

محاضرة 6: تحليل النصوص الاجتماعية (مفهومياً)

تبدأ القصة من حقيقة بسيطة: النصوص هي المادة الخام لجزء كبير من الحياة الاجتماعية—من منشورات ومنديات ورسائل عمومية إلى مقابلات ميدانية وتقارير رسمية. حين ندخل هذه النصوص إلى أدوات الذكاء الاصطناعي، فإننا لا “نستخرج الحقيقة” من داخلها تلقائياً بقدر ما نبني **طرائق منظمة** للقراءة والتلخيص ورصد الأنماط، تساعدنا على التفكير بسرعة واتساع أكبر، بشرط أن نبقي واعين لحدود الأدوات والسياقات الثقافية واللغوية التي صيغت فيها تلك النصوص. (Jurafsky & Martin, 2023; Grimmer & Stewart, 2013)

لذلك ستمشي معاً طريقاً متدرجاً: كيف تُمثل النصوص داخل الحاسوب؟ ماذا تفعل الخوارزميات حين “تلخص” أو “تستخرج كلمات محورية” أو “ترصد مشاعر وثيمات”؟ أين تتفوق هذه الأدوات وأين تضلّنا، خصوصاً مع السخرية والدلالة الثقافية والازدواج اللغوي؟ وكيف نُبقي الإنسان—الخبير الاجتماعي—في الحلقة بوصفه الضامن للمعنى والعدالة؟

حين يتعامل الحاسوب مع النص، يبدأ بتحويله إلى **تمثيل عددي** يستطيع معالجته. أبسط تلك التمثيلات يعدّ الكلمات وحدات منفصلة ويحصى تكرارها أو “أهميتها” في الوثيقة مقارنةً بغيرها فيما يُشبه “بصمة لغوية”؛ وقد تطوّرت هذه الفكرة من عدّ الكلمات الخام إلى أوزانٍ تعكس تميّز الكلمة في سياقها. (Manning & Schütze, 1999)

لاحقاً ظهرت تمثيلات تُسند لكل كلمة **متجهًا** يلتقط علاقاتها الدلالية—كقرب “عمل” من “وظيفة” وابتعاد “عمل” عن “شمس”—فصار بإمكان الحاسوب قياس تشابه المعاني لا مجرد تشابه الشكل (Mikolov, Chen, Corrado, & Dean, 2013) وتوّج هذا المسار بتمثيلات **سياقية** تجعل معنى الكلمة تابعاً للجملة التي وردت فيها، كما في نماذج “بيرت”، بحيث يختلف تمثيل كلمة “العين” إن كانت عضواً بصرياً أو نبع ماء (Devlin, Chang, Lee, & Toutanova, 2019). هذه الفكرة التقنية مهمّة اجتماعياً لأنها تفسّر لماذا تُقلّت السخرية والتهكّم من خوارزميات بسيطة تعتمد القواميس، ولماذا تتحسن النتائج عندما نستخدم تمثيلات تراعي **السياق الحي** للغة.

الانتقال من النص الخام إلى “نتيجة مفيدة” يمرّ عادة بمحطات واضحة: تنظيف أولي يحدف الضجيج غير الدلالي، وتجزئة النص إلى جمل وكلمات، وتطبيق للكتابة واختلافات الإملاء، مع انتباه خاص للغات ذات تنوع لهجي واسع كاللغة العربية، حيث تختلط الفصحى بالمحكية وتشيع الكتابة الصوتية والرموز الهجينة. (Habash, 2010) هنا تكمن إحدى المزالق الخفية: إذا تجاهلنا **التنوع اللهجي والازدواجية** سنسقط على النصوص قوالب لا تناسبها، فتتعطل القراءة الآلية عند حدودٍ لا يراها إلا من خبر الحقل اللغوي والاجتماعي. ولهذا السبب كثيراً ما يلجأ الباحثون إلى **الترجمة** حين تكون الأدوات العربية أضعف؛ غير أنّ الترجمة نفسها تُدخل تحويرات في المعنى

وتطمس مفاتيح ثقافية وإشارية يصعب استعادتها لاحقًا. (Hovy & Spruit, 2016) الخيار المنهجي الأكثر أمانًا هو الاعتراف بهذه القيود في التقرير، ومواءمة الأدوات أو **تكيفها محليًا** بقدر المستطاع، ثم إسناد النتائج دائمًا إلى قراءة بشرية نقدية.

