

Auswahlkriterien für ein Verfahren

Erarbeitet von
Dr. Katja Theune

Lernziele	1
Inhalt	2
Einstieg	2
Kriterien: Art des Anwendungsfalls und Daten	2
Weitere Kriterien	3
Anwendungsbeispiel	3
No free lunch	4
Abschluss	4
Quellen	4
Weiterführendes Material	4
Disclaimer	5

Lernziele

- Du kannst Kriterien erläutern, nach denen ein Verfahren für einen bestimmten Anwendungsfall ausgewählt werden kann
- Du kannst erläutern, dass es nicht „das eine“ Verfahren für alle Daten und Anwendungsfälle gibt


Inhalt

Einstieg

Wir haben gesehen, dass es sehr viele verschiedene Verfahren des überwachten maschinellen Lernens gibt. Und selbst die hier vorgestellten Verfahren bilden nur einen Teil aller Möglichkeiten ab. Aber wie wähle ich dann ein bestimmtes Verfahren für meinen konkreten Anwendungsfall aus? Hier gibt es natürlich keine allgemein gültige Vorgehensweise. Aber es gibt einige Kriterien, an denen man sich orientieren kann.

Kriterien: Art des Anwendungsfalls und Daten

Auswahl Verfahren: Kriterien



Ein guter Startpunkt ist es, sich zunächst die Art unseres Anwendungsfalls und die Daten anzusehen, die man verwenden möchte. Wir sollten uns zuallererst die Frage stellen, ob wir uns im unüberwachten Lernen oder im überwachten Lernen befinden. Mit unserem Fokus auf überwachtes Lernen müssen wir hier noch je nach Output überlegen, ob wir Verfahren zur Klassifikation oder Regression benötigen. Viele Verfahren können ja mit beiden Problemen umgehen, aber eben nicht alle.

Quelle [1]

Zudem stellt sich die Frage, welche Annahmen wir bzgl. des Zusammenhangs der Inputs und des Outputs haben. Vermuten wir einen einfachen linearen Zusammenhang, kann man ein speziell dafür ausgerichtetes Verfahren verwenden, z. B. die lineare Regression. Diese sind dann häufig schneller zu trainieren und liefern gute Prognosen. Wird ein komplexerer Zusammenhang vermutet, benötigt man ein flexibleres Verfahren, welches diesen Zusammenhang auch abbilden kann.

Weitere Kriterien

Das waren bis jetzt Kriterien, welche bestimmte Verfahren aufgrund der Beschaffenheit des Anwendungsfalls bzw. der Daten ausschließen. Es gibt aber auch andere Entscheidungskriterien, die darüber hinaus gehen.

So könnten wir verschiedene passende Verfahren bzgl. ihrer Prognosegenauigkeit mit Evaluationsmetriken vergleichen und das beste Verfahren auswählen. Aber auch hier ist die Auswahl nicht so einfach. Denn die Prognosegenauigkeit muss nicht unbedingt das einzige Ziel sein, welches wir erfüllen wollen oder müssen. Wir können uns sensible Anwendungsfälle vorstellen, bei denen Entscheidungen den Menschen direkt betreffen und es auch auf die Erklärbarkeit von Prognosemodellen ankommt. Damit ist gemeint, dass z. B. erklärt werden kann, wie die Prognosemodelle zu einem bestimmten Ergebnis gekommen sind – Stichwort explainable AI.

Hier stellt sich dann also die Frage, ob wir lieber ein Verfahren verwenden wollen, was durch seine Flexibilität ggf. eine bessere Prognosegenauigkeit aufweist, sich die Ergebnisse aber nur schwer potenziell Betroffenen erklären lassen. Oder doch lieber ein ggf. weniger leistungsfähiges einfacheres Verfahren, dessen Entscheidungsfindung aber transparenter ist. Wir müssen also auch einen möglichen Trade-off zwischen Prognosegenauigkeit und Interpretierbarkeit beachten.

Nicht zuletzt kann ein weiteres Entscheidungskriterium auch die benötigte Rechenleistung und Rechendauer sein, die für komplexere Verfahren deutlich größer sind als für einfachere Verfahren.

