

محاضرة 2: البيانات كوقود — مصادرهما، جودتها، وتحيزاتها

تمهيد

لا ينتج الذكاء الاصطناعي معرفته من الفراغ؛ ما يقدمه يعتمد مباشرةً على نوعية البيانات التي يتعلم منها. في العلوم الاجتماعية، تأتي هذه البيانات من استطلاعات الرأي، والمقابلات، والملاحظة الميدانية، والسجلات الإدارية، وآثارنا الرقمية على المنصات. عندما تكون البيانات ناقصة أو غير ممثلة لجميع الفئات، تنعكس هذه العيوب على قرارات تمس حياة الناس مثل توزيع الدعم أو قبول الطلاب أو توجيه الوظائف (O'Neil, 2016; Crawford, 2021). لذلك سنجيب هنا عن ثلاثة أسئلة مترابطة: من أين تأتي البيانات؟ وكيف نقيس جودتها؟ وما أبرز مصادر التحيز وكيف نخفف آثارها. (Groves et al., 2009; boyd & Crawford, 2012)

(1) ما المقصود بالبيانات الاجتماعية؟ ولماذا تُسمى «وقودًا»؟

البيانات الاجتماعية هي تمثيلات منظمة لوقائع المجتمع: قد تكون أرقامًا عن الدخل والعمر والبطالة، وقد تكون نصوصًا من مقابلات وملاحظات ووثائق. هي «وقود» لأن أي نموذج آلي يتعلم أنماطًا من الماضي ليقترح مخرجات في الحاضر؛ فإذا كان الوقود ملوثًا—أي منحازًا أو ضعيف الجودة—فإن «المحرك» سينتج قرارات مضللة حتى لو بدا أداءه مرتفعًا بالأرقام. (Salganik, 2017; Russell & Norvig, 2020) فكرة محورية هنا: جودة القرار الخوارزمي لا يمكن أن تتجاوز جودة بياناته؛ مهما كانت الخوارزمية متقدمة، ستعيد إنتاج ما في البيانات من قوة أو قصور. (boyd & Crawford, 2012)

(2) من أين نجمع البيانات؟ (مصادر رئيسية وملاحظات منهجية)

الاستطلاعات والاستبيانات مصدر تقليدي واسع الانتشار. لكن جودتها تتأثر بتصميم العينة، وصياغة الأسئلة، وطريقة التنفيذ (هاتفي، وجاهي، عبر الويب). الاستبيانات الإلكترونية مريحة وسريعة، لكنها غالبًا اختيار ذاتي؛ أي من يملكون وقتًا أو اتصالًا أفضل يشاركون أكثر، ما يخلق تحيز تغطية يستبعد من لا يستخدمون المنصة أصلًا (Groves et al., 2009; Bethlehem, 2010).

المقابلات والملاحظة الميدانية تمنحنا سياقًا ومعنى لا يمكن للأرقام وحدها التقاطه. جودة هذا النوع تُقاس بمفاهيم مثل المصدقية والاعتمادية والقابلية للنقل؛ وتتحسن عبر «التثليث» أي تنويع المصادر والباحثين وطرق الجمع، مع الالتزام بالخصوصية والسرية (Kvale & Brinkmann, 2009; Lincoln & Guba, 1985; Denzin, 1978).

السجلات الإدارية والبيانات الحكومية المفتوحة تتميز بالاتساع والانتظام الزمني، لكنها وُضعت لأغراض إدارية لا بحثية؛ قد تفقر لمتغيرات مهمة أو تعكس تصنيفات مؤسسية تاريخياً منحازة. (Salganik, 2017) أما الآثار الرقمية على المنصات (تفاعلات، منشورات، مواقع) فتعكس سلوكاً «فعلياً» داخل المنصة، لكنها لا تمثل المجتمع كله وتثير أسئلة ترخيص وخصوصية؛ كما أن خوارزميات المنصات نفسها تؤثر في ما نراه ونجمعه. (boyd & Crawford, 2012)

