمات لا يمكن تفسير

(1) Retrieved October 24, 2022, from <https://orange3-text.readthedocs.io/en/latest/widgets/topicmodelling-widget.html>

موضوعاتها؛ بسبب عمل هذه الخوارزمية التي تلغي دقة التماسك في تحديد الموضوعات، وقد ثبت ذلك من تحليلات تطبيقية، ومنها فيما يخص التحليل التطبيقي على النصوص العربيّة، الذي أجري على بيانات القصائد العربيّة على مرّ العصور^(١).

إذن؛ تُستخدم مباشرةً إما الخوارزمية الثّانية أو الثّالثة. تعمل خوارزمية تخصيص دركليه الكامن على تخصيص النصوص الأقرب اتّجاهاً (الأقرب وزناً) للكلمات بين النصوص. أما معالجة دركليه الهرمية فهي منهج بايزي (تصنيفي) غيرمقياسي، ويعمل بأسلوب التّجميع. سيُلاحظ أنّ معالجة دركليه الهرمية أفضل من تخصيص دركليه الكامن في نتائج الموضوعات المستخرجة من مجلدات مدوّنة القرآن الكريم.

Latent Dirichlet Allocation تخصيص دركليه الكامن

عدد الموضوعات: ٣٠

عدد الكلمات في جميع الموضوعات من غير تكرار: ١٤٥ كلمة من مجموع ٣٠٠ كلمة

- 1: الأرض، جعلنا، أحداً، شيء، السماء، ربه، بالحق، دونه، رحمة، كفروا
- 2: موسى، فرعون، فلما، الأرض، إله، جاء، القيامة، الدنيا، خير، أوتي
- 3: الأرض، آمنوا، بالله، السماوات، عذاب، الكتاب، ربهم، العظيم، كثير، فاسقون
- 4: آلاء، فبأي، ريكما، تكذبان، الأرض، آمنوا، كفروا، أعمالهم، فلما، السماوات
- 5: ربنا، تطع، ربه، فضة، يوماً، فهم، يعلمون، يدعون، تحكمون، مصبحين
- 6: الأرض، موسى، شيء، فلما، ربنا، إله، فرعون، خير، أمة، للذين
- 7: الأرض، أصحاب، كفروا، إله، العظيم، يعلم، أفلا، أنفسهم، إنكم، خير
- 8: الأرض، آمنوا، شيء، كفروا، الكتاب، الدنيا، الناس، النار، آمناء، الآخرة
- 9: الكتاب، الأرض، الناس، السماوات، كفروا، آمنوا، عذاب، الدنيا، ربنا، النار
- 10: لهب، البلاد، فيقول، دكا، صفا، ابتلاه، يومئذ، الإنسان، الأرض، عذاب
- 11: الأرض، آمنوا، ربهم، النبي، الكتاب، خير، يقولون، الناس، النار، تعملون
- 12: نذير، خلق، الرحمن، البصر، أمن، السماء، السعير، شيء، عذاب، الأرض

(١) المجلول، سلطان. الفهرسة الدلالية الكامنة وتخصيص دركليه الكامن لنمذجة موضوعات الشعر

العربيّ عبر العصور. مجلة اللسانيات العربيّة، العدد ١٤، ٢٠٢٢، الصفحات ٥٧-٨٠.

- 13: الأرض، ذكر، يعلم، مبين، آلهة، إله، جعلنا، إنكم، السماء، إبراهيم
- 14: خلق، ربه، السماء، كذب، اسم، ماله، فسنيسر، كيدا، الطارق، الأعلى
- 15: يومئذ، واحدة، رسول، الأرض، الحاقة، بقول، كريم، صيحة، اليوم، الجبال
- 16: الأرض، الإنسان، يشاء، السماوات، القرآن، يومئذ، جعلنا، القيامة، الآخرة، كبيراً
- 17: العالمين، موسى، قوم، فرعون، الأرض، العزيز، رسول، مؤمنين، أطيعون، فاتقوا
- 18: الأرض، السماء، الجبال، جعلنا، عذاب، شيء، السماوات، يقولون، ربه، الجحيم
- 19: شيء، الأرض، السماوات، لله، عليم، يشاء، بيوت، ربهم، عذاب، الكتاب
- 20: آمنوا، الأرض، بالله، الناس، الكتاب، أنزل، كفروا، شيء، لله، ربكم
- 21: الناس، سبيلاً، الأرض، جعلنا، نذيراً، ربنا، السماوات، ملك، السماء، يقولون
- 22: الأرض، موسى، الكتاب، الرحمن، السماوات، هدى، ربه، أهل، آمنوا، كفروا
- 23: عذابي، مدكر، نذر، الأرض، كذبت، القرآن، قوم، شيء، أمر، يسرنا
- 24: تعلمون، ألم، اليقين، يجعل، تر، يومئذ، سجيل، الجحيم، أرسل، النعيم
- 25: الأرض، كتاب، يومئذ، آمنوا، النار، داوود، مأب، أواب، اذكر، الناس
- 26: الأرض، قوم، الناس، عذاب، السماوات، كفروا، آمنوا، ربهم، أمر، جاء
- 27: الأرض، آمنوا، شيء، كفروا، عذاب، عليم، السماوات، الناس، لله، الحق
- 28: يوسف، فلما، الأرض، الناس، خير، أبانا، الملك، نفسه، السجن، أخيه
- 29: يومئذ، المؤمنين، ويل، للمكذبين، الأرض، الآخرين، رسوله، السماء، مبين، المحسنين
- 30: النبي، المؤمنين، رسوله، آمنوا، شيء، أعد، بالله، رحيماً، غفوراً، المنافقين

شكل ٩٤: نتائج الموضوعات باستخدام تخصيص دركليه الكامن

في الشَّكْل (٩٤) الموضوعاتُ المستخرجةُ باستخدام نموذج تخصيص دركليه الكامن، وهو أقل تكراراً للموضوعات من النموذج السابق. لنكتفي بالنظر إلى عدد تكرارات قِصَّة النَّبِيِّ موسى، بواقع أربع مرات، كما في الموضوع (2) و(6) و(17) و(22)، وقِصَّة النَّبِيِّ موسى مع فرعون، بواقع ثلاث مرات، كما في الموضوع (2) و(6) و(17). لتفسير بrique الموضوعات وفق إطار ما يُسمى بقبالية التفسير الإنساني (human-interpretability)؛ فإني أرى أنَّ علماء التفسير بالقرآن الكريم هم من سيجيدون كشف ارتباط الكلمات من عدم ارتباطها بكل موضوع من الناحية الدلالية كما رأها هذا النموذج. على سبيل المثال؛ ما العلاقة

بين الكلمات في الموضوع (5): رَبَّنَا، تُطِيعُ، ربه، يوماً، فهم، يعلمون، يدعون، تحكمون، مصبحين؟ أمّا في نتيجة نموذج معالجة دركلييه الهرمية (الشكل ٩٥)، فنلاحظ تنوعاً أكثر في الموضوعات بفعل تنوع الكلمات ذات العلاقة بكل موضوع.

Hierarchical Dirichlet Process معالجة دركلييه الهرمية

First level concentration (γ): 1

Second level concentration (α): 1

The topic Dirichlet (α): 0.01

Top level truncation level (T): 30

Second level truncation level (K): 15

Learning rate (κ): 1

Slow down parameter (τ): 64

عدد الكلمات في جميع الموضوعات من غير تكرار: ٢٤٨ كلمة من مجموع ٣٠٠ كلمة

- 1: الأرض، آمنوا، الناس، الكتاب، خير، يشاء، السماوات، أنزل، يعلمون، النار
- 2: الأرض، موسى، الحق، آمنوا، عليم، كفروا، عذاب، الدنيا، الزيتون، خير
- 3: الأرض، موسى، ربكم، قوم، فلما، بآياتنا، قنوط، القرآن، ربنا، مستبصرين
- 4: شيء، الأرض، تخلفه، عذاب، أرجه، أنطقنا، العالمين، الفرع، لهو، يؤمنون
- 5: الأرض، يجادلون، يوسف، الناس، فلما، سقيم، أهل، الكتاب، آمنوا، حق
- 6: آمنوا، الكتاب، كفروا، الأرض، النار، شيء، عذاب، بالله، الحكيم، ربنا
- 7: الكتاب، بالله، الناس، آمنوا، الأرض، عليم، سيقول، ردوه، لتعلن، عظيما
- 8: الأرض، السماوات، خطيئته، الرحمن، الوسيلة، الكتاب، بدارا، قمرا، عذاب، نجعلهم
- 9: الأرض، تبصرون، أريناه، بالإيمان، بسكاري، أنثى، قارون، يغلب، المصلحين، صبروا
- 10: رسوله، روحا، نزعناها، تستفتيان، بالله، إخوانكم، آمنوا، تعددوا، لصاحبه، كفروا
- 11: الناس، مشيك، النبي، آمنوا، بأحسن، دفع، القلم، يلمزون، تشاءون، تجد
- 12: الأرض، السماوات، يشاء، أخذناهم، الرحيم، كفروا، أخيه، حصحص، تأثيما، مضغة
- 13: آمنوا، الأرض، أنزل، أحتاجوننا، آمننا، اتقوا، الأحلام، معيشتها، الكتاب، فتكونون
- 14: قوم، خافون، ليدبروا، تنتصران، عذاب، بأمر، افتريته، أقسموا، أخلق، فاتبعوا
- 15: بدأنا، تركبون، فاتبعوا، الشيطان، نجعلهم، مرية، مقمحون، يريكمهم، للذين، قست

- 16: استكثرتم، الوهاب، قوما، بمستيقنين، يأتيكما، يصدنك، حاسد، روجي، الأرض، أوتمن
- 17: بالبر، فلنأتينهم، القردة، مهيمنا، بكاف، نادينا، تلفح، ويل، الأرائك، الأرض
- 18: تشطط، ذرعا، أحطت، دخل، طغوا، بست، تستفتحوا، عيون، بأيدي، يأتكم
- 19: مترفيهم، محاريب، باسطو، البعث، أصحاب، يبطش، رحيق، يضره، منكرا، نجا
- 20: يعبدوها، موسى، ترجون، خشوعا، بساطا، آخرنا، الصخرة، يجتنبون، بعوضة، أعمالكم
- 21: مدرارا، يرتد، الإشراف، فرجها، ندلكم، الأرض، قربناه، صدقاتهن، يدخلونها، برأسي
- 22: فأوى، جثيا، معكوف، ليتمتعوا، أعناب، أتبعه، رواسي، صارمين، ليبيدي، يجاهد
- 23: صدقنا، يتجرعه، بشرر، بعولتهن، ذكره، ألقاها، إبليس، فثبتوا، فزده، يصروا
- 24: تكذبان، فبأي، ريكما، آلاء، هب، لإبراهيم، أسكنت، لكثير، تأتوني، تفعل
- 25: أضلنا، فضلوا، بالشهر، فسترضع، يعبا، ينشرون، مركوم، سئلت، فأخلفتم، رهينة
- 26: تعرف، يعصرون، بأنه، صم، الأنثى، متراكبا، فليأتنا، جهر، يسلبهم، عارض
- 27: بيوت، تستفتيان، أشكو، سنكتب، الأوفى، ينادون، أحصنت، اصطنعتك، مفسدون، مأتيا
- 28: صواف، خلقها، يورثها، حجورك، لعملكم، فئتكم، محبة، فحسبنا، يحار، يكشف
- 29: تذكيري، صلاته، لأسجد، يتنزل، لساحر، فاستقم، فتطردهم، يعصينك، سيبطله، نورهم
- 30: أطوارا، يتولونه، هديناهم، منكر، فاستأذنوك، مطاع، يتخذوا، أبانا، ليقولون، أيدتك

شكل ٩٥: نتائج الموضوعات باستخدام معالجة دركليه الهرمية

المبحث الثاني: الكَلِمَات المفتاحية

لا بدّ من التّمييز بين المصطلحات الآتية: المصطلحات، والكَلِمَات المفتاحية، والألفاظ الأكاديمية، والألفاظ الشّائعة. المصطلحات أكثر تمييزاً من الكَلِمَات المفتاحية، فهناك مصطلحات دقيقة جدّاً في حقليّ فرعّي من حقليّ واحدٍ من الحقول العلميّة لا تعدّ كلماتٍ مفتاحيّة، وهناك مصطلحات أقلّ دقّة تكون كلماتٍ مفتاحيّة في المجال العامّ. كذلك الحال بين الكَلِمَات المفتاحيّة والألفاظ الأكاديمية، وبين الألفاظ الأكاديمية والألفاظ الشّائعة، وما يُفرّق الألفاظ الأكاديمية عن الكَلِمَات المفتاحيّة هو تضمّنها للأفعال والصّفات والعبارات. إذن هناك منطقة ضبابيّة نوعاً ما، وصغيرة نسبياً، تتضمّن كلماتٍ تشترك بين ما ينضوي تحت مفهوم كلّ مصطلحٍ من هذه المصطلحات الأربعة. هناك

أساليب إحصائية دقيقة^(١)، تكشف الحدود المتميزة بين ما ينضوي تحت كل مصطلح من كلماتٍ وعباراتٍ، وبين ما يكون في تلك المنطقة الضبابية^(٢).

أُجريت دراسة على استخراج التباين المعجمي بين المعاجم العربية القديمة والمعاجم العربية المعاصرة^(٣)، ووفق منهج إحصائي تطبيقي. وفي المقابل، هناك عدد من الخوارزميات في تعلم الآلة، التي تعمل على استخراج الكلمات المرشحة موضوعياً، وال قابلة لأن تكون كلمة مميزة نصياً. هناك أداة (استخرج المصطلحات Extract keywords) في أداة أورانج، وقد دُمج فيها كل من أسلوب (تكرار الكلمة-تكرار المستند العكسي Term Frequency-Inverse Document Frequency TF-IDF)، وخوارزمية (مُستخرج الكلمة المفتاحية الآنية Yet Another Keyword Extractor YAKE)، وخوارزمية (الاستخراج الآلي السريع للكلمات المفتاحية Rapid Automatic Keyword Extraction RAKE). شُرح مسبقاً عمل خوارزمية (تكرار الكلمة-تكرار المستند العكسي) في المبحث الثاني (الإحصاءات) من الفصل الأول في هذا الباب.

تعمل خوارزمية (YAKE) على استعمال الإحصاءات؛ لفهم أكثر الكلمات صلةً بكل نص، ولا تصلح للنص العربي؛ كونها تعتمد على تكرار الكلمات المناطة بالأنظمة الكتابية للغات اللاتينية، فعند استخراج السمات (feature extraction)؛ يُفرق بين الكلمات وفق الاختصارات (acronyms)، ووفق الكلمات التي تبدأ بحروف كبيرة. أما خوارزمية الاستخراج الآلي السريع للكلمات المفتاحية (RAKE)؛ فتصلح للنصوص العربية، وتعمل على ترشيح الكلمة المميزة في النص عن طريق مقياس درجتها، الذي يُستخلص وفق نتيجة: (درجة الكلمة ÷ تكرار الكلمة). نعرف تكرار الكلمة، أما درجة الكلمة فتحدد بناءً على التتابع اللفظي أولاً، وفيما إن كانت درجة التتابع اللفظي ١،

(١) لمعرفة أفضل الممارسات حتى اليوم في كشف تلك الحدود؛ الاطلاع على هذه الدراسة: حوراء. الألفاظ الأكاديمية في المدونات العربية العلمية: دراسة حاسوبية تحليلية. (رسالة ماجستير) إشراف: د. سلطان المجبول. قسم اللغة العربية (جامعة الملك سعود)، ٢٠٢٢.

(2) Almujaivel, S. (2020). An Overview of the Lexical Variation Between Arabic Lexicons and Natural Arabic Language. International Journal of Arabic Linguistics, 6(1 & 2). 91107-.

أم ٢ إلى ٥ على الحدّ المعمول به في معظم المشاريع. لننظر إلى المثال الآتي، ثم نجري توزيعاً يوضح طريقة استخراج درجة الكلمة.

المستند الأول (على اعتباره نصّ): "الحمد لله رب العالمين"

المستند الثاني (على اعتباره نصّ): "[و] قل الحمد لله سيريكم آياته"

في هذا المثال نصّان خاليان من الكلمات الوظيفيّة ومن الفواصل، وفي حال وجودهما؛ فإنّ ذلك سيؤثّر، ولذلك يجب استبعادهما في المعالجة القبليّة للنصّ. استبعدنا حرف العطف (و)؛ لأنّ هذا النصّ مُقطّع. لو حدّدنا التّتابع اللَّفْظِيّ (النّغرام) ليكون (١) فقط؛ فستبدأ الخوارزمية بتحديد قيمة كلّ كلمة في جدولة مصفوفات، ثم تُعطي كل قيمة عدداً يمثّل عدد مرات التّجاوز، فإن كانت لا شيء؛ فذلك يعني أنّ الكلمة لم تكن سابقةً أو لاحقةً للكلمة المجاورة، وإن كانت (١) فذلك يعني مُجاورتها مرّة واحدة، وإن كانت (٢) فذلك يعني أنّ المجاورة بواقع مرّتين (الجدول ٣٠). وتزيد هذه القيم أو تنقص بحسب عدد حالات التقاطع المتّجاور بين صفيضة الكلمات عمودياً وأفقيّاً في المصفوفة. ويلاحظ بعد هذه الخطوة كما في الجدول (٣١)؛ أنّ المقياس الأعلى قد جاء لكلمة "الحمد"، و"الله"، ثم "قل"، و"سيريكم"، و"آياته"، ثم "رب"، ثم أخيراً "العالمين".


جدول ٣٠: تمثيل مصفوفة خوارزمية الاستخراج الآلي السّريع للكلمات المفتاحيّة

الحمد	له	رب	العالمين	قل	الحمد	له	سيريكم	آياته
الحمد	2	1	1		2	1		
له	1	1	1		1	2		
رب	1	2	1					
العالمين	1	1	1					
قل				2	1	1	1	
الحمد				1	2	1	1	
له				1	1	2	1	
سيريكم				1	1	1	2	
آياته				1	1	1	1	2

جدول ٣١ : مقياس درجات الكلمات مع التكرارات

الدرجة	الحمد	لله	رب	العالمين	قل	سيريكيم	آياته
التكرار	2	2	1	1	1	1	1
الدرجة ÷ التكرار	7.0	7.0	5.0	4.0	6.0	6.0	6.0

فيما يلي تطبيق على مُدَوَّنة القرآن الكريم باستخدام أداة تنقيب النصوص (أورانج).
البيانات التي حُمِلت في أداة المُدَوَّنة (Corpus) في الشَّكْل (٩٦) تتضمَّن ما عُرِض في
الشَّكْل (٧٩)، واستُخلِصت النَتائِج وعُرِضت في الشَّكْل (٩٧).



