# überwachtes Lernen

## Autor und Herausgeber

Alexander Jung*, Department of Computer Science, Aalto University, Espoo, Finland (ORCID 0000-0001-7538-0990)
Editors: Konstantina Olioumtsevits (ORCID 0000-0003-2697-8659), Ekkehard Schnoor (ORCID 0000-0001-8252-1499), Aalto University, Espoo, Finland
*Corresponding author: alex.jung@aalto.fi

## Zusammenfassung

Überwachtes Lernen ist die Variante des maschinelles Lernen (ML)s, für die die Label-Werte einiger Datenpunkte benötigt werden. Durch diese Anforderung unterscheidet es sich von anderen Formen des MLs wie dem unüberwachtes Lernen oder dem bestärkendes Lernen (RL). Zwei Hauptarten des überwachten Lernens sind die Regression bei einem numerischen Label und die Klassifikation bei einem Label mit endlich vielen Werten. Die empirische Risikominimierung (ERM) lernt eine Hypothese aus einem Hypothesenraum, die den durchschnittlichen Verlust auf einem Trainingsdatensatz aus gelabelte Datenpunkte minimiert. Ein Label kann von einem Messgerät erfasst, berechnet oder von einer Person annotiert werden. Diese Annotierungsprozesse sind typischerweise fehlerbehaftet, sodass ein aufgezeichneter Label-Wert eine verrauschte Schätzung des wahren Werts darstellt.

## Definition

Eine Wetterstation der GeoSphere Austria in Krems an der Donau (Österreich) zeichnet stündlich die Lufttemperatur auf (GeoSphere Austria, 2026). Aus zehn solchen Tagen lassen sich zwei Lernaufgaben ableiten: die Vorhersage des Messwerts eines Tages um 15:00 Uhr (UTC) anhand seines Messwerts um 06:00 Uhr (UTC) sowie die Vorhersage, ob es am nächsten Tag um 15:00 Uhr mindestens zwei Grad wärmer ist. Beide erfordern für jeden der zehn Tage den vorherzusagenden Wert, sein Label. Überwachtes Lernen bezeichnet Methoden des maschinelles Lernen (ML)s, die die Label-Werte einiger Datenpunkte benötigen – und zwar derjenigen, die ein Trainingsdatensatz bilden. Diese Anforderung grenzt es von den anderen Ansätzen ab: Beim unüberwachtes Lernen steht kein solcher Wert zur Verfügung, und der Verlust wird über Modellparameter definiert, die den gesamten Datensatz zusammenfassen; beim bestärkendes Lernen (RL) misst stattdessen ein Belohnungssignal den Nutzen einer Vorhersage (Sutton and Barto, 2018, Abschn. 1.1). Methoden des überwachten Lernens bewerten die Güte einer Hypothese, indem sie deren Vorhersage mit einem bekannten Label-Wert vergleichen (Sutton and Barto, 2018, Abschn. 1.1; Hastie et al., 2009, Kap. 2).

Die empirische Risikominimierung (ERM) lernt eine Hypothese, indem sie deren Vorhersagen für die Datenpunkte in einem Trainingsdatensatz mit deren tatsächlichen Labels vergleicht. Das Trainingsdatensatz

$\mathcal{D}^{(\text{train})} = \left\{ \left(\mathbf{x}^{(r)}, y^{(r)}\right) \right\}_{r=1}^{m}$ besteht aus $m$ gelabelte Datenpunkte, jeweils mit einem Merkmalsvektor $\mathbf{x}^{(r)}$ und einem Label $y^{(r)}$. Unter den Hypothesen eines Hypothesenraums $\mathcal{H}$ wählt sie eine aus, die den durchschnittlichen Verlust auf dem Trainingsdatensatz minimiert,

$$\widehat{h} \in \operatorname*{arg\,min}_{h \in \mathcal{H}} \frac{1}{m} \sum_{r=1}^{m} L\left(\left(\mathbf{x}^{(r)}, y^{(r)}\right), h\right).$$