عندما نطلب من الأداة "تلخيصًا"، فنحن في الحقيقة نختار بين طريقتين: **تلخيص انتزاعي** يعيد صياغة مقاطع أساسية من النص الأصلي ويجمعها في فقرة ممرضة، و**تلخيص توليدي** يصوغ عبارات جديدة مستخلصة من المعنى الكلي للنص. الأول أكثر أمانًا لأنه يبقى "قريبًا" من الأصل، أما الثاني فأوسع قدرةً على التصرف لكنه معرضٌ لخطر **اختلاق حقائق** أو "ملء فجوات" غير موجودة أصلاً، وهي ظاهرة موثقة في بحوث التلخيص الحديثة. (Maynez, Narayan, Bohnet, & McDonald, 2020) في البحث الاجتماعي، يُستحسن التعامل مع أي تلخيص مولد بوصفه **مسودة أولى** تُساعد على رؤية الصورة الكبيرة، لا نصًا مُعتمدًا جاهزًا للنشر، وأن يُرفق—كلما أمكن—بإشارات إلى الجمل الأصلية التي استند إليها كي يسهل التحقق البشري.

أما القول إن الأداة "ترصد المشاعر"، فله أيضًا وجهان. من جهة، يمكن لخوارزميات "رأي/لا رأي" أو "موجب/سالِب/محايد" أن تمنحنا نظرة سريعة إلى **مزاج عام** في مجموعة كبيرة من النصوص، وقد أسست لهذا المجال أعمال مبكرة راسخة. (Pang & Lee, 2008) لكن من جهة أخرى، تمتلئ اللغة اليومية بأقنعة سخرية وتهكم ومجاز، وتشيع فيها **الازدواجية المقصودة** في البيانات الإلكترونية تحديدًا، ما يجعل قراءة الانفعال الآلية هشة في كثير من الحالات. (Reyes, Rosso, & Veale, 2013) لهذا تُعتبر "قراءة المشاعر" مفيدة كإشارة اتجاه عام، لا كحكم فردي أو سندٍ وحيد لصناعة قرار، ويزداد الخطر عندما تمسّ القرارات فئات هشة أو يختلط التقييم الانفعالي بالأثر الاجتماعي للألفاظ. الحل المنهجي هو تثبيت هذه الحدود في التقارير، ودمج الرصد الكمي بمراجعة نوعية انتقائية لنماذج نصوص موثقة، بحيث نتحقق من أن ما تسميه الخوارزمية "غضبًا" أو "سخرية" هو بالفعل كذلك في سياق الجماعة المدروسة.

وحيث نقول إن الأداة "تستكشف الثيمات"، فنحن غالبًا نعني أساليب تُوازن بين **الانتظام الإحصائي وقابلية التفسير**. يقدم "نمذجة الموضوعات الاحتمالية" مثالًا شائعًا: الخوارزمية تبحث عن تجمعاتٍ من الكلمات كثيرًا ما تأتي معًا، وتعتبر كل تجمعٍ "موضوعًا" يتوزع بدرجات متفاوتة على الوثائق، فيظهر لنا الهيكل الخفي للنقاشات الكبرى داخل المجموعة. (Blei, 2012) غير أنّ "الموضوع" هنا ليس كيانًا جاهزًا في النص بقدر ما هو افتراض إحصائي يحتاج تسميات بشرية دقيقة وتدقيقًا صارمًا؛ وقد بيّن بحث مبكر أنّ الناس قد يختلفون جوهريًا في تفسيرهم لمخرجات النماذج إن لم تُقدّم بعناية ومع أمثلة ممثلة (Chang, Gerrish, Wang, Boyd-Graber, & Blei,

(2009) لذا يوصي الباحثون الاجتماعيون بأن تُحرّر "خريطة الموضوعات" كمنطلق للأسئلة، لا كمآل يقيني للقراءة، وأن تُربط دائماً بعينات نصية وحجج تفسيرية وباختبارات متانة، بل وبمقابلات لاحقة تسأل المشاركين أنفسهم: هل تمثل هذه الثيمات رؤيتكم حقاً؟ (Grimmer & Stewart, 2013).

