

Eine Einordnung der ökonomischen Literatur zu Algorithmen und Künstlicher Intelligenz

Verein für Wettbewerbsökonomik

10.11.2022

Dr. Nicolas Eschenbaum



Heutigen Themen

Kurze „**Tour-de-Force**“ und persönliche Einschätzung der ökonomischen Aspekte:

1. Pricing-Algorithmen.
 - Kollusion und Absprachen.
 - Preisdiskriminierung.
2. «Consumer Steering» und «Recommender Algorithms».
3. Computational Antitrust.

Der **bisherige Forschungsschwerpunkt** in der wissenschaftlichen Literatur liegt auf **Preisalgorithmen** und Absprachen.

Algorithmic Collusion

Stillschweigende Kollusion als zentrales Bedenken

- **Algorithmen können Kollusion ermöglichen und stabilisieren**, aufgrund:
 - Der Möglichkeit umfangreiche Daten zu sammeln und auszuwerten, um die **Strategien** von Konkurrenten zu **erkennen**.
 - Einer **Vermeidung unabsichtlicher Abweichungen** von Absprachen («menschliche Fehler»).
 - Reduzierte Tendenz zu kurzfristigem Denken und entsprechender Abweichungsanreize.
 - **Sehr schnelle Reaktionen** auf Abweichungen durch Konkurrenten und entsprechende Bestrafung.
- Allgemein gibt es **drei mögliche Szenarien**:
 - Eine **explizite Koordination** auf bestimmte Algorithmen.
 - Die Koordination mithilfe einer «**third-party**», z.B. eines Repricing Anbieters.
 - Sowie der «**autonomous collusion**», also eigenständig erlernter Kollusion von konkurrierenden Algorithmen.
- **Stillschweigende, autonome Kollusion** als mögliche, **neue Herausforderung**.

Algorithmic Collusion

Algorithmen können kollusives Verhalten am Computer lernen

Das Konzept

- Der **Algorithmus setzt eigenständig einen Preis** abhängig von der beobachteten Umgebung.
- Ein **Lernprozess updated die Strategie** des Algorithmus auf Basis der vorherigen Performance.
- **Menschen wählen lediglich den Massstab**, anhand dessen Performance gemessen wird, sowie den Typ des Algorithmus.
- Zwei mögliche Ansätze in der Umsetzung
 - Empirische Schätzung von z.B. Nachfrage (-Elastizität) und eine Vorhersage des Effektes von Preisveränderungen.
 - «Model-free» Optimierung der Preise (Reinforcement Learning, RL).

Die Evidenz

- In Simulationen erreichen Algorithmen zumeist sehr hohe Preise und Gewinne (z.B. Calvano et al., 2019).
- Standardlogik von kollusiven Strategien ersichtlich: **reward-and-punishment**.
- Erste **empirische Studien** der Auswirkungen von Algorithmen auf Marktpreise **deuten auf höhere Preise** hin (z.B. Assad et al., 2021).
- **Preisalgorithmen auf Online-Plattformen** sind aber vermutlich sehr viel **simpler** als die untersuchten (z.B. Wieting & Sapi, 2022).
 - Im Prinzip komplexe «if-else» Konditionen.
 - Zudem können Algorithmen auch Effizienzen generieren.

Algorithmic Collusion

Extrapolation von „Autonomer Kollusion“ in die Praxis ist sehr problematisch

- Wie sehr die Resultate in die Praxis übertragen werden können ist unklar:
 - Die Strategieräume sind komplex und **konvergierte Strategien schwer zu interpretieren**.
 - Es braucht sehr **viele Iterationen**, bevor die Algorithmen konvergieren.
 - **Simulationsumgebungen** sind **stark vereinfacht** (konkret Bertrand-Spiele mit Logit-Demand oder sequenzielle Preisspiele).
 - **Relevanz der spezifischen untersuchten Algorithmen** in der Anwendung nicht offensichtlich (z.B. ist Q-Learning irrelevant in der Praxis).
 - Schlussfolgerungen werden auf Basis der **Trainingsumgebung** der Algorithmen gezogen.
- Strategien und kollusive Gewinne sind **nicht robust** (z.B. Eschenbaum, Mellgren & Zahn, 2021).
 - **Strategien sind sehr idiosynkratisch** – und nicht übertragbar auf neue Umgebungen oder Konkurrenten.
 - Analog zu «menschlicher Kollusion», die einen gemeinsamen Lernprozess benötigt (z.B. Byrne & De Roos, 2019).
 - Stattdessen zeigen Algorithmen **hochkompetitives Verhalten** (statisches Nash-GG) **ausserhalb der Trainingsumgebung**.