(3) كيف نقيس «جودة» البيانات؟ (أبعاد مفهومة بلا تعقيد)

للبيانات الكمية، يمكن التفكير في خمس زوايا بسيطة: الدقة أي قرب القياس من الحقيقة، الاكتمال أي قلّة القيم المفقودة والمتغيرات الناقصة، الاتساق أي ثبات التعاريف عبر المصادر والسنوات، الحدّثة أي مواكبة الواقع وليس الماضي فقط، والتمثيل أي شمول الفئات والمناطق والأعمار بعدالة. (Groves et al., 2009) هذه الأبعاد ليست درجات امتحان منفصلة؛ بل سلّة نزنّها بحسب غرضنا البحثي. أما للبيانات النوعية، فالجودة تعني مصداقية السرد عبر التثليث، واعتمادية الإجراءات عبر أثر تدقيقي واضح، وقابلية النقل عبر وصفٍ سياقي غني يسمح للقارئ بفهم أين تنطبق النتائج وأين لا تنطبق، مع اعتبارات أخلاقية صارمة للموافقة وإخفاء الهوية (Lincoln & Guba, 1985; Kvale & Brinkmann, 2009; Denzin, 1978).

(4) أين تتسلّل التحيزات؟ (خريطة مبسّطة للأخطاء الشائعة)

تحيزّ التغطية والاختيار الذاتي يظهر حين لا تتاح الفرصة بالتساوي للجميع للمشاركة—كاستطلاع يعتمد تطبيقاً واحداً يستبعد من لا يملكون هواتف ذكية. النتيجة: صورة منحازة تبدو واثقة لأنها «مدعومة بالأرقام» (Bethlehem, 2010).

تحيزّ عدم الاستجابة يحدث عندما يرفض بعض الناس المشاركة لأسباب منهجية (انشغال، عدم ثقة، خوف)، فيختلفون عن المشاركين بخصائص مؤثرة، فنتشوّه النتائج. (Groves et al., 2009) تحيزّ القياس يجيء من سؤال موجّه أو صياغة ملتبسة أو أداة غير معاييرة لغويّاً وثقافياً، فيدخل الخطأ في صلب الإجابة. (Groves et al., 2009)

وعلى امتداد دورة حياة الذكاء الاصطناعي قد تظهر فئات تحيزّ إضافية: انحياز تاريخي في البيانات، تمثيل ناقص لفئات، وسم متحيزّ عند عنونة النصوص، أهداف غير منصفة عندما نختار معياراً يؤدي فئة بلا داع، ثم تحوّل

التوزيع بعد النشر حين يتغير العالم ويظل النموذج على حاله. (Suresh & Guttag, 2021) الفكرة أن التحيز ليس حادثاً عارضاً بل نسق متسلسل يمكن أن يبدأ قبل النمذجة ويمتد بعدها.

5) لماذا تختفي بعض القيم؟ وكيف نتعامل مع «الفراغات»؟

اختفاء البيانات له آليات مختلفة تؤثر في الحل المناسب. قد تكون المعلومة مفقودة عشوائياً تماماً وهو نادر اجتماعياً، أو مفقودة بشكل يعتمد على معلومات مرصودة كأن يغيب الدخل غالباً بين الشباب أكثر من غيرهم، أو مفقودة بشكل يعتمد على قيمة غير مرصودة كأن يحجب ذوو الدخل المرتفع معلوماتهم بشكلٍ منهجي (Little & Rubin, 2019). حذف السجلات عشوائياً حلٌ سهل لكنه قد يزيد الانحياز. بدلاً من ذلك، نلجأ إلى الإكمال المتعدد الذي يملأ القيم بطريقة إحصائية محافظة مع الإفصاح عن الافتراضات، ثم نجري تحليلات حساسية لتأكد من متانة النتائج. (van Buuren, 2018)

