Verlust

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

Der von einer Hypothese auf einem einzelnen Datenpunkt verursachte Verlust ist ein Skalar, der den Fehler der Hypothese bei der Bewertung auf diesem Datenpunkt quantifiziert. Das letztendliche Ziel von machine learning (ML)-Methoden ist es, ein Modell so zu trainieren, dass die gelernte Hypothese Vorhersagen mit minimum Verlust liefert. Ein Schlüsselmerkmal von ML-Anwendungen und -Methoden ist die Zugänglichkeit von Verlustwerten. Im überwachtes Lernen kann der Verlust für jede Hypothese bewertet werden. Im bestärkendes Lernen (RL) wird der Verlust nur für die tatsächlich ausgeführte Aktion beobachtet.

Definition

Bei der Temperaturvorhersage wird die Qualität einer vorhergesagten Temperatur natürlicherweise danach gemessen, wie stark sie von der tatsächlich am nächsten Tag gemessenen Temperatur abweicht. Der Verlust formalisiert diese Idee. Der von einer Hypothese $h \in \mathcal{H}$ auf einem einzelnen Datenpunkt verursachte Verlust ist ein Skalar, der den Fehler von h bei der Bewertung auf diesem Datenpunkt quantifiziert (Shalev-Shwartz and Ben-David, 2014, Sect. 2.1). Ein kleinerer Verlustwert deutet auf einen kleineren Fehler hin. Im überwachtes Lernen ist dieser Fehler die Diskrepanz zwischen der Vorhersage $h(\mathbf{x})$, die für die Merkmale $\mathbf{x}$ geliefert wird, und dem Label y dieses Datenpunkt. Einige Verluste (z. B. der squared error loss) nehmen ein Kontinuum von Werten an, während andere (z. B. der 0/1 loss) binär sind und nur anzeigen, ob die Vorhersage mit dem Label übereinstimmt. Für die Temperaturvorhersage kann der Verlust an einem bestimmten Tag die quadrierte Differenz zwischen der vorhergesagten Temperatur (der Vorhersage) und der gemessenen (dem Label) sein; siehe Abb. 1.

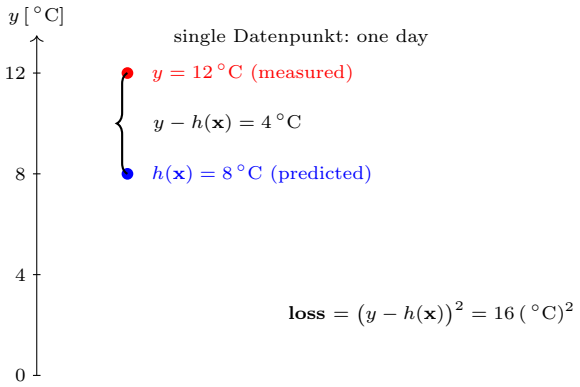

Abbildung 1: Verlust auf einem einzelnen Datenpunkt, der einen Tag repräsentiert. Das wahre Label ist die gemessene Temperatur um 15:00 (UTC), $y = 12\,^\circ\mathrm{C}$; die Hypothese sagt voraus $h(\mathbf{x}) = 8\,^\circ\mathrm{C}$. Unter dem squared error loss beträgt der auf diesem Datenpunkt entstandene Verlust $\big(y - h(\mathbf{x})\big)^2 = 16\,(^\circ\mathrm{C})^2$

Verlustwerte sind typischerweise nicht-negativ: viele Verluste werden aus einer Norm oder Metrik gebildet und sind daher nach unten durch Null begrenzt. Nicht-Negativität ist jedoch nicht zwingend erforderlich: der logarithmic loss (negative Log-Likelihood), der maximum likelihood-Methoden zugrunde liegt, kann negative Werte annehmen, da eine Wahrscheinlichkeitsdichte eins überschreiten kann. Der Verlust ist auch nicht spezifisch für das überwachtes Lernen. Im unüberwachtes Lernen gibt es kein Label: ein Clustering-Verlust misst, wie weit ein Datenpunkt von seinem zugewiesenen Clusterzentrum entfernt liegt, und der Verlust eines Autoencoder ist der Rekonstruktionsfehler zwischen einem Datenpunkt und seiner Rekonstruktion.

Machine learning (ML)-Methoden verwenden beobachtete Verlustwerte, um eine Zielfunktion für das Modell-Training zu konstruieren. Der durchschnittliche Verlust über einen Trainingsdatensatz von Datenpunkte ist das empirical risk, das empirische Risikominimierung (ERM) minimiert.

ML-Anwendungen können danach kategorisiert werden, wie die Verlustwerte zugänglich sind. Im überwachtes Lernen kann der Verlust prinzipiell für jede Hypothese im Hypothesenraum bewertet werden, da das wahre Label jedes Training-Datenpunkt beobachtet wird.

Im bestärkendes Lernen (RL) ist die Situation anders (Sutton and Barto, 2018). Bei jedem Zeitschritt wählt die ML-Methode (implementiert durch einen Agent) eine Aktion über die aktuell verwendete Hypothese aus. Der Agent beobachtet dann den Verlust, der durch die tatsächlich ausgeführte Aktion entsteht. Der Verlust, der durch die anderen Aktionen entstanden wäre, wird nicht offengelegt. Diese eingeschränkte Zugänglichkeit von Verlustwerten ist als Bandit- (oder partielles) Feedback bekannt (Hazan, 2022, Sect. 6.1). Zum Beispiel lernt ein Routenplanungssystem die tatsächliche Reisezeit nur für die Route, die der Fahrer genommen hat, nicht für alternative Routen. Ähnlich wählt ein selbstfah-

rendes Auto eine Lenkrichtung, und der entstandene Verlust kann von bordeigenen Sensoren wie Kollisionsdetektoren und Spurhalteassistenten gemessen werden, aber nur für die tatsächlich gefahrene Trajektorie.

Synonyme: Kosten.

Siehe auch: Verlustfunktion, empirical risk, ERM, Datenpunkt, Hypothese, RL, überwachtes Lernen.

Querverweise

Literatur

1. Hazan (2022). Introduction to Online Convex Optimization. 2nd ed., MIT Press, Cambridge, MA, USA.

2. Shalev-Shwartz and Ben-David (2014). Understanding Machine Learning: From Theory to Algorithms. Cambridge Univ. Press, New York, NY, USA.

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