

محاضرة 3: من سؤال البحث إلى نموذج — رحلة منهجية مبسّطة لعالم الاجتماع

تمهيد

الهدف من هذه المحاضرة هو فهم كيف تنتقل خطوة بخطوة من سؤال اجتماعي واضح إلى نموذج يساعدنا على الفهم أو التنبؤ أو دعم القرار. الفكرة الجوهرية أنّ التقنيات ليست بديلاً عن الحكم العلمي والخبرة الميدانية، وإنما أدوات تنظّم تفكيرنا وتُسرع عملنا عندما نستخدمها بوعي وبعدل وشفافية (Mitchell, 2019; Russell & Norvig, 2020). لهذا سنشرح المسار بلغة عادية، مع أمثلة قريبة من واقع التعليم والعمل والخدمات، لكي ترى كيف تُترجم المفاهيم إلى ممارسة يومية مسؤولة. (Crawford, 2021).

(1) ما الذي نريده بدقة: تفسير الأسباب أم توقع النتائج؟

قبل أي شيء، أسأل نفسك: هل أريد فهم الأسباب أم توقع ما سيحدث؟ إذا كان هدفك فهم الأسباب، فأنت تميل إلى تصميم يركّز على المقارنة العادلة بين المجموعات، والتحكّم في العوامل المؤثرة، وفحص البدائل التفسيرية الممكنة. هذا النوع من العمل يُسمّى تفسيراً سببياً، ويحتاج عناية بأساليب التصميم والصدق الداخلي (Shadish, Cook, & Campbell, 2002). أما إذا كان هدفك توقع من قد يتعرّض لمشكلة قريباً، مثل توقع التسرّب المدرسي في العام القادم، فأنت تركز على قدرة النموذج على النجاح خارج البيانات التي تعلّم منها، أي على التعميم الحقيقي في الميدان. (Shmueli, 2010) لا يوجد خيار "أفضل دائماً"، بل يوجد خيار أنسب لغرضك. المهم أن تُصرّح بهذا الغرض في بداية أي تقرير أو عرض.

(2) من الفكرة إلى القياس المنصف: كيف نحول المفاهيم إلى أسئلة وبيانات؟

نتعامل في علم الاجتماع مع مفاهيم مثل "الاندماج"، "الثقة"، "الوصم"، و"العدالة". لكي نستخدم هذه المفاهيم في البحث، علينا تحويلها إلى أسئلة قابلة للقياس أو إلى مؤشرات واضحة. الخطوة الحساسة هنا هي التأكد من أنّ الأسئلة لا تُوجّه المشارك نحو إجابة معيّنة، وأنّ اللغة مفهومة للفئة المستهدفة، وأنّ المؤشر يعكس المفهوم فعلاً لا ظلّه المشوّه. (Groves et al., 2009) في البحوث النوعية، نضيف طبقة مهمّة من الانتباه للسياق: من يتكلّم؟ بأي لهجة؟ وما علاقة الباحث بالمشاركين؟ هذه الأسئلة تؤثر في المعنى النهائي للنصّ وفي "الصدق" النوعي (Lincoln & Guba, 1985) القاعدة البسيطة هنا: إن أردت نتائج عادلة من أي نموذج، فابدأ بأداة قياس عادلة.

(3) ما هي "الإجابة الصحيحة" التي يتعلّم منها النموذج؟ وكيف نتأكد من جودتها؟

لكي يتعلّم أي نموذج، يحتاج إلى أمثلة يعرف معها ما هو الصحيح. في حالة التسرّب المدرسي مثلاً، قد نعتبر أنّ “الإجابة الصحيحة” هي تسجيل المدرسة بأنّ الطالب انقطع عن الدراسة. هذا تعريف عملي، لكنه لا يحكي لنا السبب، وقد يتأخّر تسجيله زمنياً. وفي حالة تصنيف النصوص (شكاوى وغير شكاوى)، نحتاج إلى مُوسّمين بشريين يضعون العلامات وفق دليل واضح، ثم نتأكد من درجة اتفاهم على التصنيف حتى نطمئن إلى جودة “الإجابات الصحيحة” التي سنعلّم بها النموذج. (Krippendorff, 2018) كل هذا يجب توثيقه بشفافية في ملف وصفيّ للبيانات يشرح المصدر والدقّة والحدود. (Gebru et al., 2021)