شكل ٩٦ : مسار عمل استخراج الكلمات المفتاحية

- 'أطعنا سادتنا وكبراءنا فأضلونا السبيلا' (23.5)
- 'وامراته قائمة فضحكت فبشرناها بإسحق' (23.0)
- 'آبائهم وذرياتهم وإخوانهم واجتبيناهم وهديناهم' (22.833333333333336)
- 'صلاقي ونسكي ومحياي ومماتي لله' (22.76923076923077)
- 'الفريقين كالأعمى والأصم والبصير والسميع' (22.733333333333333)
- 'استحقا إثما فأخران يقومان مقامهما' (22.714285714285715)
- 'يصدر الرعاء وأبونا شيخ كبير' (22.666666666666668)
- 'عروشها وبئر معطلة وقصر مشيد' (22.666666666666664)

- ('ثُلثي الليل ونصفه وثُلثه وطائفة' , 22.612244897959183)
('لـفـريـقا يـلوون أـلسـنـتـهـم بـالـكـتـاب لـتـحـسـبـوه' , 22.5)
('فـتـحـوا مـتـاعـهـم وـجـدوا بـضـاعـتـهـم رـدـت' , 22.5)
('السـاعـة ءـاتـيـة أكـاد أخـفـيـها لـتـجـزى' , 22.484848484848484)
('وـيـدـع الـإنـسـان بـالـشـر دـعـاءـه بـالـخـير' , 22.4)
('نـطـوي السـمـاء كـطـي السـجـل لـلـكـتـب' , 22.30392156862745)
('مـوعـدـهـم الصـبـح أـلـيس الصـبـح بـقـريـب' , 21.923076923076923)
('السـرـاء والـضـراء والـكـاظـمـين الغـيـظ والـعـافـين' , 20.933333333333334)
('قـريـب نـجـب دـعـوتـك وـتـتـبـع الرـسـل' , 19.964285714285715)
('تـأكـلوا الرـيـا أـضـعـافـا مـضـاعـفـة وـاتـقـوا' , 18.057234432234434)
('تـولـى وـنـصـله جـهـنـم وـسـاءـت مـصـيرـا' , 17.907986111111111)
('الـكـتـاب يـؤمـنـون بـالـجـبـت والـطـاغـوت وـيـقـولـون' , 16.981118373275237)
('أـتـاك حـديـث ضـيـف إـبـراـهـيـم المـكـرمـين' , 15.993333333333334)
('يـتـوكـل المـتـوكـلون' , 3.333333333333333)
('يـصـلـونـها' , 3.0)
('آمـنا' , 2.972972972972973)
('آبـائـهـن' , 1.0)

شكل ٩٧ : الكَلِمَات المفتاحِيَّة باستخدام خوارزمية الاستخراج الآلي السَّريع للكلمات المفتاحِيَّة

الفصل الرَّابِع

الأنماط النَّحْوِيَّة

لمفهوم النمط (pattern) في المعالجة الآليّة للغة العديد من الممارسات في تنقيب النصوص، ومعالجة اللغة الطّبيعيّة، وتعلّم الآلة. وهناك نوعان مهمّان في معالجة اللغة الطّبيعيّة؛ وهما: التّعبيرات النّمطيّة، والأنماط النّحويّة المعجميّة، يُعَيّن الأوّل على إجراء العديد من التّشذيب، والتّنظيف، والتّفريق، والاستبدال، وكشف الأنماط الخطيّة^(١) للنصوص العربيّة، ويُعَيّن الثّاني على فهم الأنماط النّحويّة العامّة للنصّ العربيّ مثل: [فعل+اسم]، و[موصوف+صفة]، و[اسم+فعل+مفعول به]، إلخ^(٢). لم تُدمج التّعبيرات النمطية كلها في أداة أورانج، إذ لم يُدمج فيها إلا تنميط الكلمات مع علامات التّرقيم.

ينبني مفهوم النّحو النّمطيّ الذي انطلقت فكرته من اللّغويّات على تنميط الحالات النّحويّة التّتابعيّة. واهتمّ النّحو العربيّ القديم بتحليل هذه الأنماط في النصوص العربيّة قبل اللّغويّات الحديثة. والسؤال المطروح في هذا الفصل هو: كيف يُمكن لنا تطبيق تحليل الأنماط النّحويّة في معالجة النصّ العربيّ؟ لا يُمكن استخدام هذا النظام في أداة أورانج، ويتطلّب تطبيقه درايةً عمليّة بمكتباته في لغة البرمجة (البايثون).

يعتمد تحليل الأنماط النّحويّة على مجموعة الوسوم النّحويّة والبنوك الشّجرية. أشهر أنظمة الوسوم النّحويّة للعربيّة هو بنك براغ للنحو الاعتمادي العربيّ

(١) للاطلاع على قواعد التّعبيرات النمطية في لغة البايثون: <https://developers.google.com/>

https://www.w3schools.com/python/python_regex.asp و [edu/python/regular-expressions](https://www.w3schools.com/python/python_regex.asp)

(تاريخ الاسترداد ٢٤ أكتوبر، ٢٠٢٢).

(٢) حول مزيد من أساليب معالجة النّحو النّمطيّ المعجميّ للتّصاحبات اللّفظيّة والتّعبيرات

الاصطلاحيّة: الغامدي، أيمن. تقنيات الذّكاء الاصطناعيّ والمعالجة الحاسوبية للمتلازمات اللّفظيّة والتّراكيب الاصطلاحيّة. في: خوارزميات الذّكاء الاصطناعيّ في تحليل النصّ العربيّ، ٢٠١٩،

الصفحات ١٢٥-١٦٧.

(Prague Arabic Dependency Treebank) بادت^(١)، ومداميرا^(٢)، وفراسة^(٣)، وستانفورد^(٤). وسأعرض رؤيةً عامّةً عن هذه الأنظمة في المبحث الأوّل، ثم سأطبّق واحداً منها في استخراج الأنماط النحويّة من القرآن الكريم في المبحث الثاني.

المبحث الأوّل: أنظمة الوسوم النحويّة واسعة الاستخدام

نعرّض هنا أربعة أنظمة وسوم نحويّة مشهورة للغة العربيّة، وهي: بادت (PADT)، ومداميرا، وفراسة، وستانفورد. ويتوفّر في كلّ نظام من هذه الأنظمة المعالجات الأساسيّة، وفي الآتي تعريف عن كلّ نظام.

بادت (PADT): يُعرّف بنك براغ للنحو الاعتماديّ العربيّ (Prague Arabic Dependency Treebank)، وسمّي بالبنك الشجريّ العربيّ Penn Arabic Treebank، وهو مدمجٌ مع حزمة نحو (الاعتماديات الكلية Universal Dependencies UD) للتّوسيم النحويّ والصرفي والتركيبي، وتتضمّن هذه الحزمة قرابة ٢٠٠ بنك شجريّ لأكثر من مائة لغة، وتتبع صيغة تنظيميّة معيّنة وفق صيغة محلل (CoNLL-U Format)، وهو اختصارٌ للصيغة الكلّية لفهم اللغة الطّبيعيّة الحاسوبية (Computational Natural Language Learning – Universal). يعمل بادت عن طريق تنصيب (conllu)، أو عن طريق مكتبة (Stanza) لستانفورد.

- (1) Taji, D., et al. (2017). Universal Dependencies for Arabic ; Mohamed Maamouri, et al. (2004). The Penn Arabic Treebank: Building a Large-Scale Annotated Arabic Corpus, pp. 102109-.
- (2) Pasha, A., et al. (2014). MADAMIRA: A Fast, Comprehensive Tool for Morphological Analysis and Disambiguation of Arabic.
- (3) Abdelali, A., et al. (2016). Farasa: A Fast and Furious Segmenter for Arabic; Darwish, K., & Mubarak, H. (2016). Farasa: A New Fast and Accurate Arabic Word Segmenter. LREC-2016; Darwish, K., et al. (2017). Arabic pos tagging: Don't abandon feature engineering just yet; Mubarak, H. (2018). Build Fast and Accurate Lemmatization for Arabic. Paper presented in the International Conference on Language Resources and Evaluation.
- (4) Peng Qi, et al. (2020). Stanza: A Python Natural Language Processing Toolkit for Many Human Languages; Manning, Christopher D., et al. (2014). The Stanford CoreNLP Natural Language Processing Toolkit.

```

!pip install conllu
!wget https://lindat.mff.cuni.cz/repository/xmlui/bitstream/handle11234/1-3105/ud-
treebanks-v2.5.tgz
!tar xzf ud-treebanks-v2.5.tgz
#The imports needed to open and parse (interpret) the conllu fil
from io import open
from conllu import parse_incr
#Open the file and load the sentences to a list.
data_file = open("/content/ud-treebanks-v2.5/UD_Arabic-PADT/ar_padt-ud-train.
conllu", "r", encoding="utf-8")

```

```

import stanza
# Download an Arabic model into the default directory
print("Downloading Arabic model...")
stanza.download('ar')
# Build an Arabic pipeline, with all processors by default
print("Building an Arabic pipeline...")
ar_nlp = stanza.Pipeline('ar')

```

مداميرا: وقد بُنيت فيه أنظمة المعالجة الأساسية من التوسيم النحوي، والتفريق، والتشكيل، والمعجم، والحالات النحوية (base phrases)، واستخراج الكيانات.

فراصة: وبُنيت فيه أنظمة المقطع، والمعجم، والموسم النحوي، والمصحح الآلي، ومُستخرج أسماء الكيانات، والمُشكّل الآلي، والمحلّل المكوّن للعبارات، والمحلّل الاعتمادي للنحو.

ستانفوررد: وبُنيت فيه أنظمة التوسيم النحوي، والمعجم، واستخراج الكيانات، والمحلّل المكوّن، وتحليل المشاعر، والعلاقات، والإحالات (النصيّة).

يمكن -على سبيل المثال- تجريب الاعتماديات الكلية (Universal Dependencies UD) من خلال استخدام الأكواد في الملحق (و) من الكتاب، وللقارئ أن ينظر في دقة التوسيم

لبَياناتِ هذا النُّظام، ثم ينظر في أداءِ توسيمه لـ (الحمد لله رب العالمين الرحمن الرحيم ملك يوم الدين) باستخدام أكواد الملحق (و). سيُلاحظ أن توسيمه لهذه الكَلِمَات غير دقيق، ويعود سببُ ذلك إلى أنَّ البَيانات التي تدرَّب عليها لا تُمثِّل نصوصاً عَرَبِيَّةً متنوِّعةً بتنوُّع الأزمنة والأوعية والمجالات. نستعرضُ في المبحث الآتي نظرةً عامَّةً عن أنظمة التوسيم النُّحويِّ المشهورة في معالجة اللغة العَرَبِيَّة الطَّبِيعِيَّة.

المبحث الثاني: نظرة عامَّة عن الأنظمة

أُشيرُ باختصارٍ إلى مكوِّنات أنظمة المعالجة الأساسيّة، وهي: التَّفريق (tokenization)، والتَّوسيم النُّحويّ (POS tagging)، والمُعجَم (lemmatizer). يتطلَّب التَّفريق أن يعمل النُّظام على فصل التوكن token (الكلمة الفعلية أو الحيز المفصول عن سابقه ولاحقه بمسافة واحدة) عن بعضه بعضاً في النُّصوص، وهذا الفصل يطال الكلمة، ويطال غير الكلمة أيضاً، فغير الكَلِمَات من الأرقام، أو علامات التَّريق، أو الرُّموز؛ تتطلَّب أن تنفَرَق عن بعضها بعضاً، فجملة (في هذا العام ١٤٤٣هـ) يكون شكل التَّفريق فيها على النُّحو الآتي: ([في]، [هذا]، [ال]، [عام]، [١٤٤٣]، [هـ]). قد تجدُ نظاماً من أنظمة المعالجات الأساسيّة لا يفصل (أل) التَّعريف كما هو الحال في ستانفورد، وهذا بحكم تجريبي أفضل؛ لأن فصل المباني الصرفية يُولد مشكلةً عند تعلم الآلة الكلمات بوصفها وحدات معجمية سياقية. مرحلة التَّفريق هي المرحلة الأولى الأساسيّة، يليها معالجة التَّجذيع (stemming)، وهو لا يهَمُّ كثيراً إلا في إطار حصرِ الجذور والجذوع. يليها التَّوسيم النُّحويّ الآتي لما تمَّ تفريقه، ومرحلة التوسيم مهمَّةٌ في بناء المُعجَم (lemmatizer)؛ أي: ردَّ الكلمة إلى أصلها المعجميّ.

في الشَّكْل (٩٨) نتأخَّج تحليل المعالجات المتوفرة في كُلِّ مِن بادت ومداميرا وفرنسة وستانفورد على عَيِّنَةٍ من القرآن الكريم. الملحوظ من الوهلة الأولى أنَّك ستجدُ معالجةً أساسيّةً معيّنةً في نظامٍ من هذه الأنظمة غير متوفرة في نظامٍ آخر، مثل عدم وجود مُعجَم في ستانفورد. أجريتُ اختباراً لهذه الأنظمة على سورة النَّصر من القرآن

الكريم على الرغم من أن هذه الأنظمة قد بُنيت على نصوصٍ عربيّةٍ معاصرةٍ؛ إلا أنّ العيّنةُ تمثّل سورةً قصيرةً لا غرابة في ألفاظها التي نستعملها في عربيّتنا المعاصرة، غير أنّ النّظّم فيها مختلفٌ، وليس كنظم البشر. بُنيت للقرآن الكريم أنظمةٌ مبنيةٌ على القواعد لمستوى الصّرف، والنّحو، والتّركيب، والشّبكات الدّلاليّة، وهي ليست أنظمةً مبنيةً على تعلّم الآلة؛ لأنّ النّصّ القرآنيّ ليس كمثله نصٌّ آخر، ولذلك نجدها دقيقة تماماً^(١). وعوداً إلى نتائج المعالجات في بادت ومداميرا وستانفورد؛ يُلحظ مثلاً تقطيع (يحمّد) إلى [ب]؛ [حمد] في نظام مداميرا وستانفورد، ومن الطّبيعيّ نوعاً ما أن يُصنّف النّظام (حمّد) إلى اسم علم، وهو ليس بـ (حمّد)، لكن سبب ذلك يعود إلى عدم تدرب النّظام في بياناته على صيغة (حمّد)، فضلاً عن غياب التّشكيل أساساً. في نظام بادت؛ لا تتشارك كلمة (استغفر) في صيغتها الكتابيّة مع صيغة خطيّة اسميّة في حال غياب التّشكيل، ومع ذلك فقد صنّفها النّظام على أنها اسم، وهذا غير صحيح، ولا يعني هذا أنّ النّظام لا يصلح، فنسبة الدّقة فيه عاليةٌ لبياناتٍ لغويّةٍ جديدةٍ، لكن كلمة (استغفر) بصيغة فعل الأمر ليست مستعملةً بكثرة في النّصوص العربيّة المعاصرة، فلم تخضع الكلمة لتدريب واختبار. أما بقية الملاحظات فأتركها لواسع نظر اللّغويين القراء. وأشير هنا إلى أنّ هذه الأنظمة الأربعة للتّوسيم النّحوي تختلف فيما بينها في اصطلاح تسمية الوسوم النّحويّة، وفي تعريف كلّ وسيم (أو: رمز) من هذه الوسوم وفق الحالة النّحويّة للكلمة في النّص. والسؤال المهم: هل اختلاف تسمية الواسيم (أو: الرّمز) يؤثر؟ الجواب: لا، إلا إذا اختلف تصنيف الحالات النحوية (الأمثلة) فيها يدوياً. أقترح متابعة ما يتطور لأنظمة هذه الوسوم بعد ظهور النّماذج اللّغويّة الضّخمة Large Language Models LLMs، وأعني هنا: نماذج تمثيلات المشفّر الثنائي الاتجاه من المحوّلات (Bidirectional Encoder Representations from Transformers BERT) التي تطوّر

(١) بُنيت معالجة أساسية لدونة القرآن الكريم، وهي خاصّةٌ بها، فالّصّرف والتّركيب في القرآن الكريم مختلف عن غيره، كما أنّ النّصّ القرآنيّ نصٌّ بلاغيّ مختلفٌ عن نصوص العربيّة القديمة في نظمه المعجز. تميز هذا المشروع ببناء أنظمةٍ شاملةٍ على مستوى الصّرف والنحو والتّركيب والعلاقات الدلالية. للاطلاع على هذا المشروع: <https://corpus.quran.com> (تاريخ الاسترداد ٢٤ أكتوبر، ٢٠٢٢).

سنة	مستطورد			فريسة			ممايزا			بادت			سورة القصص
	الاسم الحرة	المستطورد	الاسم الحرة	المستطورد	الاسم الحرة	المستطورد	الاسم الحرة	المستطورد	الاسم الحرة	المستطورد	الاسم الحرة	المستطورد	
1	حرف جر	IN	إنا	إنا	حرف جر	CCONJ	إنا	إنا	حرف جر	VERB	إنا	إنا	
2	اسم علم مذكر	NNP	جاء	جاء	اسم علم مذكر	VERB	جاء	جاء	اسم علم مذكر	VERB	جاء	جاء	
3	اسم علم مذكر	NNP	الله	الله	اسم علم مذكر	VERB	الله	الله	اسم علم مذكر	VERB	الله	الله	
4	أداة عطف	CC	و	و	أداة عطف	CCONJ	و	و	أداة عطف	CCONJ	و	و	
5	اسم معرفه مذكر	DTMN	الفتح	الفتح	اسم معرفه مذكر	CCONJ	الفتح	الفتح	اسم معرفه مذكر	CCONJ	الفتح	الفتح	
6	أداة عطف	CC	و	و	أداة عطف	CCONJ	و	و	أداة عطف	CCONJ	و	و	
7	فعل تام	VBD	ربن	ربن	فعل تام	VERB	ربن	ربن	فعل تام	VERB	ربن	ربن	
8	اسم معرفه مذكر	DTMN	الفتح	الفتح	اسم معرفه مذكر	CCONJ	الفتح	الفتح	اسم معرفه مذكر	CCONJ	الفتح	الفتح	
9	فعل تام	VBP	يدخلون	يدخلون	فعل تام	VERB	يدخلون	يدخلون	فعل تام	VERB	يدخلون	يدخلون	
10	حرف جر	IN	في	في	حرف جر	CCONJ	في	في	حرف جر	CCONJ	في	في	
11	اسم شائع	NN	دين	دين	اسم شائع	CCONJ	دين	دين	اسم شائع	CCONJ	دين	دين	
12	اسم علم مذكر	NNP	الله	الله	اسم علم مذكر	CCONJ	الله	الله	اسم علم مذكر	CCONJ	الله	الله	
13	اسم معرفه مذكر	NN	أولها	أولها	اسم معرفه مذكر	CCONJ	أولها	أولها	اسم معرفه مذكر	CCONJ	أولها	أولها	
14	أداة عطف	CC	ف	ف	أداة عطف	CCONJ	ف	ف	أداة عطف	CCONJ	ف	ف	
15	فعل تام	VBD	سبح	سبح	فعل تام	VERB	سبح	سبح	فعل تام	VERB	سبح	سبح	
16	حرف جر	IN	ب	ب	حرف جر	CCONJ	ب	ب	حرف جر	CCONJ	ب	ب	
17	اسم علم مذكر	NNP	حمد	حمد	اسم علم مذكر	CCONJ	حمد	حمد	اسم علم مذكر	CCONJ	حمد	حمد	
18	اسم علم مذكر	NNP	ربك	ربك	اسم علم مذكر	CCONJ	ربك	ربك	اسم علم مذكر	CCONJ	ربك	ربك	
19	أداة عطف	CC	و	و	أداة عطف	CCONJ	و	و	أداة عطف	CCONJ	و	و	
20	فعل تام	VBD	استغفر	استغفر	فعل تام	VERB	استغفر	استغفر	فعل تام	VERB	استغفر	استغفر	
21	مجرر مقسم	PRP	هـ	هـ	مجرر مقسم	PRON	هـ	هـ	مجرر مقسم	PRON	هـ	هـ	
22	حرف جر	IN	ان	ان	حرف جر	CCONJ	ان	ان	حرف جر	CCONJ	ان	ان	
23	مجرر مقسم	PRP	هـ	هـ	مجرر مقسم	PRON	هـ	هـ	مجرر مقسم	PRON	هـ	هـ	
24	فعل تام	VBD	كان	كان	فعل تام	VERB	كان	كان	فعل تام	VERB	كان	كان	
25	اسم علم مذكر	NN	نورا	نورا	اسم علم مذكر	CCONJ	نورا	نورا	اسم علم مذكر	CCONJ	نورا	نورا	

أُشير إلى نقطة مهمّة عن نصوص القرآن الكريم، وهي منعكسةٌ من النّظم البديع. يكمن النّظم البديع فيه في جملة القصيرة المكتملة معنيً والمتماسكة اتّساقاً، حتى في الآيات الطويلة كآية الدّين في سورة البقرة. وفي المقابل، ستجد أيّها القارئ أنّ النّصوص القانونية المعاصرة نصوصٌ تتضمّن جملاً قصيرة؛ لكنّها ليست مكتملة المعنى، ومُتسّقة النّظم، وفيها من الغموض النّظمي والإحالي ما فيها معنيً واتّساقاً.

