


Alternative Modelle

Joern Ploennigs · AI4SC



It is often necessary when some cherished scheme has failed, to take up the best alternative open, and if so, it is folly not to work for it with all your might.

— Winston Churchill

Neben den bekannten maschinellen Lernmodellen wie logistischer Regression, linearer Regression, Entscheidungsbäumen, Ensemble-Modellen, Clustering, Principal Component Analysis (PCA), Matrixfaktorisierung, neuronalen Netzwerken und Reinforcement Learning gibt es eine Vielzahl weiterer Modelltypen, die in verschiedenen Anwendungsbereichen verwendet werden. Diese werden oft in Spezialfällen verwendet, z.B. wenn Daten zeitlich strukturiert oder unsicher sind.

Sie sind besonders dann interessant, wenn Unsicherheit, kausale Struktur oder spärliches Expertenwissen wichtiger sind als maximale reine Vorhersagegenauigkeit.

Hier sind einige zusätzliche Typen von maschinellen Lernmodellen:

Markov-Modelle

Markov-Modelle sind stochastische Modelle, die auf der Markov-Annahme basieren, die besagt, dass der Zustand eines Systems nur von seinem aktuellen Zustand abhängt, nicht aber von früheren Zuständen. Wir haben sie kurz im Kontext von Reinforcement Learning kennen gelernt, weil dort u.a. Markov Decision Processes (MDP) zur Modellierung des Zustandsraums der Umgebung genutzt werden. Dies macht sie nützlich für Anwendungen wie Spracherkennung, der Bildverarbeitung oder der Bioinformatik, wo aufeinanderfolgende Ereignisse (Zuständen) von Bedeutung sind.

Bayesian Networks

Bayessche Netze modellieren Wahrscheinlichkeitsbeziehungen zwischen verschiedenen Variablen in Form von gerichteten azyklischen Graphen. Anders als Markov-Modelle (welche Folgen von Ereignissen modellieren) konzentrieren sie sich vor allem auf bedingte Wahrscheinlichkeiten und Abhängigkeiten zwischen Variablen. Sie ermöglichen es, komplexe Zusammenhänge zu modellieren und Schlussfolgerungen auf Basis bedingter Wahrscheinlichkeiten zu ziehen. Dies macht sie wertvoll für Diagnose-Systeme oder Risikoanalysen, wo viele Faktoren zusammenspielen.

Naive Bayes

Naive Bayes sind einfache probabilistische Klassifikationsmodelle, die auf dem Bayesschen Theorem zur Schätzung bedingter Wahrscheinlichkeiten basieren. Im Unterschied zu Bayesschen Netzwerken besitzen sie keine explizite grafische Struktur, sondern berechnen die Wahrscheinlichkeit einer Klasse auf Basis einer Menge von Attributen unter der Annahme der bedingten Unabhängigkeit der Attribute. Sie eignen sich insbesondere für Probleme mit hoher Dimensionalität und relativ wenig Trainingsdaten und werden häufig in Textklassifikation, Spam-Filterung, Sentiment-Analyse und anderen Anwendungen mit klar definierten Merkmalen verwendet.

Assoziationsanalyse

Assoziationsanalyse (Association rule learning) konzentrieren sich auf die Identifikation von Zusammenhängen in Daten in Form von Regeln, insbesondere in Transaktionsdaten. Ein klassisches Beispiel ist die Warenkorbanalyse im Einzelhandel, bei der untersucht wird, welche Produkte oft zusammen gekauft werden. Diese Modelle verwenden Metriken wie Support und Konfidenz, um Assoziationsregeln (z.B. Regel: wer A kauft -> kauft auch B) zu identifizieren.

Random Fields

Random Fields, insbesondere Markov Random Fields, sind probabilistische Modelle, die Beziehungen zwischen benachbarten Variablen in einem Gitter oder Graphen darstellen. Sie werden häufig in der Bildverarbeitung und Computer Vision verwendet, beispielsweise zur Segmentierung von Bildern, indem benachbarte Pixel als abhängig modelliert werden.

Autoencoder

Autoencoder sind spezielle neuronale Netzwerke, die darauf abzielen, Daten effizient zu komprimieren (kodieren) und wiederherzustellen (dekodieren). Sie werden häufig zur Dimensionalitätsreduktion, Bildkompression, Feature-Learning und Anomalieerkennung verwendet. Ein Beispiel ist die Reduktion der Dimensionalität von Bildern für eine effiziente Speicherung. Wir werden Sie im nachfolgenden Kurs „Machinelles Lernen und Künstliche Intelligenz“ behandeln.

Generative Modelle

Generative Modelle lernen die Wahrscheinlichkeitsverteilung der Eingabedaten und können neue Daten generieren. Zu den gängigen Typen gehören Generative Adversarial Networks (GANs), die aus zwei konkurrierenden neuronalen Netzwerken bestehen, und Variational Autoencoders (VAEs), die probabilistische Annahmen über die zugrunde liegende Verteilung der Daten machen. Generative Modelle werden zur Bilderzeugung, Datenaugmentation und Textgenerierung ver-

wendet. Ein Beispiel ist die Erzeugung synthetischer Bilder, die echten Bildern ähneln. Wir werden Sie vertiefend im Kurs „Machinelles Lernen und Künstliche Intelligenz“ behandeln.