(4) من أين نأتي بالبيانات؟ وكيف نضمن تمثيلاً عادلاً؟

مصدر البيانات وشكلها يحدّدان ما يمكن أن يعرفه النموذج وما يعجز عنه. عندما نعلم على استطلاع عبر تطبيق إلكتروني واحد، نحن نستبعد تلقائياً من لا يستخدمون التطبيق لأسباب ماديّة أو اجتماعيّة، فينشأ تحيّز في التغطية. وعندما يرفض بعض الناس المشاركة، قد يكون الراضون مختلفين منهجياً عن الموافقين، فينشأ تحيّز في عدم الاستجابة. (Groves et al., 2009) الحلول بسيطة في فكرتها: قنوات بديلة لجمع الإجابات، مقارنة توزيع العيّنة مع التوزيعات الرسمية للسكان، وتسجيل هذه القرارات في مستند توثيقي يبيّن لمن حُصّصت البيانات ومن غاب عنها. (boyd & Crawford, 2012; Gebru et al., 2021) تذكّر أنّ عدالة القرار تبدأ من عدالة العيّنة (O’Neil, 2016).

(5) كيف نعلّم النموذج دون “غشّ”؟ تقسيم البيانات وفكرة الفحص المتكرر

لكي نتأكد من أنّ النموذج لا يحفظ الأمثلة فقط، نقسم البيانات إلى ثلاثة أجزاء: جزء للتعلّم، وجزء للفحص أثناء التطوير، وجزء أخير لا يراه النموذج إلا في النهاية من أجل الحكم العادل على أدائه. عندما تكون البيانات قليلة أو غير متجانسة، نُعيد هذا التقسيم أكثر من مرة بطرق منظّمة ثم نأخذ متوسط الأداء. الفكرة تشبه امتحاناً تعقده للطالب عدّة مرّات بأسئلة مختلفة من المنهج نفسه، بدلاً من اختبار واحد قد يجري فيه الحظّ مجراه (Arlot & Celisse, 2010). احذر أن تُجري خطوات التنظيف أو الاحتساب على كامل البيانات قبل التقسيم؛ افعل ذلك داخل كل جزء كي تمنع تسريب معلومات من المستقبل إلى الماضي.

(6) أيّ النماذج نختار؟ ولماذا نحبّ النماذج المفهومة في القرارات الحسّاسة؟

في القرارات التي تمسّ حياة الناس مباشرة، مثل قبول المنح أو توزيع الخدمات، نفضّل النماذج التي يمكن شرحها بوضوح للمستفيدين وصنّاع القرار، مثل الانحدار اللوجستي أو الأشجار البسيطة. هذه النماذج أقلّ “سحراً” لكنها

أكثر قابلية للتفسير، وهذا يمنحنا مساءلة حقيقية عند الحاجة. (Rudin, 2019) في المقابل، قد نحتاج نماذج أغنى عندما تكون العلاقات معقدة للغاية. في هذه الحالة نرفع من جرعة الشفافية: نوثق الافتراضات، نعرض النتائج لكل فئة على حدة، ونُبقي الإنسان جزءًا من الحلقة الرقابية. (Breiman, 2001)

(7) كيف نقيس الأداء بشكل اجتماعي مسؤول؟ ما وراء رقم "الدقة"