نقطةٌ مهمّةٌ أخرى تتعلّق بطول تراكيب المتمّمات أو الفضلات في الجمل العربيّة المعاصرة، ويُقصد بالمتمّمات complements ما ورد من غير ركني الإسناد (المسند والمسند إليه). نجد المتمّمات في المفعولات، والمنصوبات، وشبه الجمل، والتوابع، والإضافة، إلخ. من أمثلة الإضافة أنَّ غالبَ أسماء المواضع في العربيّة القديمة كلمةٌ واحدةٌ، وقليلٌ منها

يكون مركباً تركيباً إضافياً بسيطاً مثل (مكة المكرمة). ونجد أن أسماء المواضع في العربية المعاصرة قد اتسمت بالطول. على سبيل المثال: المملكة العربية السعودية.

المبحث الثالث: أمثلة على الأنماط النحوية

بعد إجراء مقارنة عشوائية لتكشيف الأنماط؛ يُرى استعمال نظام ستانفورد (الجدول ٢٧) للتوسيم النحوي على تتابع ٢ و ٣ متتابعات لفظية بدلاً من الأنظمة الأخرى؛ لوضوحها ولقلة أخطائها على البيانات الجديدة. وفيما يأتي هذه الأنماط:

١- التركيب الإضافي (NN ثم NNP أو DTNN أو DTNNP أو DTNNS). ومن أمثلته ما يأتي:

[رب NN العالمين / DTNNS]: ورد ٣٤ مرة. [حدود NN الله / NNP]: ورد ١١ مرة. [امراة /

NN العزيز / DTNNP]: ورد مرتين. [زخرف NN القول / DTNN]: ورد مرة واحدة.

٢- التركيب الوصفي، ومن أمثلته ما يأتي:

[غفور JL رحيم / NNP]: ورد ٤٩ مرة. [الحياة DTNNP الدنيا / DTNN]: ورد ٩

مرات. [العزيز DTJJ الحكيم / DTJJ]: ورد ٢٩ مرة. [العزيز DTNNP الرحيم /

DTNNP]: ورد ١٣ مرة. [قول NN معروف / JL]: ورد مرتين. [الروح DTNN

الأمين / DTJJ]: ورد مرة واحدة [مقاما NN محمودا / NN]: ورد مرة واحدة،

[رجل NN رشيد / NNP]: ورد مرة واحدة.

٣- التركيب الفعلي: عدد التراكيب الفعلية الماضية أكثر من المضارعة، والأخيرة

أكثر من المبني للجهول، والأخير أكثر من الأمر، وهذا على عموم الأمثلة في مدونة القرآن الكريم. ومن أمثلته ما يأتي:

فعل تام: [ملك VBD أيما نكم / NN]: ورد ٥ مرات. فعل مضارع: [تؤمنون /

VBP ب IN الله / NNP] ورد ٥ مرات. فعل مبني للجهول: [و CC قيل VBN

ل IN لله / NN]: ورد مرة واحدة. فعل أمر: [ادع VB ل IN نا PRP رب NN ك /

PRP\$]: ورد ٥ مرات.

ما الذي ستفيدنا به قائمة الأنماط للمدونة اللغوية؟ الفائدة تكمن في استخلاص الأنماط العامة، وأكثر الأنماط السائدة، وطبيعة الأمثلة الطبيعية لكل نمط من الأنماط، وذلك يُفيد في معرفة البنية النحوية النمطية الأكثر استخداماً، يليها الأقل استخداماً، وهي إفادة آلية مهمة في بناء المعاجم والمصادر المعجمية.

من فوائدها أيضاً كشف طبيعة أنماط نظم القرآن البياني، وأنماط الفواصل القرآنية^(١). يقول الباقلاني: «إنَّ نظم القرآن على تصوّف وجوهه، واختلاف مذاهبه خارج عن المعهود من نظام جميع كلام العرب، ومباين للمألوف من ترتيب خطابهم، وله أسلوب يختص به، ويتميّز في تصوّفه عن أساليب الكلام المعتاد»^(٢). ويقول أيضاً: «الفواصل حروف متشاكلّة في المقطع، يقع بها إفهام المعاني»^(٣). ومن صور الفواصل ما يكون للتصدير، وما يكون للتوشيح في القرآن الكريم، فالتصدير: إشارة لفظية، وهي أن تتقدّم لفظة الفاصلة بمادتها في أول صدر الآية، أو في أثنائه، أو في آخره، مثل قوله تعالى: ﴿رَبَّنَا لَا تُزِغْ قُلُوبَنَا بَعْدَ إِذْ هَدَيْتَنَا وَهَبْ لَنَا مِنْ لَدُنْكَ رَحْمَةً إِنَّكَ أَنْتَ الْوَهَّابُ﴾ [آل عمران: ٨]. والتوشيح: إشارة معنوية، وهو أن يكون معنى الآية مشيراً إلى هذه الفاصلة، كما ورد في الحديث أن زيداً بن ثابت كان يكتب ما يُملي عليه الرسول -صلى الله عليه وسلم- فأُملي قوله تعالى: ﴿فَرُخْلَقْنَا النُّطْفَةَ عَلَقَةً فَخَلَقْنَا الْعَلَقَةَ مُضْغَةً فَخَلَقْنَا الْمُضْغَةَ عِظْلًا فَكَسَوْنَا الْعِظْلَ لَحْمًا ثُمَّ أَنْشَأْنَاهُ خَلْقًا...﴾ [المؤمنون: ١٤]، فنهض معاذ بن جبل فقال: «فتبارك الله أحسن الخالقين»، فضحك رسول الله -صلى الله عليه وسلم-، فقال له معاذ: ممّ ضحكت يا

(١) وقفت على رسالة ماجستير مقدّمة في جامعة وهران السانية عن دلالة الخطاب في القرآن الكريم، وقد وقفت فيها على نقاط مختصرة ومفيدة عن تميّز نظم القرآن، وعن الفواصل القرآنية فيها، اعتمد الباحث فيها على التصدي لكثير من المصادر العربية القديمة في التفسير والبلاغة واللغة. انظر: معمر، شباب. دلالة الخطاب في القرآن الكريم (رسالة ماجستير)، إشراف: محمد زعراف والجيلاني سلطاني، جامعة وهران السانية، الجزائر، ٢٠٠٦.

(٢) الباقلاني، إعجاز القرآن، صفحة ٣٥.

(٣) المصدر السابق، صفحة ٢٧١.

رسول الله؟ قال: "بها ختمت" ^(١). ومن ذلك قوله تعالى: ﴿وَأَيُّ لَّهُمْ إِلٌ نَسْلَخُ مِنْهُ النَّهَارَ فَإِذَا هُمْ مُظْلِمُونَ﴾ [يس: ٣٧] فنجد فاصلة هذه الآية قد تَوَشَّحت بـ «مُظْلِمُونَ» نتيجةً انسلاخ النَّهَار.


التصدير: مولاكم... نعم المولى التوشيح: جاهدو... النصير	[و/ CC جاهدوا/ VBD في/ IN الله/ NNP حق/ NN جهاده/ NN هو/ PRP اجتباكم/ JL و/ CC ما/ WP جعل/ VBD عليكم/ NN في/ IN الدين/ DTNN من/ IN حرج/ NN ملة/ NN أبيكم/ NN إبراهيم/ JL هو/ PRP سماكم/ NN المسلمين/ DTNN من/ IN قبل/ NN و/ CC في/ IN هذا/ DT ليكون/ NN الرسول/ DTNN شهيدا/ JL عليكم/ JL و/ CC تكونوا/ VBP شهداء/ NN على/ IN الناس/ DTNN فأقيموا/ VBD الصلاة/ DTNN و/ CC آتوا/ VBD الزكاة/ DTNN و/ CC اعتصموا/ VBD بالله/ NNP هو/ PRP مولاكم/ NN فنعم/ NN المولى/ DTNN و/ CC نعم/ UH النصير/ DTNNP]
التوشيح: سبيل الغي... غافلين	[سأصرف/ NN عن/ IN آياتي/ NNS الذين/ WP يتكبرون/ VBP في/ IN الأرض/ DTNN بغير/ NNP الحق/ DTNN و/ CC إن/ VBD يروا/ VBP كل/ / NOUN آية/ NN لا/ RP يؤمنوا/ VBP بها/ NN و/ CC إن/ NN يروا/ VBP سبيل/ NN الرشد/ DTNN لا/ RP يتخذوه/ VBP سبيلا/ NN و/ CC إن/ / NN يروا/ VBP سبيل/ NN الغي/ DTNN يتخذوه/ VBP سبيلا/ NN ذلك/ / DT بأنهم/ NN كذبوا/ VBD بآياتنا/ NNP و/ CC كانوا/ VBD عنها/ NN غافلين/ JL]
التصدير: يشهدون... شهيد	[لكن/ VBP الله/ NNP يشهد/ VBP بما/ NN أنزل/ NN إليك/ NNP أنزله/ / NN بعلمه/ NNP و/ CC الملائكة/ DTNN يشهدون/ VBP و/ CC كفى/ / VBD بالله/ NNP شهيدا/ JL]
التوشيح: سلطان.. وكيل	[إن/ VBD عبادي/ NNP ليس/ VBD لك/ DT عليهم/ NN سلطان/ NNP و/ CC كفى/ VBD بربك/ NNP وكيلا/ NNS]

(١) أورده السيوطي في الإتقان في علوم القرآن، الجزء الثاني، صفحة ١٠١. انظر أيضا: معمر، شباب. دلالة الخطاب في القرآن الكريم (رسالة ماجستير)، صفحة ١٠٤.

التصدير: توكل... وكيلا	[و/ CC توكل / VBD على / IN الله / NNP و/ CC كفى / VBD بالله / NNP و/ كيلا / NNS]
التوشيح: ليقولوا قولاً سديداً	[و/ CC ليخش / NNP الذين / WP لو/ IN تركوا/ VBD من / IN خلفهم / NN ذرية / لـ ضعافا / NN خافوا/ VBD عليهم / NNP فليتقوا/ NNP الله / NNP و/ CC ليقولوا/ VBD قولاً / NN سديداً / NN]
التوشيح: تفجر... ينبوعا	[و/ CC قالوا/ VBD لن / RP نؤمن / VBP لك / DT حتى / IN تفجر/ NN لنا / VBD من / IN الأرض / DTNN ينبوعا / NN]
التصدير: تبذر تبذيرا	[و/ CC آت / VBD ذا / DT القربى / DTNN حقه / NN و/ CC المسكين / DTNNS و/ CC ابن / NN السبيل / DTNN و/ CC لا / RP تبذر/ VBP تبذيرا / NN]

الفصل الخامس تنقيب البيانات

نسمعُ بتعلم الآلة (Machine Learning)، وتحليل البيانات (Data Analysis)، وتطوير البرمجيات (Software Development)، وهي حقولٌ مختلفةٌ عن بعضها من ناحية التطبيق والممارسة. يعتمدُ نَعْلَمُ الآلة على علوم الحاسب، وتقنية المعلومات، مع الرياضيات (التطبيقية)، وعلوم الإحصاء. ويعتمدُ تحليل البيانات على حقل الرياضيات، وعلوم الإحصاء، وتطبيقاتهما على مجالات الأعمال، والمعرفة، والعلوم. ويكون تطوير البرمجيات معتمداً على علوم الحاسب، وتقنية المعلومات في مجالات الأعمال، والمعرفة، والعلوم. أما عِلْمُ البيانات (Data Science)؛ فيعتمدُ على كُلِّ ما سبقَ ذكره، شرطُ أن يبدأ من وجود مشكلةٍ محدّدةٍ للعالم، وتتطلّب استخدام علوم البيانات للبحث عن حلٍّ لها. يُمكنُ التعبيرُ عن نطاقات التداخلات الاختصاصية بين كُلِّ المجالات السابقة بالشكل (٩٩).



شكل ٩٩: تداخلات المجالات التطبيقية لعلم البيانات

أما ما يتعلق بإطار معالجة المدونات اللغوية فيمكن تصنيف التداخل على النحو الآتي.

- يدخل مجال معالجة اللغة العربية الطبيعية ضمن (تعلم الآلة والذكاء الاصطناعي).
- يدخل مجال الأدوات التي تُبنى وتُصمم على أنها تطبيقات لمعالجة اللغة العربية الطبيعية كالمصحح الإملائي، والتعرف إلى الكلام، والتشكيل، ضمن (تطوير البرمجيات والتحليلات المتقدمة).
- يدخل مجال لغويات المدونة ضمن (تحليل البيانات والدراسات الكمية).
- يعتمد علم البيانات (اللغوية) على جميع ما سبق، بهدف إيجاد حلول لمشكلات واقعية تتحدد في سوق اللغة الرقمية، شرط أن يكون هذا الحل تطبيقاً مفيداً لمعالجة المشكلة المحددة.

سأنتقل إلى أساليب تعلم الآلة في التصنيف والانحدار، وأعيد قبل ذلك مثال التصنيف والانحدار من أجل التذكير والتوضيح.

في التصنيف: لدينا بيانات لغوية فيها متغيرات فئوية مصنفة؛ مثل أقسام الكلام.

في الانحدار: لدينا بيانات لغوية فيها متغيرات مقياسية؛ مثل عدد تكرارات أقسام الكلام.

للتصنيف مهمتان في تعلم الآلة.

الأولى: إيجاد أفضل نموذج يكون فيه المتغير المستقل (المتنبئ) أكثر تأثيراً في المتغير التابع (الناتج)، ويسمى هذا الإجراء اختيار السمات (feature selection)؛ على سبيل المثال: [المتغيرات المستقلة: الصفات الشخصية، وضمائر المخاطب، وضمائر الغائب]، و[المتغير الناتج: كاتب وكتابه].

سؤال: ما أكثر المتغيرات الناجمة استخداماً لنوع الضمائر؟ الجواب: يعمل التصنيف على البحث عن النموذج الأفضل؛ أي: المتغير المستقل الأكثر تأثيراً في المتغير الناتج.

لو افترضنا أن المُتغيّر (الضمائر الشخصية) هو أفضل نموذج، فهنا نستنتج بأنه الأكثر تأثيراً على استخدامات الجنسَيْن له.

الثانية: تحقيق أفضل تنبؤ آليّ لأمثلة التصنيف، وذلك على بيانات اختبار (بيانات لم ترها الآلة). لنفترض التصنيف الكلميّ الآتي: [محمد / اسم، خالد / اسم، يذهب / فعل]، ولنفترض أن الآلة قد تدرّبت على هذا التصنيف. لو أتينا ببيانات اختبار لم ترها الآلة، وفيها كلمة [يزيد / اسم]، فالمحتمل أن الآلة ستُصنّفها فعلاً، وليس اسماً، ويتطلّب عندئذٍ تدريب الآلة مرة أخرى على أمثلة صيغ الأسماء التي تُشبه الأفعال من أجل رفع كفاءة أداء التصنيف.

للانحدار مهمّتان في تعلّم الآلة.

الأولى: إيجاد أفضل نموذج يكون فيه المُتغيّر المُستقلّ (المتنبئ) أكثر تأثيراً في المُتغيّر التابع (النّاتج)، ويُسمّى هذا الإجراء اختيار السّمات (feature selection). على سبيل المثال: [المُتغيّرات المستقلّة: تكرارات الضّمائر الشخصية، وتكرارات ضمائر المخاطب، وتكرارات ضمائر الغائب]، و[المُتغيّر النّاتج: كاتب وكتابه]. لا يتعامل الانحدار مباشرةً مع المُتغيّرات الفئوية، وبالتالي لابدّ من تحويلها إلى مُتغيّراتٍ مقياسيّة. في حالتنا هنا: (كاتب) و(كاتبة)، يُجرى في تعلّم الآلة ما يُسمّى بترميز النقطة الساخنة (one hot encoding)، ويعمل ببساطة وفق عدد الفئات، فإن كانت فئتين؛ تُحذف الثانية؛ لأن الأولى دالّة على الثانية (مثل: إبقاء كاتب وحذف كاتبة)، أو تُعطى القيمة (١) لإحدهما والقيمة (٠) للآخرى، وإن كانت أكثر من ذلك؛ فيتم وضع كلّ فئة في عمودٍ مستقلٍّ، وتُعطى القيمة (١)، وتُعطى ما عداها القيمة (٠) في العمود نفسه، ويُطبّق هذا المنوال على بقية أعمدة الفئات الأخرى في جدول البيانات.

سؤال: ما أكثر المُتغيّرات النّاتجة استخداماً لتكرارات نوع الضّمائر؟ الجواب: يعمل التّصنيف على البحث عن النّموذج الأفضل؛ أي: قيمة المُتغيّر المُستقلّ الأكثر تأثيراً في

المُتَغَيَّرُ النَّاتِجُ. لو افترضنا أن المُتَغَيَّرَ (تكرارات الضمائر الشخصية - أنثى) هو أفضل نموذج، فهنا نستنتج بأن الجنس (الأنثى) هو الأكثر استخداماً لهذا النوع من الضمائر.