Vergleich

Die folgende Tabelle vergleicht die unterschiedlichen Modelle noch zusammenfassend.

Merkmal / Modell	Typ	Ziel	Struktur	Hauptannahmen	Vorteile	Nachteile	Anwendungsbeispiele
Logistische Regression	Überwacht	Regression	Lineares Modell	Lineare Beziehung	Einfach zu interpretieren	Annahme der linearen Trennung	Kreditrisikobewertung
Lineare Regression	Überwacht	Regression	Lineares Modell	Lineare Beziehung	Einfach zu interpretieren	Annahme der Linearität	Hauspreis-schätzung
Entscheidungsbäume	Überwacht	Klassifikation / Regression	Baumstruktur	Keine	Einfach zu verstehen	Neigt zu Überanpassung	Kundenklassifikation
Ensemble Modelle	Überwacht	Klassifikation / Regression	Kombination aus Modellen	Keine	Hohe Genauigkeit, Robustheit	Rechenintensiv, komplex	Spam-Erkennung, Wettervorhersage
Clustering	Unüberwacht	Gruppierung	Cluster (Gruppen)	Keine	Einfache Implementierung	Benötigt geeignete Metriken	Kundensegmentierung
PCA	Unüberwacht	Dimensionalitätsreduktion	Lineare Transformation	Lineare Beziehung	Reduziert Dimensionalität	Kann Interpretierbarkeit verringern	Datenvorverarbeitung, Feature-Reduktion

Merkmal / Modell	Typ	Ziel	Struktur	Hauptannahmen	Vorteile	Nachteile	Anwendungsbeispiele
Matrix-faktorisierung	Unüberwacht	Dimensionalitätsreduktion	Matrizenoperationen	Latente Faktoren	Effektiv für große Datenmengen	Schwierig zu interpretieren	Produktempfehlungen
Neuro-nale Netzwerke	Überwacht	Viefältig (Klass., Reg., etc.)	Mehr-schichtige Netzwerke	Keine	Kann komplexe Muster lernen	Rechenintensiv, erfordert viel Daten	Bilderkennung, Sprachverarbeitung
Reinforce-ment Learning	Überwacht	Entscheidungen	Agent-Umwelt-Interaktion	Belohnungsmodell	Löst komplexe Aufgaben	Lange Trainingszeiten	Robotik, Spiele
Markov-Mo-delle	Überwacht	Zeitabhängige Prozesse	Zustandsmodell	Markov-Eigen-schaft	Modelliert zeitliche Abhängigkeiten	Benötigt Zustands-def.	Wettervorhersage, Sprachmodellierung
Bayes-sche Netzwerke	Überwacht	Bedingte Abhängigkeiten	Gerichteter Graph	Bedingte Unabhängigkeit	Modelliert Abhängigkeiten	Komplexe Struktur	Medizinische Diagnose
Naive Bayes	Überwacht	Klassifikation	Wahrscheinlichkeiten	Bedingte Unabhängigkeit	Schnell, einfach	Annahme der Unabhängigkeit	Spam-Filter
Assoziationsregel	Unüberwacht	Assoziationsregel-Mining	Regeln	Assoziationen	Identifiziert relevante Muster	Mögliche Überanpassung	Produktkaufmuster

Merkmal / Modell	Typ	Ziel	Struktur	Hauptannahmen	Vorteile	Nachteile	Anwendungsbeispiele
Random Fields	Überwachung	Bildverarbeitung, Vision	Graph-/Gitterstruktur	Nachbarschaft	Kontextabhängigkeiten	Rechenintensiv	Bildsegmentierung
Autoencoder	Unüberwacht	Dimensionalitätsreduktion	Kodierungs-/Dekodierungsnetzwerk	Effiziente Datenrepräsentation	Reduziert Datenkomplexität	Kann überanpassen	Bildkompression
Generative Modelle	Überwachung	Datengenerierung	Verschiedene	Verteilungsannahmen	Erzeugt realistische Daten	Schwierig zu trainieren	Synthetische Datenerzeugung

Diese Modelle helfen, mit *Unsicherheit, Kausalität oder Zeitabhängigkeit* umzugehen. Das sind auch typische Herausforderungen im Baualltag. So bieten sich an:

- **Markov-Modelle (HMM):** zur Zustandsüberwachung von Brücken (gesund ↔ angerissen ↔ beschädigt)
- **Bayessche Netzwerke:** Diagnosemodell für Ursachen von Setzungen (z.B. Bodenart, Wasserstand, Belastung)
- **Naive Bayes:** Klassifikation von Messpunkten aus zerstörungsfreier Prüfung (kritisch vs. unkritisch)

Bibliographie