رقم "الدقة" مفيد لكنه ليس كافيًا في القضايا الاجتماعية. نسال: هل يكتشف النموذج من يحتاجون التدخل حقًا؟ هذه هي القدرة على الالتقاط. وهل الأشخاص الذين يضعهم النموذج في قائمة التدخل هم فعلاً من يحتاجون الدعم؟ هذه هي جودة الإشارة. ثم نسال: هل يتعامل النموذج بعدل مع الفئات المختلفة؟ قد نبحث عن تكافؤ الفرص، أي أن يكون احتمال اكتشاف الحالات المستحقة قريبًا بين الفئات، لا أن تتحمل فئة معينة العبء الأكبر من الأخطاء. (Hardt, Price, & Srebro, 2016; Lipton, 2018). أحيانًا تتعارض مفاهيم العدالة فيما بينها، وعندها يجب أن نعرض المقايضات بصدق ونُشرك المعنيين في اختيار ما يُقدّم (Kleinberg, Mullainathan, & Raghavan, 2017; Suresh & Guttag, 2021).

(8) العالم يتغير: لماذا يضعف النموذج بمرور الزمن؟ وماذا نفعل؟

حتى لو كان النموذج ممتازًا عند إطلاقه، قد يضعف بعد شهور لأن الاقتصاد يتغير، أو لأن سياسات المدرسة تبدلت، أو لأن سلوك الناس على المنصات تحوّل. هذا ما يسميه الباحثون تغيير البيئة أو انزياح البيانات. الحل عملي: مراقبة مؤشرات الأداء بانتظام، وتجربة النموذج على مناطق أو سنوات جديدة، وتحديث البيانات والنموذج دوريًا عند الضرورة. المهم ألا نُعَمِّم خارج السياق دون اختبار واقعي (Quiñonero-Candela, Sugiyama, Schwaighofer, & Lawrence, 2009).

(9) الشفافية ليست رفاهية: لماذا نكتب «بطاقة للبيانات» و«بطاقة للنموذج»؟

الشفافية تُبقي الثقة حيّة. نكتب بطاقة للبيانات توضّح مصدرها، والجمهور المقصود، والقيود، والمخاطر الأخلاقية. ثم نكتب بطاقة للنموذج توضّح هدفه، والبيانات التي تعلّم منها، وكيف أدّى مع كل فئة على حدة، ولمن صُمِّم، وأين لا ينبغي استخدامه. هذه الوثائق تجعل الجميع يعرف حدود الأداة وحقوقه وواجباته، وتحوّل التقنية من صندوق أسود إلى عقد اجتماعي واضح. (Mitchell et al., 2019; Geburu et al., 2021; Raji et al., 2020)

(10) من المسؤول؟ الحوكمة ووضع الإنسان في الحلقة

لا يكفي أن نبني نموذجًا جيدًا؛ نحتاج منظومة تُحدّد الأدوار: من يراقب الأداء؟ من يوقف الاستخدام عند ظهور خلل؟ من يستقبل شكاوى المتضررين؟ وكيف نُصحّ المسار؟ عندما نحدّد هذه المسؤوليات قبل الإطلاق، يصبح استخدام النماذج أكثر أمانًا وعدلاً واستدامة. (Raji et al., 2020) الإنسان لا يخرج من الحلقة؛ بل يبقى صاحب القرار النهائي عند القضايا الحساسة.

مثال تطبيقي مبسّط ومتسلسل

السؤال: كيف نحدّد الطلبة الأكثر عرضة للتسرّب في العام القادم؟

القياس: نضع تعريفًا واضحًا للتسرّب يعتمد على السجلات الإدارية مع هامش زمني معقول، ونصوغ أسئلة عن الدافعية والدعم الأسري بلغة غير موجّهة، ثم نختبر الصياغة مع عيّات صغيرة لتفادي سوء الفهم (Groves et al., 2009).

البيانات: نجمع من مدارس حضرية وريفية، ونوفّر قنوات بديلة لمن لا يستخدمون التطبيقات الرقمية. نُعدّ "بطاقة بيانات" توضح من شملناه ومن غاب عنا. (boyd & Crawford, 2012; Gebru et al., 2021)

التعلّم والفحص: نقسم إلى تعلّم وفحص واختبار، ونكرّر التقسيم أكثر من مرة للحصول على تقدير مستقر للأداء (Arlot & Celisse, 2010).