Die hier genannten Kriterien sind aber natürlich nicht vollständig, sondern dienen nur einer ersten Orientierung, wie man sich dem passenden Verfahren nähern kann.

Anwendungsbeispiel

Kommen wir auf unser Anwendungsbeispiel der Prognose eines möglichen Studienabbruchs zurück. Wir benötigen also ein überwachttes Lernverfahren zur Klassifikation. Hier handelt es sich zudem eher um ein sensibleres Anwendungsgebiet und das Ergebnis dieses Modells und die sich daraus ergebenden Maßnahmen haben einen direkten Einfluss auf Studierende. Wir könnten uns hier vorstellen, dass es neben der Prognosegenauigkeit auch interessant und wichtig ist, welche Inputs eine besondere Rolle spielen, um daraus Maßnahmen abzuleiten. Dafür würde sich dann z. B. eher ein möglichst erklärbares Verfahren eignen und eines, bei dem man auch etwas über die Inputwichtigkeit erfährt. Zudem könnte man vermuten, dass bei der Studienabbruchprognose der Zusammenhang zwischen den vielen relevanten Inputs und dem Output sehr komplex ist. Es ist dann sinnvoll, ein Verfahren zu wählen, das diese Komplexität berücksichtigen kann. In den Sinn käme uns hier vielleicht ein random forest.

Quelle [2]

No free lunch

Wir sehen also, dass die Verfahrensauswahl sehr stark vom Anwendungsfall, den Daten und unseren Zielen abhängt. Es gibt auch nicht „das eine“ Verfahren, keine Geheimwaffe, die in allen Situationen, für alle Daten und Anwendungsfälle immer und überall den anderen Verfahren überlegen ist. Häufig wird dies auch als „no free lunch Theorem“ bezeichnet, unter dem Motto „nichts im Leben ist umsonst“. Soll heißen, man kann es sich nicht einfach einfach machen, und ein einmal gut funktionierendes Modell auch beim nächsten Anwendungsfall wieder verwenden. Stattdessen man muss immer wieder das für seinen spezifischen Fall beste Verfahren finden.

Abschluss

Wir haben verschiedene Kriterien kennengelernt, an denen man sich bei der Wahl eines geeigneten Verfahrens für seine konkrete Fragestellung orientieren kann. Wir wissen aber auch, dass es nicht „das eine“ Verfahren gibt, das in allen Situationen immer besser ist als alle anderen, sondern dass wir sorgfältig ein jeweils passendes Verfahren auswählen müssen.

Quellen

Quelle [1] https://scikit-learn.org/stable/tutorial/machine_learning_map/index.html

Quelle [2] Behr, A., Giese, M., Tegum K., H. D. , & Theune, K. (2020). Early Prediction of University Dropouts – A Random Forest Approach. *Journal of Economics and Statistics*, 240 (6), 43-789. <https://doi.org/10.1515/jbnst-2019-0006>

Weiterführendes Material

Han, J., Kamber, M., & Pei, J. (2012). *Data Mining: Concepts and Techniques* (3. Auflage). Morgan Kaufmann.

James, G., Witten, D., Hastie, T., & Tibshirani, R., & Tylor, J. (2023). *An Introduction to Statistical Learning - with Applications in Python*. Springer.

Lantz, B. (2015). *Machine learning with R* (2. Auflage). Packt Publishing Ltd, Birmingham.

Disclaimer

Transkript zu dem Video „Prognosemodelle (Klassifikation und Regression): Auswahlkriterien für ein Verfahren“, Dr. Katja Theune.

Dieses Transkript wurde im Rahmen des Projekts ai4all des Heine Center for Artificial Intelligence and Data Science (HeiCAD) an der Heinrich-Heine-Universität Düsseldorf unter der Creative Commons Lizenz [CC-BY 4.0](https://creativecommons.org/licenses/by/4.0/) veröffentlicht. Ausgenommen von der Lizenz sind die verwendeten Logos, alle in den Quellen ausgewiesenen Fremdmaterialien sowie alle als Quellen gekennzeichneten Elemente.