Der Verlust eines Datenpunkts lässt sich allein anhand dieses Datenpunkts auswerten, da sein Label den Vergleichswert liefert. Der Labelraum $\mathcal{Y}$, also die Menge der Werte, die ein Label annehmen kann, entscheidet darüber, welchem von zwei Haupttypen eine Lernaufgabe angehört: Mit $\mathcal{Y} = \mathbb{R}$ handelt es sich um eine Regression, mit einem diskreten Labelraum um eine Klassifikation. Beide Lernaufgaben lassen sich aus denselben Datenpunkte bilden.

Abb. 1 zeigt zwei überwachte Lernaufgaben, eine Regression und eine Klassifikation, die aus denselben Datenpunkte gewonnen wurden, nämlich den zehn Tagen aus Krems an der Donau. Mit dem Messwert des Tages um 15:00 Uhr als Label ist die Lernaufgabe eine Regression, und die ERM mit dem quadratischer Verlust lernt die Kurve in Teilabbildung (a). Die zweite Lernaufgabe verwendet beide Messwerte des Tages als Merkmale. Ihr Label ist $+1$, falls der nächste Tag um 15:00 Uhr mindestens zwei Grad wärmer ist, und andernfalls $-1$, sodass die Lernaufgabe eine Klassifikation ist. Die beiden Klassen überlappen sich, weshalb keine Gerade sie trennt: Auf dasselbe Messwertpaar kann sowohl ein wärmerer als auch ein kühlerer Tag folgen, und die beste Gerade ordnet neun der zehn Tage richtig zu.

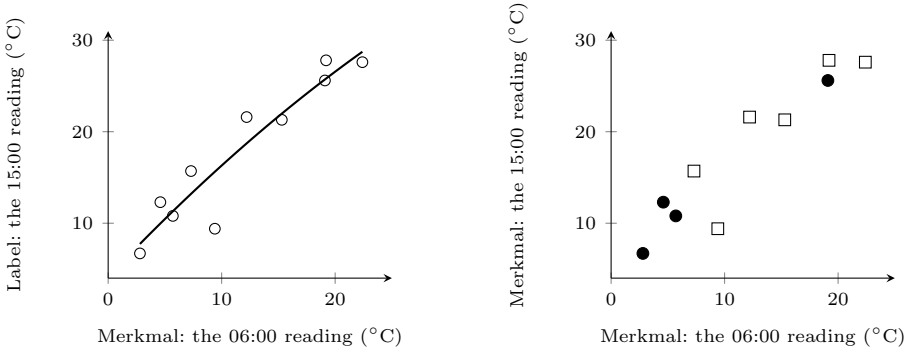


(a) Regression with a numeric Label (b) binary Klassifikation

Abbildung 1: Zehn Datenpunkte, die die täglichen Wetterbedingungen in Krems an der Donau jeweils am 25. eines Monats von Januar bis Oktober darstellen, werden in zwei verschiedenen überwachten Lernaufgaben verwendet. In (a) ist das Merkmal eines Tages sein Messwert um 06:00 Uhr (UTC) und das Label sein Messwert um 15:00 Uhr (UTC) (offene Kreise), sodass die Lernaufgabe eine Regression ist; die Kurve ist eine mittels ERM und dem quadratischer Verlust gelernte Hypothese. In (b) sind beide Messwerte eines Tages Merkmale, und das Label ist $+1$, falls der nächste Tag um 15:00 Uhr mindestens zwei Grad wärmer ist (gefüllte Kreise), und andernfalls $-1$ (offene Quadrate), sodass die Lernaufgabe eine Klassifikation ist. Daten erzeugt mit `pythondemos/supervisedlearning.py`