اختيار النموذج: نبدأ بنموذج مفهوم يمكن شرحه، مثل الانحدار اللوجستي، لأنه مناسب لاتخاذ قرارات مدرسية شفافة. (Rudin, 2019)

التقييم: نركّز على اكتشاف الحالات المهمة بعدل بين الفئات، لا على رقم الدقّة وحده (Hardt et al., 2016; Lipton, 2018).

الشفافية والحوكمة: ننشر "بطاقة للنموذج" تبيّن أنّه غير مناسب للاستخدام خارج المرحلة الثانوية الحضرية، ونضع خطة مراجعة ربع سنوية وتحديث دوري للبيانات (Mitchell et al., 2019; Quiñonero-Candela et al., 2009).

خاتمة

التحويل من سؤال اجتماعي إلى نموذج ليس مسارًا تقنيًا معقدًا بقدر ما هو تفكير منظم: غرض واضح، قياس منصف، بيانات ممثّلة، تعلّم وفحص واختبار عادل، تقييم يراعي الإنصاف، شفافية في الوثائق، ومسؤوليات محدّدة

بعد النشر. عندما نتبع هذه الخطوات، تصبح النماذج جزءًا من جرفة عالم الاجتماع، لا عبثًا ولا غموضًا
(Shmueli, 2010; Mitchell, 2019).

قائمة المراجع

1. Arlot, S., & Celisse, A. (2010). A survey of cross-validation procedures for model selection. *Statistics Surveys*, 4, 40–79.
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. Breiman, L. (2001). Statistical modeling: The two cultures (with comments and a rejoinder by the author). *Statistical Science*, 16(3), 199–231.
4. Crawford, K. (2021). *Atlas of AI: Power, politics, and the planetary costs of artificial intelligence*. Yale University Press.
5. Gebru, T., Morgenstern, J., Vecchione, B., Vaughan, J. W., Wallach, H., Daumé III, H., & Crawford, K. (2021). Datasheets for datasets. *Communications of the ACM*, 64(12), 86–92.
6. Groves, R. M., Fowler Jr., F. J., Couper, M. P., Lepkowski, J. M., Singer, E., & Tourangeau, R. (2009). *Survey methodology* (2nd ed.). Wiley.
7. Hardt, M., Price, E., & Srebro, N. (2016). Equality of opportunity in supervised learning. *Advances in Neural Information Processing Systems*, 29, 3315–3323.
8. Kleinberg, J., Mullainathan, S., & Raghavan, M. (2017). Inherent trade-offs in the fair determination of risk scores. *Proceedings of the 8th Innovations in Theoretical Computer Science Conference (ITCS 2017)*, 43:1–43:23. (Also available as arXiv:1609.05807)
9. Krippendorff, K. (2018). *Content analysis: An introduction to its methodology* (4th ed.). Sage.
10. Lincoln, Y. S., & Guba, E. G. (1985). *Naturalistic inquiry*. Sage.
11. Mitchell, M. (2019). *Artificial intelligence: A guide for thinking humans*. Farrar, Straus and Giroux.
12. O’Neil, C. (2016). *Weapons of math destruction: How big data increases inequality and threatens democracy*. Crown.

13. Quiñonero-Candela, J., Sugiyama, M., Schwaighofer, A., & Lawrence, N. D. (Eds.). (2009). *Dataset shift in machine learning*. MIT Press.
14. 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).
15. Rudin, C. (2019). Stop explaining black box machine learning models for high-stakes decisions and use interpretable models instead. *Nature Machine Intelligence*, 1(5), 206–215.
16. Russell, S., & Norvig, P. (2020). *Artificial intelligence: A modern approach* (4th ed.). Pearson.
17. Shadish, W. R., Cook, T. D., & Campbell, D. T. (2002). *Experimental and quasi-experimental designs for generalized causal inference*. Houghton Mifflin.
18. Shmueli, G. (2010). To explain or to predict? *Statistical Science*, 25(3), 289–310.
19. 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)*.