الثانية: تحقيق أفضل تنبؤ آلي للانحدار الخطي، وذلك على بيانات اختبار (بيانات لم ترها الآلة). لنفترض أن التصنيف لنصوص بين ثلاثة أوعية مختلفة، ولنفترض أننا قد دربنا الآلة على التنبؤ بتكرارات علامات التقييم في تلك النصوص بين هذه الأوعية (الجدول ٣٢)، وبعد التدريب؛ تنبأت الآلة بأن تكرارات علامات التقييم في الصحف ١٥، وفي الرسائل العلمية ٩، وفي الروايات ٣٠. هنا ستكون نسبة قيمة المنحدر (regressor score) ٧٥٪ مقابل التكرارات الحقيقية لعلامات التقييم. إذن، فتعلم الآلة لنموذج الانحدار يعتمد على تنبؤ النموذج بالقيم المتنبأ (predicted values) مقابل القيم الحقيقية (actual value) في البيانات.

جدول ٣٢ : التنبؤ بعلامات التقييم بين الأسماء والأفعال والضمائر

	المُتَغَيَّرَاتُ الْمَتَّبَعَةُ (المُسْتَقْلَّة)			المتغير الناتج (التابع)	
	الأسماء	الأفعال	الضمائر	القيمة الحقيقية	القيمة المتنبأ
الصحف	100	90	66	20	15
الرسائل العلمية	90	20	10	12	9
الروايات	150	110	79	40	30

المبحث الأول: تهيئة المُتَغَيَّرَات في البيانات

أشير هنا إلى أبسط أنواع المُتَغَيَّرَات في تعلم الآلة، وإلى اختلاف المصطلحات مع تشابه المفاهيم، بحكم اختلاف مجال تعلم الآلة عن مجال علم الإحصاء. في الجدول الآتي تصنيف لتلك الأنواع والاختلافات.

جدول ٣٣ : أنواع المتغيرات في البيانات بين تعلم الآلة وعلم الإحصاء

علم الإحصاء	تعلم الآلة	
التابع dependent، الاستجابة response، الخروج outcome	الهدف target، العلامة label، الناتج output	التابع Y
المستقل independent، التأويلي explanatory، المتنبئ predictor	الخاصية feature، السمة attribute، الدخل input	المستقل X

ولشرح إمكانات أدوات (أورانج) القائمة بذاتها في مجال تنقيب البيانات (اللغوية)؛ أمثل بثلاثة أشكال للبيانات المهيأة للتصنيف في المبحث الثاني (الشكل ١٠٠ و١٠١)، وللانحدار في المبحث الثالث (الشكل ١٠٢). يُشير إلى المتغيرات الاسمية (كالزمن: مكّي MK ومدني MD) أو الفئوية (كالطول: طويل long ومتوسط medium وقصير short)، ويدلّ c على المتغيرات المقياسية (كعدد الآيات)، ويُشير الصنف (class) إلى المتغير التابع أو الناتج. سيُجرى التحليل في المبحث الثاني (التصنيف) على بيانات الشكل (١٠٠) و(١٠١)، وفي المبحث الثالث (الانحدار) على بيانات الشكل (١٠٢).

السجدة	الطول	الزمن
d	d	d
class		
no	short	MK
no	long	MD
no	long	MD
no	long	MD
no	long	MD
no	long	MK
yes	long	MK
...	...	...

شكل ١٠٠: بيانات تحليل للتصنيف

الزمن	الطول	الأنبياء
d	d	d
		class
long	MD	yes
long	MD	yes
long	MD	yes
long	MD	yes
long	MK	yes
long	MK	yes
long	MD	yes
...	...	...


شكل ١٠١ : بيانات تحليل للتصنيف

الترتيب الزمني	مدني	مكي	الزمن	السجدة	الأنبياء	عدد الآيات	ترتيب المصحف
c	c	c	d	c	c	c	c
							class
5	0	1	MK	0	1	7	1
87	1	0	MD	0	1	286	2
89	1	0	MD	0	1	200	3
92	1	0	MD	0	1	175	4
112	1	0	MD	0	1	120	5
55	0	1	MK	0	1	156	6
39	0	1	MK	1	1	206	7
88	1	0	MD	0	1	75	8
113	1	0	MD	0	1	129	9
51	0	1	MK	0	1	109	10
...	...	...	...	...	...	...	...

شكل ١٠٢ : بيانات تحليل الانحدار

المبحث الثاني: التصنيف

من أجل شرح أسلوب تعلم الآلة في التصنيف، هيئت البيانات (الشكل ١٠٠) وفقاً للمتغيرات الآتية: تصنيف السورة من حيث مكينها أو مدنيّتها، وطول السورة (طويل ومتوسط وقصير). هذه المتغيرات فئوية، أما المتغير الهدف (target) - أو الصنف (class)؛ أي: التابع أو الناتج - فهو (السجدة). لنطرح هذا السؤال: ما أداء النموذج في بيانات الاختبار (٢٠٪ من مجموعة البيانات) لتصنيف: (وجود السجدة من عدم وجودها) بناءً على معطيات المتغيرات الفئوية؟ لبدء مسار التحليل وصولاً إلى تنبؤات الآلة بالتصنيف؛ يتخذ مسار العمل في أداة أورانج وفق الشكل (١٠٣).




شكل ١٠٣: مسار العمل لتحليل التصنيف بالأنحدار اللوجستي

يُلاحظ في نتيجة أداء الأنحدار اللوجستي للتصنيف أن نسبة (الدقة) في التصنيف هي (٠,٧٦٤)، ونسبة (الاسترجاع) الذي يُخبر عن نسبة التصنيف الصحيح هي (٠,٨٧٤).


ومن أساليب تمثيل البيانات المستخدمة في مسار هذا التحليل إجراء مخطط التَشَتُّت. أُجري ذلك لتمثيل التصنيف بين السور المكّية والمدنيّة على محورين (المحور السيني: السجدة، والمحور الصادي: الزمن) كما في الشكل (١٠٤)، ثم على محورين آخرَين (المحور السيني: السجدة، والمحور الصادي: الطول) كما في الشكل (١٠٥).

جدول ٣٤ : مصفوفة الارتباك لنموذج الأنحدار اللوجستي

النموذج	الصحة	الدقة	الاسترجاع	مقياس-ف
الأنحدار اللوجستي	٠,٨٧٤	٠,٧٦٤	٠,٨٧٤	٠,٨١٥



شكل ١٠٤ : مخطط التَشَتُّت لحجم السُّور المَكِّيَّة والمدَنِيَّة بين السَّجْدَة والزمن




شكل ١٠٥ : مخطط التَشَتُّت لحجم السُّور المَكِّيَّة والمدَنِيَّة بين السَّجْدَة والطول

للتصنيف في تعلّم الآلة نماذج أساسيّة تُطبّق للتدريب والاختبار والتحقّق. لمعرفة أداء كل نماذج التصنيف، سنستخدم بيانات (الشكل ١٠١). المتغيرات المستقلة (المتنبئة): السور من حيث الزمن (مكيّة ومدنيّة)، ومن حيث الحجم (طويلة ومتوسطة وقصيرة)، والمتغير التابع أو الناتج: (نعم): ورد اسم نبي من الأنبياء؛ و(لا): لم يرد اسم نبي من الأنبياء. في الشكل (١٠٦) حملت البيانات في أداة (ملف file)، ثم ربطت مسارات أعمال التحليل والمعالجة مع الاختبار والقياس (Test and Score)، ثم ربط الاختبار والقياس مع ستة نماذج تصنيفيّة. أما الأدوات التمثيليّة فوضعت بعد أداة الاختبار والقياس.

أما النماذج فهي ستة، وهي على النحو الآتي:

- بايزي البسيط Naïve Bayes
- خوارزمية الجوار الأقرب kNN
- آلة المتجه الداعمة SVM
- الغابة العشوائية Random Forest
- الانحدار اللوجستي Logistic Regression
- التعزيز التكيّفي AdaBoost



شكل ١٠٦: مسار التحليل لنماذج التصنيف وتمثيل النتائج

في أداة الاختبار والقياس، تُجرى عدة مناهج لاختبار أداء تصنيف كُلاً نموذج من النماذج الستة، وهي على النحو الآتي:


- التَّحْقُقُ المتقاطع (cross validation)، الذي يُقسَّم البَيِّنَات إلى عددٍ معيَّن من الطَّيَّات، وعادةً تكون ٥ طَيَّات (5-folds) أو ١٠ طَيَّات (10-folds)، ويعمل على اختبار خوارزمية النموذج عن طريق النظر إلى تصنيف كُلاً طَيَّة، واستنتاج ذلك في الطَيَّات الأخرى، وهكذا دواليك، إلى أن يُمرَّر كلُّ عدد الطَيَّات المحدد مسبقاً.
- العَيِّنَةُ العشوائية (تدريب-اختبار) التي تُقسَّم فيها البَيِّنَات عشوائياً إلى مجموعة تدريب ومجموعة اختبار، ويتكرر هذا التقسيم لعددٍ محددٍ في ضبط التَّدرِيب.
- الاختبار على بيانات التَّدرِيب فقط، ويُستخدم على كامل البَيِّنَات، ولا يصل إلا إلى نتائج خاطئة، والسَّبَبُ يتعلَّقُ بأنَّ النَّمُودَج الذي يتعلَّم على بيانات التَّدرِيب، ويختبر نفسه فيما تعلمه فقط؛ لا يحقِّق هدف تعلُّم الآلة في الأساس.
- الاختبار على بيانات الاختبار فقط، ويُستخدم لكشف أداء الآلة على التَّصنيف في بَيِّنَات الاختبار (بيانات لم ترها الآلة).

بعد اختيار أحد هذه المناهج؛ يُتطلَّب اختيار صنف المُتغيِّر الهدف (target) الذي يُعدَّ في بيانات ملف (الأنبياء)؛ ثنائياً: (نعم) أو (لا). وهناك طريقتان لاستخراج مصفوفة الارتباك للتَّصنيف في مثل هذه الحالات، وهي أن نستخرج إمَّا متوسط الأوزان لكلِّ الأصناف؛ أي لـ (نعم) و (لا) في مثالنا هنا، أو أن نختار صنفًا واحدًا منهما. اخترتُ هنا التَّحْقُقُ المتقاطع ثم متوسط أوزان الأصناف (Average over classes) لـ: (نعم) و (لا). سنلحظ أن أفضل أداءٍ من هذه النماذج قد عُولِجُ بنموذج بايزي البسيط ثم نموذج خوارزمية الجوار الأقرب وفق نسب كلِّ من الدَّقة والاسترجاع (الجدول ٣٥).

جدول ٣٥ : مقاييس مصفوفة الارتباك لنماذج التّصنيف

نوع التّحليل : ٥ طيّات تحقق متقاطع cross-validation الصنف: المُتغيّر الهدف (متوسط أوزان الأصناف)					
النموذج	الصحة	الدقة	الاسترجاع	مقياس-ف	
بايزي البسيط	0.702	0.707	0.702	0.693	Naïve Bayes
خوارزمية الجوار الأقرب	0.693	0.761	0.693	0.761	kNN
آلة المتجه الداعمة	0.693	0.699	0.693	0.683	SVM
الغابة العشوائية	0.693	0.699	0.693	0.683	Random Forest
الانحدار اللوجستيّ	0.693	0.699	0.693	0.683	Logistic Regression
التعزيز التكيّفي	0.675	0.674	0.675	0.672	AdaBoost

لنقم بإنشاء مسارٍ عمليّ تحليليّ كما في الشّكل (١٠٧) للبيانات التّصنيفيّة للأنبياء، لننظر إلى حساب المسافات ومصفوفتها.




شكل ١٠٧ : مسار العمل لتحليل بيانات الأنبياء التّصنيفيّة

سأجري حساب المسافة الإقليديّة، ويمكن اختيار غيره من أداة المسافات (Distances). في الشّكل (١٠٨) أسلوبُ قياس المسافات بين الصّنف (class) -نعم yes ولا no- لورود أسماء الأنبياء بين السّور المكيّة الطّويلة والمتوسطة والقصيرة، وبين السّور المدنيّة الطّويلة

[illegible]

شكل ١٠٨: قياس المسافات بين الصنف class (نعم ولا)



شكل ١٠٩: تمثيل الإقحام الخطي

المبحث الثالث: الانحدار الخطّي

يُسمى الانحدار الخطّي بالترميزات الصغرى المعتادة (ordinary least squares)، ويُسمى أيضاً - بالترميزات الصغرى الخطيّة (linear least squares). في تعلّم الآلة، يتعلّم نموذج الانحدار ليستخدم على بياناتٍ جديدةٍ، على عكس نموذج الانحدار في الإحصاء (المبحث الأول في الفصل الرابع من الباب الأوّل) الذي يُكتفى به في الإخبار عن أداء الانحدار الخطّي.

ينقسم الانحدار الخطّي إلى نوعين. الأوّل: الانحدار الخطّي البسيط الذي يُستخدم في حال أردنا إيجاد علاقة خطيّة بين متغيّر مستقلّ أو مُتنبّئ predictor واحدٍ ومُتغيّر ناتج (تابع). الثاني: الانحدار الخطّي المتعدّد الذي يُستخدم في حال أردنا إيجاد علاقة خطيّة بين متغيّراتٍ مستقلةٍ ومُتغيّر ناتج (تابع).

يَفترضُ نموذجُ الانحدار الخطي وجودَ علاقةٍ بين المُتغيِّر المتنبئ (المستقلِّ) والمتغيِّر الناتج (التابع). يجبُ أن تكون المُتغيِّراتُ كُلُّها في نموذج الانحدار الخطي مقياسية (أرقام)، ولا تكون فئوية. إن كانت فئوية؛ فيُجرى بالضرورة أسلوبُ ترميز النقطة الساخنة (one-hot encoding)، ومثاله سنراه في الشَّكل (١١٠). يتدرَّب نموذج الانحدار في تعلم الآلة من القيم الحقيقية للمتغيِّر الناتج وفق فهمها لعلاقتها مع قيم المُتغيِّر الناتج (التابع)، ثم يُختبر النموذج على بيانات اختبار، ثم يتنبأ بقيم المتغيِّر الناتج (قيم متنبأ بها predicted values) حسب ما تعلَّمته الآلة من الخصائص والمعطيات في المتغيِّر المستقلِّ. تُقاس دقة تعلم هذا النموذج بالمقارنة بين القيم الحقيقية في البيانات والقيم التي تنبأت الآلة بها، فإن كانت القيم التي تنبأت بها بعيدة، فأداء التعلم عندئذٍ يكون ضعيفاً.


لتطبيق نموذج الانحدار على مُتغيِّرات الشَّكل (١٠٢)، نُجري تحويل المُتغيِّرات الفئوية (أسماء السُّور) إلى مُتغيِّرات رَقمية. وهناك طريقةٌ في علم البيانات تعمل على تحويل المُتغيِّرات الفئوية إلى مُتغيِّرات رَقمية ثنائية dummy باستخدام ترميز النقطة الساخنة^(١) one-hot encoding. وفي هذه الحالة؛ لا بدَّ من تحويل عمود الزمن الذي يتضمَّن مُتغيِّرات فئوية إلى مُتغيِّرات مقياسية، عن طريق فصلها بترميز النقطة الساخنة، وجعل المكِّي في عمود مستقلِّ، والمديني في عمود مستقلِّ، ثم إزالة عمود الزمن كما في الشَّكل (١١٠). المُتغيِّر الهدف (أي: الناتج أو التابع) في بيانات هذا الشَّكل هو (الترتيب الزمني). والسؤال المطروح: هل يمكن التنبؤ بالترتيب الزمني وفق المُتغيِّرات المستقلة: (ترتيب المصحف، وعدد الآيات، وورود أسماء الأنبياء، ووجود السجدة، وفيما إن كانت السُّورة مَكِّيَّة أو كانت مدنيَّة)؟ يكون الجوابُ إما بالإمكان مع أداء عالٍ، أو بعدم الإمكان مع أداء ضعيف، وتتبَّين جودة التنبؤ بارتكاز أو قرب نقاط المُتغيِّرات على حَظِّ الانحدار. سننظر إلى النتيجة بعد تحميل الملف، وإعداد مسار التحليل وفق الشَّكل (١١١).

(١) لمزيد من التدريب على أسلوب التعامل مع المُتغيِّرات الفئوية في البيانات الاطلاع على تطبيقات الانحدار الخطي Linear Regression Tutorial في الرابط الآتي:

<https://www.kaggle.com/sudhirn17/linear-regression-tutorial> (تاريخ الاسترداد ٢٤ أكتوبر، ٢٠٢٢).

الترتيب الزمني	مدني	مكي	الزمن	السجدة	الأنبياء	عدد الآيات	ترتيب المصحف
c	c	c	d	c	c	c	c
class							
5	0	1	MK	0	1	7	1
87	1	0	MD	0	1	286	2
89	1	0	MD	0	1	200	3
92	1	0	MD	0	1	175	4
112	1	0	MD	0	1	120	5
55	0	1	MK	0	1	156	6
39	0	1	MK	1	1	206	7
...	...	...	...	...	...	...	...

شكل ١١٠: مثال لبيانات تحليل الأنجدار الخطّي



شكل ١١١: مسار العمل لتحليل الأنجدار الخطّي

قبل النظر في أداء نموذج الأنجدار الخطّي، لابدّ من إجراء تحليل الارتباط بين المتغيرات. أشرت في الجدول (٣٦) إلى قيم الارتباط بين المتغيرات، وجميعها ضعيفة، ويُقاس ذلك بمنطق + و-١، ويتمثل الضعف بالجناح إلى القيمة (-1) التي تدلّ على العلاقة السلبية، أو القيمة (0) التي لا تدلّ على أيّ علاقة، على عكس الجناح إلى القيمة (+1) التي تدلّ على

وجود علاقة إيجابية. ليس بالضرورة أن تكون هناك علاقة خطية عندما يكون هناك ارتباط من عدمه بين المتغيرات، فالارتباط إذن ليس بالضرورة أن يكون سبباً في وجود علاقة خطية.

تؤكد الأبحاث التجريبية إلى أن تفسير قيمة الارتباط من البيانات غير اللغوية مختلف عن تفسيرها من البيانات اللغوية، ويعتمد ذلك على عدد الملاحظات وعدد عناصر البيانات ومعلوماتها (المشاهدات observations). نحتاج إلى ارتباط كبير بقيمة (0.63) فأعلى عندما يكون في البيانات عشر ملاحظات، وقد تكون قيمة الارتباط الأقل من (0.2) ذات دلالة وحجم تأثير عالٍ للملاحظات التي تزيد عن المئة حالة، كما هو حال عدد ترتيب سور القرآن زمنياً (١١٤)، كما قد تكون ذات دلالة إحصائية لعدد الملاحظات التي تزيد عن الألف عندما تكون قيمة الارتباط (0.06) فأعلى. يحدّر التأكد من عدد الملاحظات في البيانات اللغوية، والإفصاح عن معامل الارتباط الناتجة عن التحليل، نظراً لأهمية هذا العدد في كشف طبيعة الارتباطات بين المتغيرات اللغوية^(١).