في الطرف المقابل من "الثيمات" الآلية يقف الترميز النوعي—وهو صميم الحرفة في التحليل الاجتماعي للمقابلات والنصوص الطويلة. يمكن للأدوات الذكية أن تساعد في اقتراح أكواد أولية وجمع اقتباسات ممثلة لكل كود وتلخيص فقرات متشابهة، لكنها لا تُغني عن دفتر الشفرة الذي يكتبه الباحثون بأنفسهم، ولا عن اتفاق المرّمين على معنى كل فئة. من هنا تأتي أهمية اتفاق المقيمين بوصفه شرطاً لموثوقية القراءة: هل نصل نحن البشر إلى قرارات متقاربة عندما نقرأ النص نفسه وفق الدليل ذاته؟ تُقاس هذه الفكرة بمؤشرات راسخة مثل كاتبا لاتساق قارئين اثنين، وألفا كريبندورف حين يزيد العدد أو تختلف مستويات القياس، وهي مقاييس لا تهدف إلى "تكميم" النقاش بقدر ما تضبط شفافية العملية وتمنع الانزلاق إلى أحكام فردية غير قابلة للمراجعة (Cohen, 1960; Krippendorff, 2018). عملياً، يمكن استخدام النماذج اللغوية الكبيرة لتوليد مسودة ترميز ثم اختبارها على عينة صغيرة يقارنها مرّزان بشريان مستقلان، وتراجع الشفرة بناءً على مواضع الخلاف، قبل توسيع التطبيق على كامل المتن.

التقييم في هذا المجال يجب أن يطابق الغرض الاجتماعي. فإذا كنّا نبحث عن تغطية ثيمائية صادقة، فيهمنا أن نرى كيف تغيرت الثيمات مع الزمن أو بين المجموعات، ونراجع يدويّاً أمثلة حدودية كي لا تُسقط الخوارزمية ظللاً نمطية على جماعة كاملة. وإذا كنّا نحتاج تصنيفاً تشغيلياً سريعاً لفرز آلاف الرسائل، فنسوازن بين التقاط الحالات المهمة وبين إطلاق إنذارات كاذبة، ونراقب الأداء عبر الفئات حتى لا تتحوّل الأداة إلى مُعيد لإنتاج اللامساواة (Sokolova & Lapalme, 2009; Hovy & Spruit, 2016). وعلى أي حال، يبقى الاختبار الأهم هو المعايرة على الواقع: عندما تقول الأداة "احتمال 70% أن تكون هذه شكوى"، هل يعني ذلك أنّ سبعة من كل عشرة نصوص بهذه العلامة هي فعلاً شكاوى عند الفحص البشري؟ إن لم يكن، فالأداة تخذعنا بأرقام "ذكية" لكنها غير صادقة عملياً. (Niculescu-Mizil & Caruana, 2005).

يُضاف إلى ما سبق بُعدٌ أخلاقي ومنهجي لا ينفصل عن التقنية. فالنصوص تحمل بداخلها علاقات قوة—من يتكلم، ولمن، وتحت أي شروط—وتحمل معها بصمات الهوية والطبقة والنوع الاجتماعي. إن تعاملنا معها كـ"بيانات خام" محايدة أغفلنا هذه العلاقات وعرضنا فئات هشة للأذى الرمزي والمادي (Hovy & Spruit, 2016; boyd & Crawford, 2012). لذلك ظهرت ممارسات توثيق مسؤولة مثل بيانات وصفية للبيانات اللغوية توضح من أين

جاءت النصوص ولمن تمثّل، وما حدود استخدامها، وما المخاطر الأخلاقية المرتبطة بها، وهي ما عُرف بـ“بيانات للبيانات” في علم اللغة الحاسوبي. (Bender & Friedman, 2018) ويُستحسن إقران ذلك بنمط توثيق أشمل مثل **Datasheets for Datasets** الذي يضع سياسات واضحة للاستخدام والقيود والجمهور المقصود، إضافةً إلى أطر للمساءلة تضمن وجود مسار تظلم عند وقوع الضرر. (Gebru et al., 2021; Raji et al., 2020) عند هذه النقطة يتضح الفرق بين أداة مساعدة وبديل للمحلّل: الأولى تُسهّم في التنظيم والتسريع وتوسيع الرؤية، والثانية وهم يُقرّم المعنى الاجتماعي إلى أرقام بلا سياق.

