

DYNAMIC PRICING VON HOTELPREISEN MITTELS REINFORCEMENT LEARNING

Themenbereiche:	Data Science, Machine Learning
Studierende:	Tobias Heller
Betreuungsperson:	Daniel Pfäffli, MSE Engineering, HSLU, Jaywalker Digital
Experte:	Tobias Baltensperger, Dr. sc. ETH Zürich, Oepfelbaum IT Management AG
Auftraggebende:	HSLU Informatik, Algorithmic Business (ABIZ) Research Team
Keywords:	Reinforcement Learning, Dynamic Pricing, Data Science, Machine Learning, AI

1. Aufgabenstellung

Früher haben Hotelbetriebe ihre Zimmer für einen fixen Preis pro Nacht angeboten, was heute immer weniger der Fall ist. Die Hotels passen die Preise aufgrund der aktuellen Nachfrage dynamisch an. In vielen Betrieben wird das durch einen Revenue Manager umgesetzt. Dieser Ansatz ist sehr kostenintensiv, da zur Bestimmung der Preisstrategie manuell die Auslastungsgraphen, wie auch die Konkurrenzpreise analysiert werden müssen. Deshalb suchen Hotels günstigere und skalierbarere Ansätze. Eine mögliche technische Lösung ist das datengetriebene Dynamic Pricing. In der vorliegenden Arbeit wird für diese Problemstellung untersucht, wie man mit historischen Daten und Offline Reinforcement Learning (RL) eine Preisstrategie erlernen kann. Diese dynamische Preisstrategie soll sowohl für den Revenue Manager als auch den Hotelkunden erklärbar und nachvollziehbar sein.

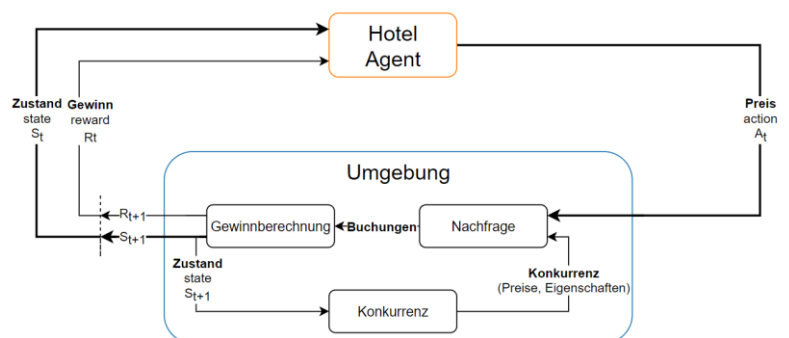
2. Lösungskonzept

Aufgrund des grossen explorativen Anteils der vorliegenden Bachelorarbeit wurde das Lösungskonzept in einem iterativ-inkrementellen Verfahren entwickelt.

Um die Lösungsfindung zu vereinfachen, wurde die Problemstellung in drei Einzelteile zerlegt.

1. Konkurrenzsituation modellieren
2. Erwartete Nachfrage modellieren
3. Reinforcement Learning Umgebung integrieren

Dies bietet die Grundlage, damit ein Reinforcement Learning Algorithmus trainiert werden kann. Dabei lernt der Reinforcement Learning Agent für ein Hotel eine Preisstrategie, welche historische Daten auswertet. Diese Daten beinhalten Preise des Hotels und der Konkurrenz aus der Vergangenheit sowie der damit erzielte Gewinn (Reward). Dadurch soll der Agent lernen, welche Aktionen (Preise) in welcher Situation zu einem möglichst hohen Gewinn führen.



3. Spezielle Herausforderungen

Zu Beginn des Projektes war unklar, ob mit den vorhandenen Daten eine gute Modellierung der Reinforcement Learning Umgebung möglich ist.

Eine weitere Herausforderung war die Umsetzung des Konkurrenzmodells, da für jedes zu simulierende Hotel bestimmt werden muss, welche anderen Hotels ein potenzieller Kunde als Konkurrenz betrachtet. Da im Datensatz keine Informationen zu möglichen Konkurrenten vorhanden sind, mussten diese anhand von Eigenschaften bestimmt werden. Zusätzlich sollten für diese Konkurrenten für jeden Zeitpunkt ein Preis berechnet werden.

Schlussendlich stellte sich auch die Modellierung der Nachfrage als eine grosse Herausforderung dar. Damit werden die Anzahl Buchungen berechnet, die das zu simulierende Hotel schlussendlich erhält. Die richtige Modellierung der Nachfrage und der Einfluss der Konkurrenz auf die Nachfrage ist essenziell, da schlussendlich der Reinforcement Learning Algorithmus dieses Nachfragemodell lernt. In dem bereitgestellten Datensätzen sind ausschliesslich Buchungen für 10 Hotels vorhanden. Diese beinhalten jedoch keine Nachfragedaten, sondern nur die effektiv getätigten Buchungen von Hotelgästen.