جدول ٣٦: قيم الارتباط بين متغيرات بيانات نموذج الانحدار الخطي

التسلسل	المتغير	المتغير	قيمة الارتباط
1	الترتيب الزمني	مكي	-0.736
2	الترتيب الزمني	ترتيب - المصحف	-0.419
5	الترتيب الزمني	السجدة	+0.031
4	الترتيب الزمني	عدد الآيات	+0.118
3	الأنبياء	الترتيب الزمني	+0.277

بعد تحليل الارتباط، يُجرى الاختبار والقياس (Test and Score) لأداء نموذج الانحدار الخطي بين المتغيرات في أداة أورانج، وذلك بمتوسط الخطأ التربيعي (Mean Square Error MSE)

(١) بريزينا، فاكلاف. علم الإحصاء في لغويات المدونة الحاسوبية. ترجمة: سلطان المجيلول. دار جامعة الملك سعود للنشر، الرياض، الطبعة الأولى، ٢٠٢١، الصفحات ١٨٨-١٨٩.

الذي يُظهر معدل الخطأ الذي يكون مربّعه هو متوسط مربّعات كل الأخطاء، وبجذر متوسط الخطأ التّربيعي (Root Mean Square Error RMSE) الذي يقيس مدى تباعد القيم المتنبّأ بها عن القيم الحقيقية في البيانات، وبمتوسط الخطأ المطلق (Mean Absolute Error MAE) الذي يقيس إمكان التنبؤ من عدمه بالنتائج النهائيّة، وبمعامل R^2 الذي يقيس نسبة التباين في المتغير التابع، وتكون قيمة النسبة بين (١) و(٠). وعند تقييم مدى مُلاءمة نموذج الانحدار الخطّي، يُستعان بقياس كل من جذر متوسط الخطأ التّربيعي (RMSE) ونسبة مُعامل R^2 ، وذلك وفق المعطى الأتّرياديّ الآتي:

- متوسط الخطأ التّربيعي (RMSE): كلّما انخفضت القيمة، كان النموذج أدعى إلى التّلاؤم مع مجموعة البيانات.
- مُعامل R^2 : كلّما زادت قيمة النسبة إلى (1)، كان النموذج أدعى إلى التّلاؤم مع مجموعة البيانات.

نجد في الجدول (٣٧) مُدخلات الاختبار القياس، التي اخترنا فيها اختبار النّموذج بأسلوب العيّنة العشوائيّة (تدريب-اختبار)، ثم بأسلوب التّحقّق المتقاطع (٣ طيّات 3 folds). جاءت معدلات كل القيم عاليّة، ونسبة تباين تجاوزت النصف ($R^2 = 0.610$ ثم $R^2 = 0.578$)، ولا يُمكن أن يكون التنبؤ الآليّ ذا كفاءة؛ لأنّه يصعب على الآلة تحقيقها لحالة هذه البيانات اللغوية التي تتسم بفرط التخصيص^(١) (overfitting) للمتغيرات اللغوية (أي: أنّ النموذج قد حفظ البيانات دون فهم).


(١) عكس «فرط التّخصيص» هو «فرط التّعميم» (underfitting) في البيانات اللغوية، ويشير إلى أن النموذج لم يتعلّم شيئاً. تؤكد حالة «فرط التّخصيص» أو حالة «فرط التّعميم» على أهمية العناية بتهيئة البيانات في تعلّم الآلة، وأنها هي الأساس لتحقيق التعلّم، ويترتب في حالات «فرط التّخصيص» التفریط في بعض الخصائص الشاذة في البيانات اللغوية، كما يترتب في حالات «فرط التّعميم» زيادة التّخصيص من خصائص البيانات، بغية تحقيق هدف التعلّم الآلي. هذا كله على خلاف ما لاحظناه في متغيّرات البيانات اللغوية في علم الإحصاء، التي تُقاس وتُحلّل وتُستخرج منها المعلومات والدلالات الإحصائية، ويُفصح عن معنويتها من عدمها وعن تأثيرها من عدمه، دون الحاجة إلى الاعتناء بحالات الفرط في التّخصيص أو التّعميم.

جدول ٣٧: الاختبار والقياس (الانحدار الخطّي)


التَّحَقُّقُ المتقاطع Cross validation				العَيِّنَةُ العشوائية Random sampling			
Regularization (عدد الطّيّات: ٣)				(تدريب-80% اختبار 20%)؛ عدد مرات التعلم: ١٠ مرات			
R2	MAE	RMSE	MSE	R2	MAE	RMSE	MSE
0.578	16.431	21.378	457.015	0.610	16.059	20.500	420.235

الانحدار
الخطّي


في الشَّكْل (١١٢) تمثيلاً لخط الانحدار لثلاث حالات؛ وهي (أ): التَّرتيب الزَّمني [مستقل] وترتيب المصحف [تابع]؛ و(ب): التَّرتيب الزَّمني [مستقل] وعدد الآيات [تابع]؛ و(ج): ترتيب المصحف [مستقل] وعدد الآيات [تابع]، وقد مُثِّلَ خطُّ الانحدار بمتعدّد الحديّة (polynomial)، والانحدار غير متلائم فيها جميعاً مع نقاط البيانات للمتغيّرات بين المتغير المستقلّ والمتغير التابع (النَّاتج).



(أ) الترتيب الزمني وترتيب المصحف




(ب) الترتيب الزمني وعدد الآيات



(ج) ترتيب المصحف وعدد الآيات

شكل ١١٢: خط الانحدار البسيط (متغير مستقل واحد مقابل متغير تابع واحد)


تتضمن أداة أورانج للانحدار الخطي خياراتٍ لمزيد من التحسين، وذلك بإيجاد أفضل نموذج خطّي للتنبؤ. ولطرح بعض الحلول؛ طُبّق تنظيمُ انحدار ريدج (Ridge regression) بين الترتيب الزمنيّ بصفته المتغيّر المستقلّ وبين عدد الآيات بصفته المتغيّر التابع (الشكل ١١٣: ب)، وبمعدّل خطأ: ٣٤,٩١٢. لا بدّ من الإفصاح عن جذر متوسط الخطأ التريعي (Root Mean Square Error RMSE) ونسبة التباين لـ (٢) إن لم يتحقق تحسينُ التعلّم بأيّ حلٍّ من حلول التنظيم (regularization)؛ كاستخدام انحدار ريدج (Ridge regression) الذي يُساعدُ في تقليل التباين الكبير، أو انحدار لاسو (Lasso regression) الذي يُساعد على التقليل من متغيّرات (التابع) وعلى التقليل من فرط التخصيص.



شكل ١١٣: مخطط التشتت بخط الانحدار بين الترتيب الزمني وعدد الآيات

يمكن في مثل هذه الحالة استخدام نماذج الخطّ المناسبة (fitted line models)، وبنموذج الانحدار التدرجيّ (stepwise regression). أُجري هذا النموذج بأفضل تمثيل على المتغيّرين: (الترتيب الزمني وعدد الآيات). نلاحظ أنّ أقرب تمثيل للخطّ بين الترتيب الزمنيّ وعدد آيات السور قد ظهر كما في الشكّل (١١٣)، وبقيمة ارتباط تساوي (0.17)،

وهي قيمة قليلة تدل على وجود ارتباط ضعيف، ولكنها قيمة قد تكون ذات ارتباط مهم في البيانات اللغوية.



شكل ١١٤: الانحدار المتعدد الحدود بين الترتيب الزمني وعدد الآيات

ثمة عدة أساليب لتعددية الحدود، أي: حدود الدرجات المتعددة لنقاط البيانات بين المتغير المستقل (الترتيب الزمني) والمتغير التابع (عدد الآيات)، ولنمذجة العلاقة بين المتغيرات متعددة الحدود، يتعين استخدام نموذج الانحدار اللاخطي، ومن أنواعه ما نجد في أداة الانحدار الخطي linear regression في أورانج، ويسمى الانحدار المتعدد الحدود (polynomial regression)، الذي يمثل الشكل المنحني الأكثر ملاءمة لمجموعة البيانات عندما تكون العلاقة بين المتغير المستقل وبين المتغير التابع غير خطية. وفي الشكل (١١٤) تمثيل للمنحنى الأفضل الذي أوجدته باختيار سبع درجات من درجة تعددية الحدود (polynomial degree)، وهو المنحنى الذي يعد الأكثر ملاءمة لنقاط البيانات بين المتغير المستقل (الترتيب الزمني) والمتغير التابع (عدد الآيات).

الخاتمة

جاء هذا الكتاب في بابين. الأول: الإحصاء اللُّغوي، والثاني: تنقيب النُّصوص والبيانات العربية. أجريت تطبيقات الإحصاء اللُّغوي وتطبيقات تنقيب النصوص والبيانات على مدونة القرآن الكريم، واحتوى كل فصل من فصول البابين على تطبيقات محددة في مباحثه. اخترت أدوات لانكستر الشبكية لتطبيقات التحليل الإحصائي لمدونة القرآن الكريم في الفصول الخمسة من الباب الأول، نظراً لشمولية أدوات مُعالجتها التحليلية للمدونة اللُّغوية، كما اخترت أداة أورانج لتنقيب النصوص والبيانات في معالجة مدونة القرآن الكريم وتحليلها في الفصول الخمسة من الباب الثاني، ذلك أن هذه الأداة الجاهزة قد صُمِّمت من نماذج الآلة مُطَوِّرة في البايتون.

ومع تدفُّق النُّصوص والمعلومات المنصّوية فيها، وضخامة حجم هذا التدفُّق من المدونات اللُّغوية، بات تطبيق الممارسات التحليلية ملحاً، سواء كان بالنماذج الإحصائية في البيانات اللُّغوية كما في فُصول الباب الأول، أو كان بالمعالجة الآلية للبيانات اللُّغوية كما في فُصول الباب الثاني. والذي أقترحه عند إجراء تطبيقات فُصول الباب الأول، وتطبيقات فُصول الباب الثاني، أن يُجري المتدرب بعد قراءة كل مبحث تطبيقاً على بيانات هذا الكتاب، المرفوعة في موقع Kaggle؛ لكي يتأكد من تطابق النتائج في كل مبحث أو عند كل تطبيق تحليلي واحد من مباحث البابين. يتبقى على المتدرب بعد صياغة أسئلة بحثه أو بعد صياغة فرضيات تحليله الكمي (في: الإحصاء اللُّغوي) أو بعد تحديده مهمة من مهام معالجة النصوص العربية (في: تنقيب النصوص والبيانات اللُّغوية) أن يهيئ البيانات الخاصة به بالهيكل أو الشكل الذي صُمِّمت به شكل البيانات في كل تطبيق تحليلي مُحدّد في مباحث فصول البابين من هذا الكتاب.

وأختم في الآتي بنتيجتين عامتين، وبوجهتين أساسيتين، كل واحدة منهما تخصّ باباً من البابين، مع ذكر التوصيات التي تخصّ كل باب على حدة.

أولاً: عن الإحصاء اللغوي في الباب الأول

النتيجة

من ناحية ما ظهر من نتائج من تحليل مُدَوَّنة القرآن الكريم؛ فأهمُّها أنَّ الكثافة المعجمية في القرآن عالية، وقد قاربت ٧٠٪، وهذا ممَّا لم أقف عليه في النصوص البشرية، وأن مقاييس التَّشْتُّت قد أكَّدت على أنه لا يوجد تباين بين أجزاء القرآن، فكانت النسبة متدنيَّة جداً (١٣٪)، كما أنَّ التَّوْزِيع المْتَرَن قد بلغ نسبةً عاليةً، تزيد عن ٩٨٪، ولم أقف -أيضاً- على مثل ما يُقارب هذه النسب في مُدَوَّنات اللغة العربية، إذ يَغْلُب عليها ارتفاع نِسَبِ التَّبَايُن عن هذه النسبة. ومن أهمِّ النتائج -أيضاً- ما أجريته في مقاييس التَّصَاخُب اللَّفْظِي، وما تُفيد به قِيَمُ هذه المقاييس من تحليل إحصائيٍّ معيَّن في تحليل الخطاب، سواءً لاستنتاج ندرة وحصرية التَّصَاخُب معاً، أو لاستنتاج حصريَّة التَّصَاخُب فقط، أو لاستنتاج أثر التَّصَاخُب وكثرته، أو لاستنتاج معنويَّة التَّصَاخُب، أو لاستنتاج حجم زيادة نموُّ التَّصَاخُب، أو لاستنتاج ثنائية الاستعمال التبادليِّ للتَّصَاخُب. ومثالُ الأخير: استخدام مقياس دلتا-ب، وما أعطاه من نتيجة مكوَّنة من قيمتين؛ بَرَهْنَتْ لنا أنَّ الاستخدام التبادليَّ أو الثَّنَائِيَّ الحَدَّ (binomial) لـ ("غفوررحيم" و "رحيم غفور": 0.844; 0.803) ممكنٌ، وفق ما أفاد به هذا المقياس من مُدَوَّنة القرآن الكريم، وأنَّ الاستخدام التبادليَّ لـ ["البقيات الصالحات" و "الصالحات البقيات": 0.999; 0.032] غيرُ واريٍّ في السِّيَاقِ الاستعماليِّ، وفق ما أفاد به هذا المقياس من مُدَوَّنة القرآن الكريم؛ لأنَّ القيمتين متباعدتان جداً. ومن أهمِّ النَّتَاج -أيضاً- ما جاء في الارتباط بين أقسام الكلام في مُدَوَّنة القرآن، فقد جاءت أقوى الارتباطات إيجابيةً بين الأسماء والصفات ثم بين الضَّمائر والأدوات، ثم بين الأفعال والضمائر، وجاءت أقوى الارتباطات سلبيةً (أي انعداماً) بين الأسماء والضمائر، ثم بين الأسماء والأدوات، ثم بين الصفات والأدوات. وفي عرض تحليل التَّنَاطُر بين السُّور السَّبع الطَّوَالِ؛ ظهرت السُّورَةُ السَّابِعَةُ (الأنفال والتوبة) متميزةً في استخدام الأفعال والأدوات، وتميزت السُّورَةُ الثَّالِثَةُ والرَّابِعَةُ والخامسة بالصفات، وتميزت كُلُّ السُّور عدا السُّورَةَ الثَّالِثَةَ بالأسماء.

الوجهة

أَوَّلُ مَا يَرُومُهُ القارئُ وَيَطْلُبُهُ فِي الإحصاءِ اللُّغَوِيِّ كَيْ يَتَغَيَّأَ تَطْبِيقَاتِهِ وَيَجِدَ فِي اسْتِخْدَامَاتِهِ هَوَانٌ يَتَأَلَّفُ مَعَ كُلِّ أُسْلُوبٍ مِنَ الأساليبِ الإحصائيةِ. اتَّجَهْ إِلَى التَّفْكِيرِ الإحصائيِّ؛ ذَلِكَ لِأَنَّهُ دَاعِمٌ قَوِيٌّ، وَرَادِفٌ مَتِينٌ لَمَّا يُرَادُ اسْتِنتَاجُهُ فِي التَّفْكِيرِ النَّوْعِيِّ، فَالتَّحْلِيلِ النَّوْعِيِّ وَوَسَائِلِ التَّفْكِيرِ لَمْ يَعُودَا كَافِيَيْنِ بِأَدَوَاتِهِمَا، وَلَنْ تَكُونَ مَقْبُولَةً إِنْ لَمْ تَرْتَكِزْ عَلَى تَفْكِيرِ إحصائيٍّ فِي مُسْتَقْبَلِ الأبحاثِ اللُّغَوِيَّةِ وَالإنْسَانِيَّةِ الَّتِي تَهْتَمُّ بِالمَادَّةِ اللُّغَوِيَّةِ. أَمَّا مَنْ يَقُولُ بِأَنَّ لُغَةَ الأرقامِ قَدْ تَخَدَعُ؛ فَإِنَّ الممارسينَ فِي علومِ البَيِّنَاتِ يُدْرِكُونَ مَا هُوَ صَحِيحٌ وَمَا هُوَ غَيْرُ صَحِيحٍ، فَعِلْمُ البَيِّنَاتِ بِالنَّسْبَةِ إِلَيْهِمْ لَيْسَ تَسْوِيقًا يُمَكِّنُ أَنْ يُمَارَسَ فِيهِ التَّضْلِيلُ.

التوصيات

المعرفةُ النَّظَرِيَّةُ للمُعَادَلَاتِ والخوارزمياتِ لَيْسَتْ مَطْلُوبَةً. المَطْلُوبُ معرفةُ كَيْفِيَّةِ عَمَلِ هذه المُعَادَلَاتِ والخوارزمياتِ معرفةً سَرَدِيَّةً، والقدرةُ عَلَى تَفْسِيرِ نَتَائِجِهَا. مِنَ الأهميةِ بِمَكَانٍ أَنْ تَتَنَاوَلَ الأبحاثُ اللُّغَوِيَّةُ الكَيْفِيَّةُ فِي العلومِ اللُّغَوِيَّةِ وَالإنْسَانِيَّةِ والاجتماعيةِ قَدْرًا مِنْ مَتَانَةِ التَّطْبِيقَاتِ الإحصائيةِ والمعالجةِ الآليَّةِ، وَأَنْ يَجْرِيَ التَّأَلُّفُ بِالممارسةِ المُستَمِرَّةِ مَعَ اسْتِخداماتِ التَّطْبِيقَاتِ والمعالجاتِ الوارِدةِ فِي هَذَا الكِتَابِ، إِذْ بَاتَتْ عَصَبَ الأبحاثِ والمشاريعِ فِي وَقْتِنَا الحَاضِرِ وَفِي الغَدِ مِنَ المُسْتَقْبَلِ عَلَى المُسْتَوَى العَالَمِيِّ. أَمَّا المُقْتَرَحَاتُ التَّطْبِيقِيَّةُ العِلْمِيَّةُ المُسْتَقْبَلِيَّةُ فَهِيَ مُفْتُوحَةٌ، مَا دَامَتْ مَادَّةُ التَّحْلِيلِ والمعالجةِ هِيَ (المدونةُ اللُّغَوِيَّةُ) الَّتِي تُمَثِّلُ اللُّغَةَ العَرَبِيَّةَ الطَّبِيعِيَّةَ المُنتَجَّةَ، الشَّفْهِيَّ مِنْهَا وَالمَكْتُوبَ، وَالمَاضِي مِنْهَا وَالحَاضِرَ، وَالفَصِيحَ مِنْهَا وَاللَّهْجِيَّ، وَالمَحَلِّيَّ مِنْهَا وَالدَّوَلِيَّ.

وَمِنْ أَهمِّ التَّوَصِيَّاتِ حَوْلَ مَا عُرِضَ مِنْ تَطْبِيقَاتِ إحصائيةٍ فِي البَابِ الأولِ مَا يَلِي:

أَوَّلًا: أَهمِيَّةُ تَطْبِيقَاتِ الإحصاءاتِ الوَصْفِيَّةِ قَبْلَ الإحصاءاتِ الاسْتِدْلَالِيَّةِ فِي البَيِّنَاتِ اللُّغَوِيَّةِ، إِذْ تَكْمُنُ أَهمِّيَّتُهَا فِي التَّكْشِيفِ الأَوَّلِيِّ للمَعْلُومَاتِ اللُّغَوِيَّةِ المُهمَّةِ حَوْلَ التَّكَرَّاراتِ وَالتَّوْزِيعِ وَالتَّنَوُّعِ وَالكثافةِ وَالتَّشَتُّتِ وَالقيَمِ المُتَطَرِّفَةِ.