Die Label-Werte von Datenpunkte lassen sich auf unterschiedliche Weise gewinnen, etwa durch physikalische Messgeräte, Berechnungen oder menschliche Annotation. Beispielsweise stammt der Messwert eines Tages um 15:00 Uhr (UTC) in Krems von einem kalibrierten Thermometer der Wetterstation (GeoSphere Austria, 2026). Der Label-Wert kann auch durch numerische Berechnungen bestimmt werden. GeoSphere Austria betreibt das System INCA, das die Temperatur in ganz Österreich auf einem Ein-Kilometer-Gitter berechnet (Haiden et al., 2010, Abschn. 2; Haiden et al., 2011). INCA geht von der Prognose eines numerischen Wettervorhersagemodells aus und korrigiert diese mithilfe der Abweichungen zwischen Prognose und Beobachtung an den umliegenden Stationen, sodass es auch für einen Ort ohne eigene Station einen Temperaturwert liefert (Haiden et al., 2010, Abschn. 5.1). Die Temperaturaufzeichnungen können stattdessen auch von einer Person annotiert werden, etwa einem Meteorologen oder einer Gruppe von Anwohnern.

Diese Annotierungsprozesse unterscheiden sich im Ressourcenaufwand und in der resultierenden Label-Qualität. Jeder Prozess ist mit einem eigenen Fehler behaftet, sodass ein aufgezeichneter Label-Wert eine verrauschte Schätzung des wahren Werts ist. Das Stationsthermometer weist eine Kalibrierungstoleranz auf. Ein berechnetes Label übernimmt den Fehler der Gleichungen sowie der eingespeisten Messwerte. Ein Anwohner könnte Temperaturen falsch angeben.

Menschliche Annotation begrenzt zudem die mögliche Größe des Trainingsdatensatzs, da sie die Fachkraft erfordert, deren Einschätzung nachgebildet werden soll. Crowdsourcing hebt diese Beschränkung auf: ImageNet, ein Datensatz, der zum Zeitpunkt seiner Erstveröffentlichung 3.2 Millionen annotierte Bilder umfasste, wurde von Annotatoren über eine Crowdsourcing-Plattform zusammengestellt (Deng et al., 2009, Abschn. 3.2).

Ein annotiertes Label hält ein Urteil statt einer Messung fest, und zwei Annotatoren müssen nicht denselben Wert liefern. ImageNet wurde so aufgebaut, dass diese Abweichungen begrenzt werden. Mehrere Annotatoren stimmen über jedes Bild ab, das nur bei einer überzeugenden Mehrheit übernommen wird. Die erforderliche Stimmenanzahl wird pro Kategorie anhand einer anfänglichen Teilmenge ihrer Bilder festgelegt (Deng et al., 2009, Abschn. 3.2).

Siehe auch: Label, gelabelter Datenpunkt, Trainingsdatensatz, ERM, Hypothese, Verlust, quadratischer Verlust, Klassifikation, Regression, Klassifikator, Validierungsfehler, unüberwachtes Lernen, selbstüberwachtes Lernen, semiüberwachtes Lernen (SSL), RL.

## Querverweise

## Literatur


1. GeoSphere Austria (2026). GeoSphere Austria climate station archive. Data hub, station historical resource klima-v2-1d. URL: https://dataset.api.hub.geosphere.at/v1/station/hist v2-1d.

2. Haiden et al. (2011). The Integrated Nowcasting through Comprehensive Analysis (INCA) system and its validation over the Eastern Alpine region. Weather and Forecasting, 26(2), pp. 166–183.

3. Haiden et al. (2010). Integrated Nowcasting through Comprehensive Analysis (INCA) – System description, Central Institute for Meteorology and Geodynamics (ZAMG), Vienna, Austria.

4. Deng et al. (2009). ImageNet: A large-scale hierarchical image database. In: 2009 IEEE Conference on Computer Vision and Pattern Recognition, pp. 248–255.

5. Sutton and Barto (2018). Reinforcement Learning: An Introduction. 2nd ed., MIT Press, Cambridge, MA, USA.

6. Hastie et al. (2009). The Elements of Statistical Learning: Data Mining, Inference, and Prediction. 2nd ed., Springer Science+Business Media, New York, NY, USA.