لنجعل الصورة ملموسة، تخيل مجموعة مقابلات عن **بطالة الشباب** في مدينة واحدة. إذا تركنا أداة التلخيص تُنتج نصًا أنيقًا دون إسناد للجمل الأصلية، فقد تُخفي تناقضات لافتة بين المشاعر بالعار الشخصي والالتهام النبوي للسياسات. وإذا اعتمدنا “تحليل مشاعر” سريعًا، فقد تُصنّف مزحات مُرّة وسخرية لاذعة على أنها “إيجابية” لأنها تُستعمل ألفاظًا ساخرة من قبيل “الحمد لله الأمور تمام!”، فيتبدّد المعنى الاجتماعي للنص. (Reyes et al., 2013) وإذا طبقنا نمذجة موضوعات على عينة صغيرة جدًا أو غير ممثّلة، فقد نُقدّم إلى صانع قرار “خريطة ثيمات” تُضخّم أصوات مجموعة نشطة على الشبكات وتتجاهل آخرين غائبين عن المنصة (Grimmer & Stewart, 2013). الطريق المسؤول يبدأ بتوثيق مصدر النصوص وتمثيلها، ثم استخدام الأدوات بوصفها **مقترحات منظّمة**، ثم العودة إلى النصوص نفسها وإلى الميدان لضبط التفسير، وأخيرًا نشر النتائج مع حدودها وسيناريوهات سوء الاستخدام المحتملة.

الخلاصة أن تحليل النصوص الاجتماعية بالذكاء الاصطناعي ينجح حين نتعامل معه **كفنّ للتقريب**: تقريب المعنى عبر تمثيلات تراعي السياق، وتقريب الرؤية عبر تلخيصات شفافة قابلة للتحقق، وتقريب الهيكل عبر موضوعات تُراجع بشريًا، وتقريب القرار عبر مقاييس أداء صادقة اجتماعيًا لا رقمية فحسب. لا تسعى هذه الأدوات إلى إحلال الإنسان، بل إلى توسيع أفقه وتشذيبه—بشرط أن يظلّ **المعنى والسياق والعدالة** هي البوصلة من أول خطوة إلى آخر تقرير. (Grimmer & Stewart, 2013; Jurafsky & Martin, 2023)

قائمة المراجع

1. Bender, E. M., & Friedman, B. (2018). Data statements for natural language processing: Toward mitigating system bias and enabling better science. *Transactions of the ACL*, 6, 587–604.
2. Blei, D. M. (2012). Probabilistic topic models. *Communications of the ACM*, 55(4), 77–84.

3. boyd, d., & Crawford, K. (2012). Critical questions for Big Data. *Information, Communication & Society*, 15(5), 662–679.
4. Chang, J., Gerrish, S., Wang, C., Boyd-Graber, J., & Blei, D. M. (2009). Reading tea leaves: How humans interpret topics in topic models. *NeurIPS*, 288–296.
5. Cohen, J. (1960). A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, 20(1), 37–46.
6. Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of deep bidirectional transformers for language understanding. *NAACL-HLT*, 4171–4186.
7. Grimmer, J., & Stewart, B. M. (2013). Text as data: The promise and pitfalls of automated content analysis. *Political Analysis*, 21(3), 267–297.
8. Habash, N. (2010). *Introduction to Arabic natural language processing*. Morgan & Claypool.
9. Hovy, D., & Spruit, S. L. (2016). The social impact of natural language processing. *ACL*, 591–598.
10. Jurafsky, D., & Martin, J. H. (2023). *Speech and language processing* (3rd ed., draft).
11. Manning, C. D., & Schütze, H. (1999). *Foundations of statistical natural language processing*. MIT Press.
12. Maynez, J., Narayan, S., Bohnet, B., & McDonald, R. (2020). On faithfulness and factuality in abstractive summarization. *ACL*, 1906–1919.
13. Mikolov, T., Chen, K., Corrado, G., & Dean, J. (2013). Efficient estimation of word representations in vector space. *arXiv:1301.3781*.
14. Niculescu-Mizil, A., & Caruana, R. (2005). Predicting good probabilities with supervised learning. *ICML*, 625–632.
15. Pang, B., & Lee, L. (2008). Opinion mining and sentiment analysis. *Foundations and Trends in Information Retrieval*, 2(1–2), 1–135.
16. Raji, I. D., Smart, A., White, R. N., Mitchell, M., Gebru, T., et al. (2020). Closing the AI accountability gap. *FAccT 2020*, 33–44.
17. Reyes, A., Rosso, P., & Veale, T. (2013). A multidimensional approach for detecting irony in Twitter. *Language Resources and Evaluation*, 47(1), 239–268.
18. Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427–437.