ثانياً: أهمية الإفصاح عن أحجام التأثير المتعلقة بالإحصاءات الاستدلالية، فهي تُخبر عما إن كانت نتائج البيانات اللغوية المستخدمة في التحليل ذات تأثير أم لا.

ثالثاً: أهمية الإفصاح عن مجالات الثقة؛ كونها تُفيد بمدى الثقة بنتائج تحليل عينة البيانات اللغوية، وبمدى الثقة بتعميمها على المجتمع اللغوي.

رابعاً: توظيف مقاييس حساب التصاحب اللفظي المكوّنة من اثني عشر مُعاملاً بحسب الغرض من حالات الاستخدام، والاعتماد على تقنية مجموعة مقاييس التصاحب (collocation parameters notation) التي تُساعد على دقة ضبط مخرجات نتائج شبكات التصاحب اللفظي من البيانات اللغوية الكبيرة حجماً.

خامساً: التفكير الإحصائي الدقيق بنوعية المتغيرات اللغوية والمتغيرات التأويلية، وما يتفرّع منهما من متغيرات اسمية وترتيبية ومقياسية، سواء كان هذا التكفير منطلقاً من بيانات لغوية متوفرة أو من أسئلة بحثية تتطلب إعداداً وجمعاً وتهيئة للبيانات اللغوية الخاصة بها. وسواءً كان التحليل تحليلاً للارتباط، أو للتجميع، أو لمقارنة المجموعات، أو للتناظر، أو للانحدار، أو للبيانات اللغوية التاريخية والمعجمية، فالهم أن يكون جمع البيانات اللغوية وتهيئتها وتصميم هيكلتها قائماً على استيعاب المعلومات اللغوية في أعمدة البيانات وما يتمثّل فيها من أنواع المتغيرات.

ثانياً: عن تنقيب النصوص والبيانات العربيّة في الباب الثاني

النتيجة

أول ما يُرام تحقيقه -مرّة أخرى- هو أن يتألف اللغوي مع أساليب تعلّم الآلة في النصوص اللغوية العربيّة. ومن أهم ما ظهر من نتائج من خلال التحليل على مدونة القرآن؛ سهولة تعلّم الآلة للنص القرآني في إنشاء المتجهات (vectors) للكلمات، وقد لوحظ ذلك على الكلمات ذات التشابه الدلالي؛ مثل كلمة (هدى)، وقد يُعزى سبب ذلك إلى الكثافة المعجمية العالية، التي يحظى بها النص القرآني. من النتائج -أيضاً- عدم تفاوت الموضوعات في القرآن الكريم، فهي مترابطة ترابطاً تاماً بالقصص، والعبر،

والتَّشْرِيع، والجزاء، والعقاب، بالإضافة إلى غلبة استعمال التَّركيب الماضي على التَّركيب المضارع. من النَّتَاج -أيضاً- فيما يتعلَّق بأنظمة التَّوسيم النَّحْوِيَّ التَّفاوت بين الأنظمة، والحاجة إلى بناء معالجاتٍ أساسيةٍ أكثر دقَّةً؛ للتَّفريق، والتَّوسيم النَّحْوِيَّ، والتَّأصيل المعجمي، للنُّصوص العَرَبِيَّة القديمة، والنُّصوص العَرَبِيَّة المعاصرة. ومن النَّتَاج في سياق التَّصنيف والانْحِدَار الخَطِّي: أنَّ نماذج التَّصنيف للسُّور المكيَّة والمدنيَّة من حيث الزمن، والسُّور المكيَّة والمدنيَّة من حيث الحجم (الطويلة والمتوسطة والقصيرة)، مع ذكر لأسماء الأنبياء من عدم ذكر لها؛ قد جاءت متقاربة نوعاً ما في الدقَّة، بعد اختبارها على جزء لم تتعلم منه من هذه البيانات، وأكثر النماذج دقَّة كانت من آلة المتجهة الدَّاعمة، والانْحِدَار اللُّوجسِّي، والتَّعْزِيز التَّكْيَفي. أما نموذج الانْحِدَار الخَطِّي؛ فبعد تطبيقه على بياناتٍ مقياسيةٍ لترتيب السُّور الزمَني، وترتيبها في المصحف، وذكر اسم النَّبي من عدم ذكره، ووجود سجدة من عدم وجودها؛ فقد اختُبر النموذج على بيانات الاختبار، وظهر معيار خطأ عالٍ، وعدم وجود علاقة خطية. ولتحقيق العلاقة الخطية؛ يجب أن يُؤخذ في الحساب مسألة فرط التَّعميم (بيانات قليلة)، وفرط التَّخصيص (بيانات متباينة، وكثيرة، وبها قيم متطرفة)، أو: يُطبَّق الانْحِدَار اللاخطي الذي يُعطي شكل المنحنى الخطي الأكثر ملائمة مع نقاط البيانات. ومهما كانت النتيجة؛ لا بدَّ من الإفصاح عنها؛ لمعرفة طبيعة البيانات اللُّغوية المستخدمة للمعالجة، ومعرفة إمكانات البحث عن طرائق معالجة فرط التَّعميم أو التَّخصيص.

الوجهة

اتَّجه إلى معرفة الأسس التي بها تتعلَّم الآلة اللغة، وتفهمها، وتُنْتجها، فهذه آخر مَحْطَة يتطلَّب منك معرفتها اليوم. لا يحتاج اللُّغوي إلى معرفة بناء تطبيقات تعلَّم الآلة؛ لأنَّ ذلك من العمل المشترك بين المطوِّرين من مهندسي البرمجيات؛ ومهندسي البيانات، وعلماء البيانات، واللُّغويين الحاسوبيين، والممارسين في المَدَوَّنات اللُّغوية. يكفي أن يتعرَّف اللُّغوي إلى كلِّ الأنظمة والتَّطبيقات الجديدة التي تظهر، فتخدم البحث اللُّغوي، وترفع من جودة المشاريع اللُّغوية.

التوصيات

الحياة المستقبلية قائمة على الذكاء الاصطناعي، الذي يدخل في شؤون الحياة؛ ومنها اللغات، ومن هذه اللغات لغتنا العربية. من الضروري أن يكتسب غير المتخصص بالحاسب الآلي الأدوات التي تُعينه على إدراك أساليب تعلم الآلة، وفهمها، وإنتاجها للأشياء، كما نفهمها نحن ومنتجها. لقد أصبح التاريخي يهتم بهذه الأساليب وتقنياتها ليدير المعلومات الأرشيفية، وأصبح مدير الأعمال يهتم بها في تطوير الأعمال، وستجد الاهتمام بها في كل حقل من الحقول العلمية. ومن الضروري أن يتعرف اللغوي إلى معالجة اللغة الطبيعية، وإلى الأدوات البحثية؛ لمعالجة ما يُراد معالجته عن الظواهر اللغوية.

ومن أهم التوصيات حول ما عرض من تطبيقات المعالجة الآلية في الباب الثاني ما يلي:

أولاً: لابد من تصميم البيانات اللغوية وفق الهيكل المحدد في المبحث الأول من الفصل الأول (إعداد البيانات اللغوية في جدولة بيانات) كي تعمل أدوات تنقيب النصوص في أداة أوراج.

ثانياً: عند التعرف على وظيفة كل أداة في صندوق تنقيب النصوص والبيانات في أداة أوراج، تتحدد مهمة تحديد مسار العمل التحليلي وربط كل أداة بأخرى بتحديد مسار الغرض من المعالجة. وما قدمته من تطبيقات لمعالجة النص العربي ألياً يشكّل خمسة مسارات أساسية. الأول: مسار استخراج الكلمات المهمة باستخدام قياس (تكرار الكلمة - تكرار المستند العكسي)، ومسار استخراج الكلمات المفتاحية باستخدام نموذج الاستخراج الآلي السريع للكلمات المفتاحية RAKE المدمج في أداة أوراج. والثاني: مسار (تضمين الكلمات) الأكثر دقة من (حقيبة الكلمات) في نمذجة الكلمات ذات العلاقة دلائياً. والثالث: مسار استخراج الموضوعات التي تتمثل في الكلمات أو العبارات ذات المحتوى من بين النصوص والملفات النصية اللغوية. والرابع: التوسيم النحوي للكلمات الذي يُفيد بتحديد القسم الكلامي لكل كلمة في النصوص، واستكشاف الأنماط النحوية للعبارات والجمال القصيرة. والخامس: خوارزميات (التصنيف) التي تكشف مدى دقة

تعلم الآلة التصنيفي لأصناف المتغيّرات، وخوارزميات الانحدار التي تُقيّم مدى كفاءة الآلة في التنبؤ بقيم المتغيّرات المقياسيّة للقيم الحقيقية لها في البيانات.

ثالثاً: يعتمد تنقيب النصوص والبيانات اللغوية على نماذج إحصائية مثل نموذج (تكرار الكلمة-تكرار المستند العكسي) أو على نماذج اللغة language models مثل (حقيبة الكلمات، وتضمين الكلمات، ونمذجة الموضوعات). لابدّ من إدراك مسألة مهمة تتعلق بهذه النماذج، وهي في كونها نماذج غير نهائية، فنماذج اللغة المدمجة في أداة أورانج تمثل آخر النماذج المطوّرة، وتتطوّر هذه النماذج في الأداة نفسها في كل نسخة محدّثة بأداء أكثر دقة للمعالجة.

رابعاً: بُنيت مكوّنات أداة أورانج لتقنيب النصوص والبيانات بالاعتماد على تعلم الآلة، وهذا يعني أن الآلة ستعمل على مهام يصعب على الإنسان القيام بها، كمهمّة توسيم الكلمات النحويّة أو مهمّة استخراج الموضوعات النّصيّة في نصوص لغويّة تتضمّن عشرات الآلاف أو مئات الآلاف من الكلمات، غير أن ذلك يتطلّب من المستخدم أن يكون متفاعلاً مع نتائج هذه الأنظمة الآليّة، وذلك بتفسير مخرجات المعالجة الآليّة، وتمحيصها، وتحديد الأخطاء، كأن تُخطئ الآلة في توسيم كلمة ما نحويّاً، وهي أخطاء معدودة، يتمّ تقييمها وإيجاد حلول لغويّة /آليّة لها، نظراً للتطوّر الدائم والتّحسين المستمر لأداء هذه الأنظمة في المعالجة الآليّة للغة.

خامساً: استثمار هذه الأداة في الأبحاث العلميّة المتعلّقة بتحليل النصوص ومعالجتها، كون هذه النصوص جزءاً من البيانات التي تُجمع لأبحاث العلوم الاجتماعية والإنسانية واللغوية، وبخاصّة في المنهج الكيفي (النوعي) الذي سادت فيه معالجة الخصائص النّصيّة آليّاً، إذ أحدث العصر الرقمي نمواً متزايداً وهائلاً في النصوص المنتجة. وفي الوقت ذاته، تطوّرت أكثر الأساليب ذكاءاً للتحليل الآلي للنصوص، وإن لم تُوظف مثل هذه التّقنيات لمعالجة النصوص في الممارسات البحثيّة في تلك العلوم، فما نستوعبه فيها سيّتضاءل تضاهلاً كبيراً مع مرور الزمن.

المصادر والمراجع



الإحصاء وتقنيات الذكاء الاصطناعي
للبيانات اللغوية

المراجع العَرَبِيَّة والأجنبية

المراجع العَرَبِيَّة

- بريزينا، فاكلاف. علم الإحصاء في لُغَوِيَّات المَدَوَّنَةِ الحَاسُوبِيَّة. ترجمة: سلطان المجبول. دار جامعة الملك سعود للنشر، الرياض، الطبعة الأولى، ٢٠٢١.
- الجاسم، حوراء. الألفاظ الأكاديمية في المَدَوَّنَات العَرَبِيَّة العِلْمِيَّة: دراسة حاسوبية تحليلية. (رسالة ماجستير) إشراف: د. سلطان المجبول. قسم اللغة العَرَبِيَّة (جامعة الملك سعود)، ٢٠٢٢.
- الجاسم، حوراء، والمجبول، سلطان. المدونة الأكاديمية العربية (أواك) Academic Written Arabic Corpus AWAC (قائمة الجاسم والمجبول للألفاظ الأكاديمية وقوائم الجاسم والمجبول للمصطلحات العربية العلمية، ٢٠٢٢). الرابط: <https://www.arabic-ai.info/awac>
- الراجح، عبدالله. الترجمة الآلية. في: خوارزميات الذكاء الاصطناعي في تحليل النَّصِّ العَرَبِيِّ. مركز الملك عبدالله الدولي لخدمة اللغة العَرَبِيَّة (مركز الملك عبدالله بن عبدالعزيز للتخطيط والسياسات اللُّغَوِيَّة حاليًّا)، الرياض، الطبعة الأولى، ٢٠١٩، الصفحات ٦٩-٩٣.
- روبي، أحمد محمد. البنك الشجري النَّحْوِيِّ بناؤه وتوظيفه في إطار تقنيات الذكاء الاصطناعي، مركز الملك عبدالله الدولي لخدمة اللغة العَرَبِيَّة (مركز الملك عبدالله بن عبدالعزيز للتخطيط والسياسات اللُّغَوِيَّة حاليًّا)، الرياض، الطبعة الأولى، ٢٠١٧.
- السيوطي، جلال الدين عبدالرحمن بن أبي بكر. الإتقان في علوم القرآن. تحقيق: شعيب الأرنؤوط، مؤسسة الرسالة، دمشق، الجزء الأول، ٢٠٠٨.

- صالح، محمود إسماعيل. (٢٠١٥). المَدَوَّنَات اللُّغَوِيَّة وكيفية الإفادة منها. في: المَدَوَّنَات اللُّغَوِيَّة العَرَبِيَّة بناؤها وطرق الإفادة منها. مركز الملك عبدالله الدولي لخدمة اللغة العَرَبِيَّة (مركز الملك عبدالله بن عبدالعزيز للتخطيط والسياسات اللُّغَوِيَّة حاليًّا)، الرياض، الطبعة الأولى، ٢٠١٥.
- الصانع، وليد. طرق ومستويات معالجة اللغة في الذِّكَاء الاصطناعي. في: خوارزميات الذِّكَاء الاصطناعي في تحليل النِّص العَرَبِي. مركز الملك عبدالله الدولي لخدمة اللغة العَرَبِيَّة (مركز الملك عبدالله بن عبدالعزيز للتخطيط والسياسات اللُّغَوِيَّة حاليًّا)، الرياض، الطبعة الأولى، ٢٠١٩، الصفحات ١٥-٤٤.
- العصيمي، عبدالرحمن. نمذجة الكلمة العَرَبِيَّة: خوارزميات الذِّكَاء الاصطناعي في تحليل الكلمة العَرَبِيَّة لُغَوِيًّا وتوزيعيًّا. في: خوارزميات الذِّكَاء الاصطناعي في تحليل النِّص العَرَبِي. مركز الملك عبدالله الدولي لخدمة اللغة العَرَبِيَّة (مركز الملك عبدالله بن عبدالعزيز للتخطيط والسياسات اللُّغَوِيَّة حاليًّا)، الرياض، الطبعة الأولى، ٢٠١٩، الصفحات ٩٥-١٢٤.
- الغامدي، أيمن. تقنيات الذِّكَاء الاصطناعي والمعالجة الحاسوبية للمتلازمات اللُّفْظِيَّة والتراكيب الاصطلاحية. في: خوارزميات الذِّكَاء الاصطناعي في تحليل النِّص العَرَبِي. مركز الملك عبدالله الدولي لخدمة اللغة العَرَبِيَّة (مركز الملك عبدالله بن عبدالعزيز للتخطيط والسياسات اللُّغَوِيَّة حاليًّا)، الرياض، الطبعة الأولى، ٢٠١٩، الصفحات ١٢٥-١٦٧.
- الغزالي، أبو حامد. إحياء علوم الدين. صححه: محمد بن مسعود الأحمدي. عالم الكتب للطباعة والنشر، بيروت، الطبعة الأولى، ٢٠٠٥.
- القنيعير، فارس. التعلم العميق وتطبيقاته في معالجة اللغة. في: خوارزميات الذِّكَاء الاصطناعي في تحليل النِّص العَرَبِي. مركز الملك عبدالله الدولي لخدمة اللغة العَرَبِيَّة (مركز الملك عبدالله بن عبدالعزيز للتخطيط والسياسات اللُّغَوِيَّة حاليًّا)، الرياض، الطبعة الأولى، ٢٠١٩، الصفحات ٤٤-٦٨.

- لحج، محمد. مدخل إلى الذكاء الاصطناعي وتعلم الآلة. أكاديمية حاسوب، المملكة المتحدة، الطبعة الأولى، ٢٠٢٠.
- المجبول، سلطان. البحث اللغوي في المدونات العريية الحاسوبية بين الممكن والمحتمل والمأمول. في: المدونات اللغوية العريية بناؤها وطرق الإفادة منها. مركز الملك عبدالله الدولي لخدمة اللغة العريية (مركز الملك عبدالله بن عبدالعزيز للتخطيط والسياسات اللغوية حالياً)، الرياض، الطبعة الأولى، ٢٠١٥.
- المجبول، سلطان. الفهرسة الدلالية الكامنة وتخصيص دركليه الكامن لنمذجة موضوعات الشعر العريي عبر العصور. مجلة اللسانيات العريية، العدد ١٤، ٢٠٢٢، الصفحات ٥٧-٨٠.
- مكانري، توني، وأنندرو هاردي. لغويات المدونة الحاسوبية: المنهج والنظرية والتطبيق. ترجمة: سلطان المجبول. الرياض: دار جامعة الملك سعود للنشر، ٢٠١٦.

المراجع الإنجليزية

- Abdelali, A., Darwish, K., Durrani, N., & Mubarak, H. (2016). Farasa: A Fast and Furious Segmenter for Arabic. NAACL.
- Almujaivel, S. (2020). An Overview of the Lexical Variation Between Arabic Lexicons and Natural Arabic Language. International Journal of Arabic Linguistics, 6(1 & 2). 91-107.
- Almujaivel, S. (2020). A Comparative Evaluation of POS Tagging and N-Gram Measures in Arabic Corpus Resources and Tools. International Journal of Computational Linguistics, 11(1). 1-17.
- Almujaivel, S. (2019). Grammatical construction of function words between old and modern written Arabic: A corpus-based analysis. Corpus Linguistics and Linguistic Theory, 15(2). 267-296.
- Brezina, V., McEnery, T., & Wattam, S. (2015). Collocations in context: A new perspective on collocation networks. International Journal of Corpus Linguistics, 20(2), 139-173.
- Brezina, V., Timperley, M., & McEnery, T. (2018). #LancsBox v. 4.x [software]. Available at: <http://corpora.lancs.ac.uk/lancsbox>.
- Brezina, V., Weill-Tessier, P., & McEnery, A. (2020). #LancsBox v. 5.x. [software]. Available at: <http://corpora.lancs.ac.uk/lancsbox>.
- Cohen, J. (1988). Statistical power analysis for the behavioral sciences. Hillsdale, NJ: Erlbaum.
- Darwish, K., & Mubarak, H. (2016). Farasa: A New Fast and Accurate Arabic Word Segmenter. LREC-2016.
- Darwish, K., Mubarak, H., Abdelali, A., & Eldesouki, M. (2017). Arabic pos tagging: Don't abandon feature engineering just yet. In Proceedings of the Third Arabic Natural Language Processing Workshop, (pp. 130-137). Association for Computational Linguistics.
- Divjak, D. & Gries, S. Th. (2006). Ways of trying in Russian: clustering behavioral profiles. Corpus Linguistics and Linguistic Theory, 2(1), 23-60.