4. Ergebnisse

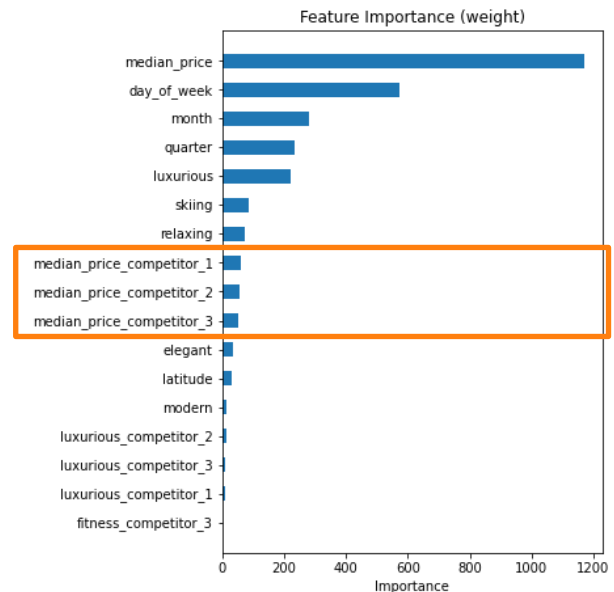
Im Rahmen der Bachelorarbeit (BAA) konnten folgende Lösungen erarbeitet werden:

- **Konkurrenzmodell:** Ein Machine Learning Modell, welches abhängig von den Eigenschaften, dem Zeitpunkt und den bisherigen Preisen eine Vorhersage über den Konkurrenzpreis macht.
- **Nachfragemodelle:** Mehrere Nachfragemodelle, welche die Anzahl Kunden für das zu simulierende Hotel zurückgeben. Diese wurden auf Erklärbarkeit und Performance hin verglichen.
- **Reinforcement Learning Umgebung:** Eine modulare Gym Reinforcement Learning Umgebung. Sie ermöglicht das Simulieren, Trainieren und Validieren von verschiedenen Offline Reinforcement Learning Algorithmen mit unterschiedlichsten Nachfrage- und Konkurrenzmodelle mit dem Reinforcement Learning Framework RLLIB.

Die Konkurrenz wurde anhand der Kosinus-Ähnlichkeit von textbasierten Eigenschaften definiert. Diese Konkurrenten können dabei mit zusätzlichen Preisinformationen für das Konkurrenzmodell verwendet werden. Das Konkurrenzmodell wurde auf einem Datensatz von Booking.com trainiert und es konnte ein Cross-Validation R^2 von 0.886 erreicht werden. Zusätzlich konnte eine Korrelation der Hotelpreise mit den Preisen der Konkurrenz im Umkreis von einem Kilometer festgestellt werden.

Weiter wurden unterschiedliche Nachfragemodelle validiert. Dazu wurden sowohl XGBoost-Modelle, lineare- und quadratische Regressionen wie auch manuelle Modelle entwickelt. Dabei konnte in Diskussionen im Projektteam während der Entwicklung festgestellt werden, dass Modelle, welche zuerst die Nachfrage und dann die Anzahl Buchungen für das zu simulierende Hotel bestimmen, eine grosse Anzahl Annahmen voraussetzen. So muss beispielsweise das einzelne Kundenverhalten und seine Präferenz für eine bestimmte Art von Hotels angenommen werden, da diese Informationen nur sehr schwierig aus den Datensätzen extrahiert werden können.

Ebenfalls wurde eine kontraintuitive Verbindung zwischen der Erhöhung des Preises und einer erhöhten Nachfrage erkannt. Dies führte zur Entwicklung eines XGBoost-Modells, welches aus den Eigenschaften und Preisen des Hotels und seiner Konkurrenten die Anzahl Buchungen direkt ableitet. Eine Betrachtung der Feature-Wichtigkeiten (siehe Abbildung rechts) hat jedoch gezeigt, dass mit den vorliegenden Daten kein genug grosser Einfluss der Konkurrenz festgestellt werden kann. Folglich konnte kein Nachfragemodell entwickelt werden, welches die Konkurrenz miteinbezieht.



Zusätzlich wurde eine modulare Reinforcement Learning Umgebung entwickelt. Für die Integration der Nachfrage- und Konkurrenzmodelle sowie Reinforcement Learning Algorithmen wurde eine standardisierte Schnittstelle konzipiert. Diese erlaubt eine sehr einfache Erweiterung der Reinforcement Learning Umgebung mit komplexeren Modellen und Algorithmen.

In einem ersten Test wurde das Konkurrenzmodell und ein statisches Nachfragemodell implementiert. Damit konnten anhand der historischen Daten ein Conservative Q-Learning Agent trainiert und auf zwei Zeiträume (Haupt- und Nebensaison) validiert werden. Die Auswertung zeigte auf, dass es für dieses Setup möglich ist, eine Performance zu erreichen, welche die Referenzdaten im Mittel um 82.49 Reward (Gewinn) pro Tag übertrifft. Zusätzlich wurde bei der qualitativen Betrachtung der Preisstrategie sichtbar, dass der Agent sehr stark das einfache Nachfragemodell gelernt hat.

5. Ausblick

Da kein Nachfragemodell mit zufriedenstellenden Resultaten entwickelt werden konnte, muss dieses in einem weiteren Schritt verbessert werden. Dabei soll mit zusätzlichen Reservationsdaten die Beziehung zwischen den Preisen des Agenten (Hotel) und seiner Konkurrenz bestimmt werden. Eine andere Möglichkeit bietet der Einbezug von effektiven Nachfragedaten. Dazu könnten beispielsweise die auf Buchungsplattformen wie Booking.com nacheinander geklickten Hotels analysiert werden.

Zudem könnte die Reinforcement Learning Umgebung erweitert werden, indem ein längerer Buchungszeitraum, Rabatte und die Möglichkeit zur Stornierung betrachtet werden. Schlussendlich soll damit ermöglicht werden, dass sowohl die Modellierung als auch die darauf basierten Preisstrategien realitätsgetreuer werden.