6) كيف نخفف المشكلات ونوثق عملنا بشفافية؟

الطريق العملي يجمع بين المنهجية الجيدة والشفافية. يبدأ ذلك بتصميم عينة واعٍ بالسياق مع قنوات للوصول إلى الفئات صعبة الوصول، ثم إن لزم الأمر نستخدم التوزين والمعايرة لتصحيح بعض الاختلالات—مع التحذير من حدود هذه المعالجات. (Groves et al., 2009) نُحسن القياس بتجريب الصياغات وترجمة ثقافية مدروسة وتدريب باحثين ميدانيين. بعد الجمع، نوثق كل شيء عبر **Datsheets for Datasets** لماذا جُمعت البيانات؟ لمن صُممت؟ من الغائب؟ ما حدود الاستخدام الأخلاقي؟. (Gebru et al., 2021) وعند بناء النماذج، نُصدر **Model Cards** توضح بيانات التدريب والأداء العام والطبقي وحدود التعميم والاستخدامات غير المستحسنة. (Mitchell et al., 2019) وأخيراً، نضع مسارات مراجعة أخلاقية وتظلم واضحة بعد النشر. (Raji et al., 2020).

7) مثال تطبيقي واضح: استطلاع «الاندماج الطلابي» عبر تطبيق واحد

تقرّر جامعة قياس «الاندماج الطلابي» بواسطة استبيان في تطبيقها الرسمي. في الظاهر يبدو الأمر حديثاً ومنظماً، لكن هناك مشكلتان. الأولى: من لا يستخدمون التطبيق—مثل طلبة الدوام الجزئي أو من خلفيات محدودة الدخل—يغيّبون عن العينة، فبنشأ تحيز تعظية. الثانية: من لديهم تجارب سلبية قد يتجنبون المشاركة، فبنشأ تحيز عدم الاستجابة. النتيجة أن قرارات الدعم قد تُوجّه لمن يظهرون في البيانات أكثر، لا لمن يحتاجونها أكثر. الحلول ليست معقدة: قنوات بديلة ورقية وهاتفية وميدانية، تصميم عينة مكافئة طبقيًا، وزن لاحق لتصحيح الاختلالات

المعروفة، وصياغات أسئلة مجرّبة لغويًا وثقافيًا. (Bethlehem, 2010; Groves et al., 2009). والأهم أن يُذكر هذا كله صراحة في **Datasheet** مع قيود التعميم.

(8) لماذا نجمع بين الكمي والنوعي؟

البيانات الكمية تمنحنا نطاقًا واسعًا ومقارنات دقيقة عبر الزمن والفئات، لكنها قد تُسطّح الخبرات. البيانات النوعية تمنحنا المعنى والسياق وتكشف ما لا يظهر في الأرقام، لكنها محلية بطبيعتها. الجمع بينهما في تصميم مختلط يوفّر فهمًا أعمق ويكشف تحيزات كان يمكن أن تبقى مخفية لو اعتمدنا منهجًا واحدًا (Salganik, 2017; Lincoln & Guba, 1985). وفي سياق «الاندماج الطلابي»، تساعدنا الأرقام على رسم الصورة العامة، بينما تعطينا المقابلات مفاتيح تفسير لماذا يشعر بعض الطلبة بالعزلة وكيف يمكن للجامعة التدخل بذكاء.

(9) كيف نقرأ المخرجات نقدياً قبل الذكاء الاصطناعي وبعده؟

قبل النمذجة نسأل: هل بياناتنا ممثلة؟ من الغائب ولماذا؟ هل المتغيرات حساسة ثقافيًا وتحتاج إعادة صياغة؟ أثناء النمذجة نسأل: هل الهدف منصف أم قد يرسّخ عدم مساواة؟ هل نعتمد مقاييس تتجاوز «الدقة» نحو الإنصاف بين الفئات؟ وبعد النشر نسأل: هل نراقب تحوّل التوزيع مع الزمن؟ وهل لدينا آليات تظلم واستجابة عندما تظهر مشكلة (Suresh & Guttag, 2021; Raji et al., 2020)؟ تذكر ضروري: «البيانات الكبيرة» ليست بالضرورة «بيانات جيّدة»؛ قد تكون كبيرة لكنها منحازة أو غير مصرّح بها (boyd & Crawford, 2012; Crawford, 2021).