- Dukes, K. (2009-2017). The Quranic Arabic Corpus [An Open-Source Project]. Available at: <https://corpus.quran.com>.
- Duque, Tiago. (2020). Peeling Natural Language Processing Layer by Layer: An Introductory Overview. In Medium [web source]. Available at: <https://tfduque.medium.com/dissecting-natural-language-processing-layer-by-layer-an-introductory-overview>.
- Gries, S. Th., Newman, J., Shaoul, C. & Dilts, P. (2009). N-grams and the clustering of genres. Presented at workshop on Corpus, Colligation, Register Variation at the 31st Annual Meeting of the Deutsche Gesellschaft für Sprachwissenschaft, March.
- Haugen, E. (1966). Dialect, language, nation. *American Anthropologist*, 68, 922–935.
- Haugen, E. (1972). Language planning, theory and practice. In E. Haugen (Ed.), *The ecology of language: Essays* (pp. 287–295). Stanford: Stanford University Press.
- Haugen, E. (1987). Blessings of Babel. *Bilingualism and language planning. Problems and pleasures*. Berlin, New York: Mouton de Gruyter.
- Jarrar, M. (2021). The Arabic Ontology – An Arabic Wordnet with Ontologically Clean Content. *Applied Ontology* 16(1), 1-26.
- Kramer, A. D. I., Guillory, J. E., & Hancock, J. T. (2014). Experimental evidence of massive-scale emotional contagion through social networks. *Proceedings of the National Academy of Sciences*, 111(24), 8788-8790.
- Lancaster Stats Tools Online (Toolbox). (2018). Available at: <http://corpora.lancs.ac.uk/stats/toolbox.php>.
- Lavin, M. J. (2019). Analyzing Documents with TF-IDF [Online Lessons]. In: Z. LeBlanc (Ed.), *The Programming Historian*. <https://doi.org/10.46430/phen0082>.
- Maamouri, M., Bies, A., Buckwalter, T., & Mekki, W. (2004). The Penn Arabic Treebank: Building a Large-Scale Annotated Arabic Corpus. Paper presented in the Proceedings of the NEMLAR International Conference on Arabic Language Resources and Tools, (pp. 102-109). Cairo, Egypt.
- Manning, Christopher D., Mihai Surdeanu, John Bauer, Jenny Finkel, Steven J. Bethard, and David McClosky. (2014). The Stanford CoreNLP Natural Language Processing Toolkit. In *Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics: System Demonstrations*, (pp. 55-60). Baltimore.

- Miner, G., Elder, J., Fast, A., Hill, Th., Nisbet, R., & Delen, D. (2012). Practical Text Mining and Statistical Analysis for non-Structured Text Data Applications. Elsevier, pp. 3-28.
- Mitkov, R. (ed.), (2022). The Oxford Handbook of Computational Linguistics. Oxford University Press, 2nd edition.
- Mubarak, H. (2018). Build Fast and Accurate Lemmatization for Arabic. Paper presented in the International Conference on Language Resources and Evaluation LREC-2018, Miyazaki.
- Parkinson, D., 2001. arabiCorpus. Available at: <https://arabicorpus.byu.edu/>.
- Pasha, A., Al-Badrashiny, M., Diab, M., El Kholi, A., Eskander, R., Habash, N., Pooleery, M., Rambow, O., & Roth, R. (2014). MADAMIRA: A Fast, Comprehensive Tool for Morphological Analysis and Disambiguation of Arabic. In Proceedings of the Ninth International Conference on Language Resources and Evaluation (LREC'14). 1094–1101.
- Peng Qi, Yuhao Zhang, Yuhui Zhang, Jason Bolton and Christopher D. Manning. (2020). Stanza: A Python Natural Language Processing Toolkit for Many Human Languages. In Association for Computational Linguistics (ACL) System Demonstrations. Online.
- Qui, X., Sun, T., Xu, Y., Shao, Y., Daj, N., Huang, X. (2020). Pre-trained models for natural language processing: A survey. Science China Technological Sciences, 63, 1872-1897.
- Scott, M. (2020). WordSmith Tools version 8 [Lexical Analysis Software]. Available at: <https://lexically.net/wordsmith>.
- Sinclair, S., & Rockwell, G. (2022). Voyant Tools [v. 2.5.3]. Available at: <https://voyant-tools.org>.
- Sketch Engine: Create and Search a Text Corpus. (2004-2021). Available at: <https://www.sketchengine.eu/>.
- Stanford NLP Group. (2020). Stanford CoreNLP (Arabic) [Model Jar]. Available at <https://stanfordnlp.github.io/CoreNLP/>.
- Stanford NLP Group. (2020). Using CoreNLP with other programming languages and packages. Available at <https://stanfordnlp.github.io/CoreNLP/other-languages.html>

- Taji, D., Habash, N., & Zeman, D. (2017). Universal Dependency for Arabic. In Proceedings of the Third Arabic Natural Language Processing Workshop (WANLP), pp. 166-176, Association for Computational Linguistics, Stroudsburg, PA, USA.
- Taji, D., Khalifa, S., Obeid, O., Eryani, F., Habash, N. (2018). An Arabic Morphological Analyzer and Generator with Copious Features. Proceedings of the Fifteenth Workshop on Computational Research in Phonetics, Phonology, and Morphology, October (pp. 140-150). Brussels (Belgium): Association of Computational Linguistics.
- Tarp, S. (2011). Lexicographical and Other e-Tools for Consultation Purposes: Towards the Individualization of Needs Satisfaction. In P. A. Fuertes-Olivera & H. Bergenholtz (Eds.), e-Lexicography: The Internet, Digital Initiatives and Lexicography, (pp. 54-79). London, New York: Continuum.
- Tsujii, J. (2021). Natural Language Processing and Computational Linguistics. Computational Linguistics, 47(4), 707-727.
- Veltri, G. A. (2020). Digital Social Research. Medford, MA: Polity Press.

الملاحق

موسسة الأبحاث
والدراسات
العلمية

الإحصاء وتقنيات الذكاء الاصطناعي
للبيانات اللغوية

الملحق (أ): إحصاءات القرآن الكريم

اسم السُورَة	ترتيب التُّرُود	ترتيب المصحف	عدد الآيات	زمن التُّرُود	السَّجْدَة	الكَلِمَات	الحروف
الفاتحة	5	1	7	مكية مدنية	0	29	139
البقرة	87	2	286	مدنية	0	6144	25613
آل عمران	89	3	200	مدنية	0	3503	14605
النساء	92	4	176	مدنية	0	3712	15937
المائدة	112	5	120	مدنية	0	2837	11892
الأَنْعَام	55	6	156	مكية	0	3055	12418
الأعراف	39	7	206	مكية	1	3344	14071
الأنفال	88	8	75	مدنية	0	1243	5299
التوبة	113	9	129	مدنية	0	2506	10873
يونس	51	10	109	مكية	0	1841	7425
هود	52	11	123	مكية	0	1947	7633
يوسف	53	12	111	مكية	0	1795	7125
الرعد	96	13	43	مدنية	1	854	3450
إبراهيم	72	14	52	مكية	0	831	3461
الحجر	54	15	99	مكية	0	658	2797
النحل	70	16	128	مكية	1	1845	7642
الإسراء	50	17	111	مكية	1	1559	6480
الكهف	69	18	110	مكية	0	1583	6425
مريم	44	19	98	مكية	1	972	3835
طه	45	20	135	مكية	0	1354	5288
الأنبياء	73	21	112	مكية	0	1174	4925
الحج	103	22	78	مدنية	1	1279	5196
المؤمنون	74	23	118	مكية	0	1051	4354
النور	102	24	64	مدنية	0	1317	5596
الفرقان	42	25	77	مكية	1	896	3786

اسم السُورَة	ترتيب التُّرُود	ترتيب المصحف	عدد الآيات	زمن التُّرُود	السَّجْدَة	الكَلِمَات	الحروف
الشعراء	47	26	227	مكية	0	1322	5517
النمل	48	27	93	مكية	1	1165	4679
القصص	49	28	88	مكية	0	1441	5791
العنكبوت	85	29	69	مكية	0	982	4200
الروم	84	30	60	مكية	0	818	3388
لقمان	57	31	34	مكية	0	550	2121
السَّجْدَة	75	32	30	مكية	1	374	1523
الأحزاب	90	33	73	مدنية	0	1303	5618
سبأ	58	34	54	مكية	0	884	3510
فاطر	43	35	45	مكية	0	780	3159
يس	41	36	83	مكية عدا آية	0	733	2988
الصفاء	56	37	182	مكية	0	865	3790
ص	38	38	88	مكية	1	735	2991
الزمر	59	39	75	مكية	0	1177	4741
غافر	60	40	85	مكية	0	1228	4984
فصلت	61	41	54	مكية	1	796	3282
الشورى	62	42	53	مكية	0	860	3431
الزخرف	63	43	89	مكية	0	837	3508
الدخان	64	44	59	مكية	0	346	1439
الجاثية	65	45	37	مكية	0	488	2014
الأحقاف	66	46	35	مكية	0	646	2602
محمد	95	47	38	مدنية	0	542	2360
الفتح	111	48	29	مدنية	0	560	2456
الحجرات	106	49	18	مدنية	0	353	1493
ق	34	50	45	مكية	0	373	1473
الذاريات	67	51	60	مكية	0	360	1510
الطور	76	52	49	مكية	0	312	1293

اسم السُورَة	ترتيب التَّزْوِيل	ترتيب المصحف	عدد الآيات	زمن التَّزْوِيل	السَّجْدَة	الكَلِمَات	الحروف
الط	23	53	62	مكية	1	359	1405
القمر	37	54	55	مكية	0	342	1438
الرحمن	97	55	78	مدنية	0	352	1585
الواقعة	46	56	96	مكية	0	379	1692
الحديد	94	57	29	مدنية	0	575	2475
المجادلة	105	58	22	مدنية	0	475	1991
الحشر	101	59	24	مدنية	0	447	1913
المتحنة	91	60	13	مدنية	0	352	1519
الصف	109	61	14	مدنية	0	226	936
الجمعة	110	62	11	مدنية	0	177	749
المنافقون	104	63	11	مدنية	0	180	780
التغابن	108	64	18	مدنية	0	242	1066
الطلاق	99	65	12	مدنية	0	279	1170
التحریم	107	66	12	مدنية	0	254	1067
الملك	77	67	30	مكية	0	337	1316
القلم	2	68	52	مكية	0	301	1258
الحاقة	78	69	52	مكية	0	261	1107
المعارج	79	70	44	مكية	0	217	947
نوح	71	71	28	مكية	0	227	947
الجن	40	72	28	مكية	0	286	1089
المزمل	3	73	20	مكية	0	200	840
المدثر	4	74	56	مكية	0	256	1015
القيامة	31	75	40	مكية	0	164	664
الإنسان	98	76	31	مدنية	0	243	1065
المرسلات	33	77	50	مكية	0	181	815
النبا	80	78	40	مكية	0	174	766
النازعات	81	79	46	مكية	0	179	762

اسم السورة	ترتيب النزول	ترتيب المصحف	عدد الآيات	زمن النزول	السجدة	الكلمات	الحروف
عبس	24	80	42	مكية	0	133	538
التكوير	7	81	29	مكية	0	104	425
الانفطار	82	82	19	مكية	0	81	326
المطففين	86	83	36	مكية	0	169	740
الانشقاق	83	84	25	مكية	1	108	436
البروج	27	85	22	مكية	0	109	459
الطارق	36	86	17	مكية	0	61	249
الأعلى	8	87	91	مكية	0	72	293
الغاشية	68	88	62	مكية	0	92	378
الفجر	10	89	30	مكية	0	139	573
البلد	35	90	20	مكية	0	82	335
الشمس	26	91	15	مكية	0	54	249
الليل	9	92	21	مختلف فيها	0	71	312
الضحى	11	93	11	مكية	0	40	164
الشرح	12	94	8	مكية	0	27	102
التين	28	95	8	مكية	0	34	156
العلق	1	96	19	مكية	1	72	281
القدر	25	97	5	مكية	0	30	112
البينة	100	98	8	مدنية	0	94	394
الزلزلة	93	99	8	مدنية	0	36	156
العاديات	14	100	11	مكية	0	40	164
القارعة	30	101	11	مكية	0	36	158
التكاثر	16	102	8	مكية	0	28	122
العصر	13	103	3	مكية	0	14	70
الهمزة	32	104	9	مكية	0	33	133
الفيل	19	105	5	مكية	0	23	96
قريش	29	106	4	مكية	0	17	73

اسم السُورة	ترتيب النُّزول	ترتيب المصحف	عدد الآيات	زمن النُّزول	السَّجدة	الكَلِمات	الحروف
الماعون	17	107	7	مكية	0	25	112
الكوثر	15	108	3	مكية	0	10	42
الكاغرون	18	109	6	مكية	0	27	95
النصر	114	110	3	مدنية	0	19	79
المسد	6	111	5	مكية	0	29	81
الإخلاص	22	112	4	مكية	0	15	47
الفلق	20	113	5	مكية	0	23	71
الناس	21	114	6	مكية	0	20	80

الملحق (ب): أقسام الكلام في القرآن الكريم

	الوسم	الوصف	التكرار	النسبة المئوية
1	NN	أسماء شائعة	22559	25.79
2	P	الأدوات (أدوات الربط وحروف الجر وأسماء الإشارة والضمائر والظروف وأدوات النصب والجزم)	20777	23.76
3	Noun	اسم علم مفرد واسم معرف وأسماء التوكيد	17614	20.14
4	VBD	فعل تام	8911	10.19
5	VBP	فعل مضارع	6619	7.57
6	JJ	الصفات	2953	3.38
7	WP	الأسماء الموصولة	2885	3.30
8	DTNNS	اسم معرف مثنى أو جمع	1370	1.57
9	NNS	اسم مثنى أو جمع	1275	1.46
10	DTJJ	الصفات المعرفة	609	0.70
11	DTNNP	اسم علم معرف مفرد	500	0.57
12	VBN	فعل مبني للمجهول	421	0.48
13	VBG	مصدر عامل / أداة فعل	375	0.43

الوسم	الوصف	التكرار	النسبة المئوية
14	VB	فعل أمر	364
15	WRB	أدوات الاستفهام	123
16	JJR	صفات المقارنة	93
17	DTJJR	الصفات المعرفة للمقارنة	9

الملحق (ج): أكواد التَّحْلِيل الإِحْصَائِي لِلْبَيِّنَات اللُّغَوِيَّة

بيئة البرمجة (آر)

الفصل الأول الأشكال البيانية

● المَخَطَّط الدَّرَجِي histogram

```
#Histogram
hist(x, breaks="Sturges", col = "gray", xlab = "linguistic variable", main=
"Histogram")
```

● مَخَطَّط الصَّنْدُوق (أو رسم المربع) boxplot

```
#Boxplot
boxplot(myData, ylab = "linguistic variable",
xlab="(sub)corpora", outline = FALSE, ylim=c(0, max(myData, na.r
m=TRUE)*1.05)); l = 1;while(l <= ncol(myData))
{
for(v in myData[,l]){points(jitter(l,3/i),v, col = "blue", pch
=1, cex = 1));
points(l, mean(myData[,l],trim = 0, na.rm = TRUE), col = "red"
, pch="_", cex = 4) i= i+1;
```

● أعمدة الخطأ error bars: مجال الثقة ٩٥٪

```
#Error bars
error.bars(myData,stats=NULL, ylab = "linguistic variable",xlab="(sub)corpora",
main=NULL,eyes=FALSE, ylim = NULL,
xlim=NULL,alpha=.05,sd=FALSE, labels = NULL, pos = NULL, arrow.len =
0.05,arrow.col="red", add = FALSE,bars=FALSE,within=FALSE, col="red")
```

● مخطط التشتت scatter plot

```
#Scatter plot with regression line
plot(myData); fitline <- lm(myData[,2] ~ myData[,1]); abline(fitline,col="red")
```

● مخطط خطي line chart

```
#Line chart
matplot(myData, type = c("myData"),pch=1, ylab="linguistic variable(s)",
xaxt = "n", col = 1:4); axis(1, at=x, labels=v)
```

● الخريطة الجغرافية geomapping

```
#Geomapping
library(maps); library(mapdata)#load libraries
map('worldHires',xlim=c((min(myData[,1])-5),(max(myData[,1])+5)),
ylim=c((min(myData[,2])-5),(max(myData[,2])+5)));
i=1;while(i<=length(myData[,1])){points(myData[i,1],myData[i,2],
col=2,pch=19, cex=(4*(myData[i,3]/x)+0.5)); i<-i+1;};")
```

● مخطط الأعمدة المرسوفة stacked barchart

```
#Stacked barchart
matplot(myData, type = c("myData"),pch=1, ylab="linguistic variable(s)",
xaxt = "n", col = 1:4); axis(1, at=x, labels=v)
```

● خطوط المؤشر sparklines

```
#Sparklines
par(mrow=c(4,1),mar=c(5,7,4,2),omi=c(0.2,2,0.2,2)); for(l in 1:4){x=round(mean(b[,l]),2)
;plot(b[,l],ann=FALSE,axes=FALSE,type="l",col="gray",lwd=2);
mtext(side=2,at=x,names(b[,l]),las=2,col="black");
mtext(side=4,at=x,x,las=2,col="black");
points(which.min(b[,l]),min(b[,l]),pch=19,col="blue");
points(which.max(b[,l]),max(b[,l]),pch=19,col="red");}
```

● مخطط الشموع candlestick plot

```
#Candlestick plot
#Prepare data
min<-apply(s, 2, min)
min<-as.vector(min)
max<-apply(s, 2, max)
max<-as.vector(max)
first<-head(s,1)
first<-as.numeric(first[1,])
last<-tail(s,1)
last<-as.numeric(last[1,])
int_1<-ifelse(first<=last,first,last)
int_2<-ifelse(last>=first,last,first)
dir<-ifelse(first<=last,1,0)
dir<-as.vector(dir)
item<-colnames(s)
item<-as.vector(item)
order<-seq_along(item)
data <- data.frame(order, item, min, int_1, int_2, max, dir)
#Creat plot
with(data,symbols(order, (int_1+ int_2)/2, boxplots=cbind(.25,int_2-
```

```
int_1, int_1-min,max-int_2,0),inches=F,ylim=range(data[, -
c(1:2)]),xaxt="n",ylab="Relative frequency", xlab="Linguistic
variables", bg = ifelse(dir==0, "black", "white")); data<-
data[with(data, order(order)),];
axis(1,seq_along(data$item),labels=FALSE);
text(x=seq_along(data$item), y=par()$usr[3]-0.05*(par()$usr[4]-
par()$usr[3]), labels=data$item, srt=15, adj=1, xpd=TRUE;
```

الفصل الثاني

● حساب موافقة المقدّر البيئي

```
gwet.ac1.raw(myData)
myData1<-table(myData); kappa2.table(myData1)
#Nominal 3 + raters
fleiss.kappa.raw(myData)
#Ordinal
gwet.ac1.raw(myData, weights="ordinal")
#Scale
ICC(myData)
```

الفصل الثالث

● الارتباط

```
#Libraries correlation
library(Hmisc)
library(corrplot)
library(stats)
#Pearson's correlation:
cor.test(mydata1, mydata2, method="pearson")
#Spearman's correlation
```



```
cor.test(mydata1, mydata2, method="spearman")
#Correlation matrix
rcorr(mydata, type="pearson")
#Scatter plot
plot(mydata, col ="blue"); fitline <lm(mydata1 ~ mydata2); abline(fitline,col="red")
#Correlation matrix
corrplot(m, method ="color", type = "full", diag = TRUE, addCoef.col="black", add
CoefasPercent=FALSE, addgrid.col="grey", tl.pos = NULL, tl.cex = 1, tl.srt = 45, tl.
col = "black")
```

• التجميع

```
#Optional z-score transformation
mydata <- scale(mydata)
#Distance matrix
d <- dist(mydata, method = "manhattan")
#Cluster analysis
fit <- hclust(d, method="ward.D")
#Plot dendrogram
plot(fit, xlab="", ylab="Height", main="")
#Draw cluster groups
rect.hclust(fit, k=5, border="red")
```

• مقارنة المجموعات

```
#t-test
t.test(data[,1], data[,2], paired=FALSE)
#t-test: repeated measures
t.test(data[,1], data[,2], paired=TRUE)
#Mann-Whitney-wilcoxon rank sum test
wilcox.test(data[,1], data[,2], paired=FALSE)
#Mann-Whitney-Wilcoxon rank sum test: repeated measures
```

```
wilcox.test(data[,1], data[,2], paired=TRUE)
#One-way ANOVA
aov(measurement ~ group, data = data)
#Kruskal-Wallis test
kruskal.test(data)
```

● تحليل التناظر

```
library(languageR);
x = corres.fnc(data);
plot(x, ccex = 0.6, rcex = 0.6)
```

الفصل الرابع

● الانحدار الخطي

```
#Libraries and data
install.packages('tidyverse')
library(tidyverse)
mydata <- read.csv("C:\\Users\\snmuj\\Downloads\\ mydata.csv")
data <- mydata %>% select(characters, verses, words, chronology)
install.packages('Ggally')
library(Ggally)
ggpairs(data)
model <- lm(data=ar, characters ~ verses + words + chronology)
summary(model)
model$coefficients
model$residuals[0:10]
model$fitted.values[0:10]
ggplot(data = ar, aes(x = verses, y = characters)) + geom_point()
ggplot(data = ar, aes(x = words, y = characters)) + geom_point()
```

```
ggplot(data = ar, aes(x = chronology, y = characters)) + geom_point()
install.packages("ggfortify")
library(ggfortify)
autoplot(model, which = 1:2)
install.packages("stargazer")
library(stargazer)
stargazer(model, type = "html", out = "my model.doc")
stargazer(model, type = "html", out = "my model.doc")
```

الفصل الخامس

● القيم والقصور

```
library(ggplot2)
library(mgcv)
p<-ggplot(data, aes(x = data[,1], y =data[,2])) + geom_point() + xldata("Time") + yldata("Linguistic variadatale"); p + stat_smooth(method = "gam", formula = y ~ s(x, datas = "cr", fx=FALSE, k =15), size = 1, fill="#707070", level = 0.95 )+ stat_smooth(method = "gam", formula = y ~ s(x, datas = "cr", fx=FALSE, k =15), size = 1, fill="#FFFF00", level = 0.99)
```

● التَّأرجح الاستعمالي

```
#Calculate Gwet's AC1; b...input data frame
l = 1; v <- c(); while(i+1 < ncol(b)) {n=(gwet.ac1.raw(b[,l:(i+2)]))[3];v<- c(v, n); i= i+1; }
#Prepare data frame
h<-seq(from, to, by = 1); g<-data.frame(h,v) #Produce graph
p<-ggplot(g, aes(x = g[,1], y =g[,2])) + xlim(from, to)+ scale_x_continuous(breaks = seq(from, to, by = 10)) + geom_point() + xlab("Time") + ylab("AC1"); p + stat_smooth(method = "gam", formula = y ~ s(x, bs = "cr", fx=FALSE, k =10), size = 1, fill="#707070", level = 0.95 )+ stat_smooth(method = "gam", formula = y ~ s(x, bs = "cr", fx=FALSE, k =10), size = 1, fill="#FFFF00", level = 0.99)
```

الملحق (د): أكواد حساب تكرار الكلمة-تكرار المستند العكسي

بيئة (بايثون)

```
from pathlib import Path

all_txt_files = []
for file in Path("...FolderPath").rglob("*.txt"):
    all_txt_files.append(file.parent / file.name)
# Counts the length of the list
n_files = len(all_txt_files)
print(n_files)

all_txt_files.sort()
all_txt_files[0]

all_docs = []
for txt_file in all_txt_files:
    with open(txt_file) as f:
        txt_file_as_string = f.read()
    all_docs.append(txt_file_as_string)

vectorizer = TfidfVectorizer(max_df=.65, min_df=1, stop_words=None, use_
idf=True, norm=None)
transformed_documents = vectorizer.fit_transform(all_docs)

transformed_documents_as_array = transformed_documents.toarray()

# represent the numpy array
len(transformed_documents_as_array)
```

```
# Construct a list of output file paths
output_filenames = [str(txt_file).replace(".txt", ".csv").replace("txt", "tf_idf_
output/") for txt_file in all_txt_files]

# Loop each item in transformed_documents_as_array
for counter, doc in enumerate(transformed_documents_as_array):
    # construct a dataframe
    tf_idf_tuples = list(zip(vectorizer.get_feature_names(), doc))
    one_doc_as_df = pd.DataFrame.from_records(tf_idf_tuples, columns=['term', 'score']
).sort_values(by='score', ascending=False).reset_index(drop=True)
    # Output to a csv
    one_doc_as_df.to_csv(output_filenames[counter])
```

الملحق (ه): أول خمسين كلمة من حساب تكرار الكلمة- تكرار المستند العكسي

مدنية			مكية		
النتيجة	الكلمة	التسلسل	النتيجة	الكلمة	التسلسل
43.56941835	تكذبان	0	60.43499965	قومه	0
29.51476727	اعلموا	1	30.92023238	خلقنا	1
16.8655813	حدود	2	30.92023238	يوسف	2
16.8655813	اليتامى	3	26.70383705	المجرمين	3
15.46011619	المسيح	4	25.29837195	نجزي	4
14.05465108	الأعراب	5	23.89290684	آلهة	5
14.05465108	يجدون	6	23.89290684	سلطان	6
14.05465108	بيوت	7	23.89290684	أهلكتنا	7
14.05465108	إنما	8	23.89290684	الملا	8

مدنية			مكية		
النتيجة	الكلمة	التسلسل	النتيجة	الكلمة	التسلسل
14.05465108	نساء	9	22.48744173	كذبا	9
14.05465108	تتقوا	10	21.08197662	عباد	10
12.64918597	قاتلوا	11	19.67651151	الآخرين	11
12.64918597	لبئس	12	19.67651151	يستهزئون	12
12.64918597	المساكين	13	18.27104641	جاءت	13
12.64918597	النصارى	14	18.27104641	أرايتم	14
12.64918597	أحل	15	18.27104641	أليس	15
12.64918597	تفعلوا	16	18.27104641	ذكرى	16
11.24372086	الحج	17	18.27104641	أدراك	17
11.24372086	تنفقوا	18	18.27104641	نادى	18
11.24372086	أطعنا	19	18.27104641	توعدون	19
11.24372086	بأموالهم	20	16.8655813	بشرا	20
11.24372086	رضوان	21	16.8655813	اليمين	21
11.24372086	اليهود	22	16.8655813	نجعل	22
11.24372086	الفتنة	23	16.8655813	الغفور	23
11.24372086	القتال	24	16.8655813	للمكذبين	24
9.838255757	سورة	25	15.46011619	أمين	25
9.838255757	يخلفون	26	15.46011619	تكذبون	26
9.838255757	أذى	27	15.46011619	عين	27
9.838255757	اشتروا	28	15.46011619	فاصبر	28
9.838255757	لعنهم	29	15.46011619	أسألكم	29

مدنية			مكية		
النتيجة	الكلمة	التسلسل	النتيجة	الكلمة	التسلسل
9.838255757	يأمرون	30	15.46011619	أوحي	30
9.838255757	المحصنات	31	15.46011619	السمع	31
9.838255757	خفتم	32	14.05465108	تنزيل	32
9.838255757	المنافقون	33	14.05465108	آياتي	33
9.838255757	عزيزا	34	14.05465108	قومك	34
9.838255757	ماتوا	35	14.05465108	يوعدون	35
9.838255757	الخبيث	36	14.05465108	أباؤنا	36
9.838255757	الريا	37	14.05465108	أجري	37
9.838255757	فاسقون	38	14.05465108	تعالى	38
8.432790649	التواب	39	14.05465108	الصور	39
8.432790649	يؤتيه	40	14.05465108	الوعد	40
8.432790649	يأمركم	41	14.05465108	لوطا	41
8.432790649	إيمانكم	42	14.05465108	بأسنا	42
8.432790649	الصدقات	43	14.05465108	فعل	43
8.432790649	الهدي	44	14.05465108	يغني	44
8.432790649	وصية	45	14.05465108	لقاء	45
8.432790649	يعذبهم	46	14.05465108	القرون	46
8.432790649	يكتمون	47	12.64918597	عذابي	47
8.432790649	مؤمنة	48	12.64918597	تبصرون	48
8.432790649	يطع	49	12.64918597	عظاما	49

الملحق (و): تدريب واختبار التَّوسيم النَّحويِّ العَرَبِيِّ للاعتِماديَّات الكُلِّيَّة

الواسمات النَّحويَّة: <https://universaldependencies.org/u/pos>.

بيئة البرمجة (بايثون): كُلّ مربع يمثِّل مدخلاً مستقلاً.

```
import nltk
nltk.download('all')
from nltk.corpus import treebank
```

```
penn_treebank = []
for fileid in treebank.fileids():
    tokens = []
    tags = []
    for word, tag in treebank.tagged_words(fileid):
        tokens.append(word)
        tags.append(tag)
    penn_treebank.append((tokens, tags))
```

```
#Install conllu package
!pip install conllu
!wget https://lindat.mff.cuni.cz/repository/xmlui/bitstream/handle/11234/1-3105/ud-
treebanks-v2.5.tgz
!tar xzf ud-treebanks-v2.5.tgz

#Imports needed to open and parse the conllu file
from io import open
from conllu import parse_incr
```



```
#Open the file
data_file = open("/content/ud-treebanks-v2.5/UD_Arabic-PADT/ar_padt-ud-train.
conllu", "r", encoding="utf-8")
ud_files = []
for tokenlist in parse_incr(data_file):
    ud_files.append(tokenlist)

#List of tuples with a list of words and a list of their PoS tags
ud_treebank = []
for sentence in ud_files:
    tokens = []
    tags = []
    for token in sentence:
        tokens.append(token['form'])
        tags.append(token['upostag'])
    ud_treebank.append((tokens, tags))
```

```
import re
def extract_features(sentence, index):
    return {
        'word':sentence[index],
        'is_first':index==0,
        'is_last':index ==len(sentence)-1,
        'is_capitalized':sentence[index][0].upper() == sentence[index][0],
        'is_all_caps': sentence[index].upper() == sentence[index],
        'is_all_lower': sentence[index].lower() == sentence[index],
        'is_alphanumeric': int(bool((re.match('^(?=.*[0-9]$)(?=.*[a-zA-
Z])',sentence[index])))),
        'prefix-1':sentence[index][0],
        'prefix-2':sentence[index][:2],
```

```

'prefix-3':sentence[index][:3],
'prefix-3':sentence[index][:4],
'suffix-1':sentence[index][-1],
'suffix-2':sentence[index][-2:],
'suffix-3':sentence[index][-3:],
'suffix-3':sentence[index][-4:],
'prev_word': "if index == 0 else sentence[index-1],
'next_word': "if index < len(sentence) else sentence[index+1],
'has_hyphen': '-' in sentence[index],
'is_numeric': sentence[index].isdigit(),
'capitals_inside': sentence[index][1:].lower() != sentence[index][1:]
}

```

#returning the data as two lists

def transform_to_dataset(tagged_sentences):

X, y = [], []

for sentence, tags in tagged_sentences:

sent_word_features, sent_tags = [], []

for index in range(len(sentence)):

sent_word_features.append(extract_features(sentence, index)),

sent_tags.append(tags[index])

X.append(sent_word_features)

y.append(sent_tags)

return X,

#for UD Treebank

ud_train_size = int(0.8*len(ud_treebank))

ud_training = ud_treebank[:ud_train_size]

ud_testing = ud_treebank[ud_train_size:]

X_ud_train, y_ud_train = transform_to_dataset(ud_training)

X_ud_test, y_ud_test = transform_to_dataset(ud_testing)

```
#Ignoring some warnings
import warnings
warnings.filterwarnings('ignore')
```

```
#Install sklearn_crfsuite, as it is not preloaded into Colab
!pip install sklearn_crfsuite
from sklearn_crfsuite import CRF
#CRF for UD
ud_crf = CRF(
    algorithm='lbfgs',
    c1=0.01,
    c2=0.1,
    max_iterations=100,
    all_possible_transitions=True
)
print("Started training on UD corpus!")
ud_crf.fit(X_ud_train, y_ud_train)
print("Finished training on UD corpus!")
```

```
#Output for UD
print("## UD ##")
from sklearn_crfsuite import metrics

y_ud_pred=ud_crf.predict(X_ud_test)
print("F1 score on Test Data ")
print(metrics.flat_f1_score(y_ud_test, y_ud_pred,average='weighted',labels=ud_crf.
classes_))

y_ud_pred_train=ud_crf.predict(X_ud_train)
print("F1 score on Training Data ")
```

```
print(metrics.flat_f1_score(y_ud_train, y_ud_pred_train, average='weighted', labels=
ud_crf.classes_))
```

```
## UD ##
```

```
F1 score on Test Data
```

```
0.9370593011076455
```

```
F1 score on Training Data
```

```
0.9894871290659856
```

```
from sklearn.preprocessing import MultiLabelBinarizer
```

```
mlb1 = MultiLabelBinarizer()
```

```
a = mlb1.fit_transform([ud_crf.classes_])
```

```
y_test_matrix = mlb1.transform(y_ud_test)
```

```
y_pred_matrix = mlb1.transform(y_ud_pred)
```

```
### Look at class wise score
```

```
print("Class wise score:")
```

```
from sklearn import metrics
```

```
print(metrics.classification_report(y_test_matrix, y_pred_matrix, target_names=ud_
crf.classes_, digits=3))
```

```
Class wise score:
```

	precision	recall	f1-score	support
X	0.986	0.981	0.983	996
VERB	0.999	0.997	0.998	1032
NOUN	0.962	0.948	0.955	134
ADJ	0.938	0.920	0.928	261
ADP	1.000	0.995	0.998	884
PUNCT	0.962	0.993	0.977	436

NUM	0.000	0.000	0.000	0
	1.000	0.999	1.000	1202
PRON	0.990	0.987	0.989	479
CCONJ	0.889	0.909	0.899	132
DET	0.991	0.997	0.994	632
PART	1.000	0.444	0.615	18
ADV	1.000	1.000	1.000	992
SYM	0.000	0.000	0.000	4
AUX	0.986	0.994	0.990	985
PROPN	0.928	0.817	0.869	931
INTJ	0.990	1.000	0.995	980
micro avg	0.984	0.973	0.979	10098
macro avg	0.860	0.822	0.835	10098
weighted avg	0.983	0.973	0.978	10098
samples avg	0.982	0.972	0.976	10098

sent = "ضع جملةً من عندك"

features = [extract_features(sent.split(), idx) for idx in range(len(sent.split()))]

#Make a prediction on a single input (sentence).

ud_results = ud_crf.predict_single(features)

ud_tups = [(sent.split()[idx], ud_results[idx]) for idx in range(len(sent.split()))]

#The results

print(ud_tups)

نبذة عن المؤلف

سلطان بن ناصر المجيول، أستاذ اللسانيات الحاسوبية بقسم اللغة العربية وآدابها في كلية العلوم الإنسانية والاجتماعية بجامعة الملك سعود. حصل على درجة الدكتوراه من جامعة إكسيتر (بريطانيا) في لسانيات المدونة الحاسوبية في عام ٢٠١٣م، وعلى دورات احترافية في مجالات الإحصاء اللغوي وتقنيات الذكاء الاصطناعي. نشر ٣٠ بحثاً علمياً، من بينها أربعة كتب، وأبحاث في مجلات Web of Science. فاز بالمركز الثاني في جائزة الترجمة ضمن الجوائز الثقافية الوطنية (وزارة الثقافة السعودية) في دورتها الأولى ٢٠٢٠-٢٠٢١م. مدرب معتمد، ومحكم لعدد من المشاريع العلمية والتطبيقية في مجالات اللسانيات العربية الحاسوبية، وتطبيقات الذكاء الاصطناعي اللغوي، والإحصاء اللغوي، والسياسة اللغوية والتخطيط.



نبذة عن الكتاب

يهدف هذا الكتاب إلى ترقية المشاريع البحثية في العلوم اللغوية والإنسانية والاجتماعية، وإلى التشجيع على ممارسة تطبيقات الإحصاء اللغوي وتقنيات تنقيب البيانات اللغوية. وقُدِّمت هذه التطبيقات والتقنيات بأسلوب بسيط ومباشر، وأُجريت على مدونة القرآن الكريم، بغية تسهيل استيعاب إجراءات التحليل والتمرس بها. ينقسم الكتاب إلى بابين. الأول: الإحصاء اللغوي، والثاني: تنقيب النصوص والبيانات العربية. وفي كل باب فصول ومباحث تُفيد القارئ بالخطوات التحليلية بأدوات قائمة بذاتها، وقد ضُمّت حزم هذه الأدوات ومكتباتها في الملاحق المرتبطة بمباحثها من أجل الرجوع إليها عند الحاجة.



9 786038 413920

هذه الطبعة
إهداء من المجمع
ولا يُسمح بنشرها ورقياً أو تداولها تجارياً