خاتمة

البيانات هي وقود الذكاء الاصطناعي في قضايا المجتمع. يمكن أن تكون وقودًا نظيفًا يدفع قرارات عادلة، ويمكن أن تكون ملوثةً يرسّخ فجوات قديمة. الفارق تصنعه مصادرها، وطرق القياس والتوثيق، ووعينا بمصادر التحيز واستراتيجيات التخفيف. عندما نحسن تصميم العيّنة، ونراجع القياس لغويًا وثقافيًا، ونتبنّى توثيقًا شفافًا (Datasheets/Model Cards)، ونقرأ النتائج على أكثر من بُعد—not رقم الدقة وحده—يصبح الذكاء الاصطناعي أداة تخدم الصالح العام بدل أن تعمق لا مساواته (Geburu et al., 2021; Mitchell et al., 2019; Raji et al., 2020).

قائمة المراجع

1. Bethlehem, J. (2010). Selection bias in web surveys. *International Statistical Review*, 78(2), 161–188.
 2. boyd, d., & Crawford, K. (2012). Critical questions for Big Data: Provocations for a cultural, technological, and scholarly phenomenon. *Information, Communication & Society*, 15(5), 662–679.
 3. Crawford, K. (2021). *Atlas of AI: Power, politics, and the planetary costs of artificial intelligence*. Yale University Press.
 4. Denzin, N. K. (1978). *The research act: A theoretical introduction to sociological methods* (2nd ed.). McGraw-Hill.
 5. Groves, R. M., Fowler Jr., F. J., Couper, M. P., Lepkowski, J. M., Singer, E., & Tourangeau, R. (2009). *Survey methodology* (2nd ed.). Wiley.
 6. Kvale, S., & Brinkmann, S. (2009). *InterViews: Learning the craft of qualitative research interviewing* (2nd ed.). Sage.
 7. Lincoln, Y. S., & Guba, E. G. (1985). *Naturalistic inquiry*. Sage.
 8. Little, R. J. A., & Rubin, D. B. (2019). *Statistical analysis with missing data* (3rd ed.). Wiley.
 9. Mitchell, M. (2019). *Artificial intelligence: A guide for thinking humans*. Farrar, Straus and Giroux.
 10. Mitchell, M., Wu, S., Zaldivar, A., Barnes, P., Vasserman, L., Hutchinson, B., Spitzer, E., Raji, I. D., & Gebru, T. (2019). Model cards for model reporting. In *Proceedings of the Conference on Fairness, Accountability, and Transparency* (pp. 220–229).
 11. O’Neil, C. (2016). *Weapons of math destruction: How big data increases inequality and threatens democracy*. Crown.
 12. Raji, I. D., Smart, A., White, R. N., Mitchell, M., Gebru, T., Hutchinson, B., Smith-Loud, J., Theron, D., & Barnes, P. (2020). Closing the AI accountability gap: Defining an end-to-end framework for internal algorithmic auditing. In *Proceedings of the 2020 Conference on Fairness, Accountability, and Transparency* (pp. 33–44).
 13. Russell, S., & Norvig, P. (2020). *Artificial intelligence: A modern approach* (4th ed.). Pearson.
- Salganik, M. J. (2017). *Bit by bit: Social research in the digital age*. Princeton University Press.

14. Suresh, H., & Gutttag, J. V. (2021). A framework for understanding sources of harm throughout the machine learning life cycle. In *Proceedings of the 2021 ACM Conference on Equity and Access in Algorithms, Mechanisms, and Optimization (EAAMO '21)*.
15. van Buuren, S. (2018). *Flexible imputation of missing data* (2nd ed.). CRC Press.