Algorithmic Collusion

Kollusion via der Koordination des Designs von Algorithmen

- **Passendes Design**, d.h. Parametrisierung und Typ des Algorithmus, **kann Algorithmische Kollusion robust machen** (Eschenbaum, Mellgren & Zahn, 2021).
 - Anpassungen in Simulationen lösen das „Extrapolationsproblem“ – **Kollusion ausserhalb der Trainingsumgebung**.
 - **Strategien** werden **weniger idiosynkratisch und simpler**, und dadurch übertragbar.
 - Indizien für „**signal-to-noise-ratio**“ Problem:
 - Mehr Informationen bedeuten ein stärkeres Signal („gut“), aber auch einen grösseren Strategieraum („schlecht“).
 - **Kontraintuitives** Ergebnis, dass ein Zugriff auf **mehr Daten** (z.B. Preise der Konkurrenten) **Kollusion erschwert**.
- Fazit: Unternehmen können ihre Strategien nicht nur direkt koordiniert, sondern auch **über das Algorithmusdesign**:
 - **Data Scientists** und Pricing Specialists als **zentrale Akteure**.
 - «State-of-the-art» Algorithmen in manchen Märkten zeigen **Designelemente**, die exakt **den Anpassungen in Simulationen entsprechen** und keine offensichtlichen Gründe haben.
 - **Sehr überraschend!** Simulationsumgebungen/Algorithmen sind viel simpler (bzw. strukturell anders) als Umsetzung in der Praxis.
 - Auch dokumentierte Algorithmen auf Online-Plattformen haben oft dezidierte Designelemente (z.B. price reset in der Nacht, Musolff, 2022).

Preisdiskriminierung

Was ist wirklich neu?

- Algorithmen können **individueller** und **präziser Kunden auswählen** und Preise anpassen, um im Extremfall individualisierte Preise zu wählen.
- „Oft diskutiert, nie beobachtet“.
- Grund: **in der Praxis** sind Unternehmen **limitiert** durch begrenzte Informationen und Daten
 - Aber, Rabattsysteme und Gruppierungen von Kunden können als bestmögliche Approximation verstanden werden.
 - Diese haben oft ein dynamisches Element – Preisdiskriminierung entwickelt sich im Zuge von Kundenentscheidungen (z.B. Buehler & Eschenbaum, 2021).
 - Präzisere «Segmentierung» kann daher aber von rationalen Agenten beeinflusst werden.
- Tatsächliche ökonomische Frage ist wie immer, ob Preisdiskriminierung schädlich ist.
 - Diskriminierung («high types») vs. Zugang («low types»).
 - «Fairness» Argumente spielen in Wettbewerbsökonomie keine Rolle.
- Somit im Kern nicht viel neues (**ökonomisch**).

Manipulation der Entscheidungsumgebung

Wichtiger Aspekt und hochaktuelles Forschungsthema

- Online-Plattformen insbesondere führen **umfangreiche A/B Tests** durch, um ihre Webseite und Algorithmen zu optimieren.
- Zentrale Beobachtung: Konsumenten tun sich mit **grossen Choice Sets** schwer.
 - Deshalb kann das «steuern» («**steering**») von Konsumentenentscheidungen **hochproblematisch** sein.
 - Höhere Preise und Provisionen, eine Umkehrung des Zusammenhangs von Preisen und Anzahl Wettbewerber, und niedrige Wohlfahrt und Konsumentenrente (Teh & Wright, 2022).
 - Und ebenso können Empfehlungen/Vorschläge («**recommender algorithms**») signifikante, **wettbewerbsschädliche Auswirkungen** haben.
 - Preiseffekte für Anbieter sind komplex und schwer vorhersagbar (z.B. de Corniere & de Nijs, 2016).
 - Konsumenten können zu Produkten mit hohen Provisionen geleitet werden (im «Extremfall» self-preferencing).
 - Mit Konsumenten, die «Fehler» machen, kann die Wohlfahrt stark sinken (z.B. Heidhues, Köster & Köszegi, 2022).
- Wie wird dieses Thema in die wettbewerbspolitische Praxis Eingang finden (abgesehen von «self-preferencing»)?

Computational Antitrust

Algorithmen als Werkzeug für Behörden

- Algorithmen bieten nicht nur neue Herausforderungen, sondern auch **Möglichkeiten**.
- Es gibt viele Beispiele des Einsatzes von Algorithmen und KI durch Behörden (Schrepel & Groza, 2022):
 - **Digitalisierung** vergangener Untersuchungen und Fälle, automatisierte Key-Words Suche.
 - **Automatisierte Aufbereitung** von Daten.
 - **Clustering** von Dokumenten und Fällen **basierend auf Themen**.
 - **Automatisierte Klassifizierung** von Beschwerden und eingereichten Dokumenten.
 - Kartell- und bid-rigging «**Screens**».
 - **Webscrape-Algorithmen** und Software, um **Konsumentenverhalten** auf Webseiten zu **imitieren**.
 - ...
- Harrington (2018) z.B. schlägt «**Sandbox**» **Umgebungen** vor, um Algorithmen explizit zu testen und zu analysieren.

Inhaltliches

- Algorithmen werden eine immer grössere Rolle in der wettbewerbpolitischen Praxis spielen.
- Die meisten Herausforderungen sind nicht neu, sondern «nur» in einem neuen Gewand.
- **Koordination via des Designs von Algorithmen** bisher **unterschätzt**, aber zentrale neue Herausforderung, denn
 - Direkte Absprachen sind «vertrautes Gelände».
 - «Third-party» Absprachen ebenfalls.
 - **Komplett autonome Kollusion** schlicht **unrealistisch**, so funktioniert die Anwendung von KI in der Praxis nicht.
- Explizite **Berücksichtigung von „behavioral“ Konsumenten unvermeidbar** in digitalen Märkten.

Praktisches

- Welche technischen Fähigkeiten brauchen Behörden **Inhouse**?
- Algorithmen sind in der Praxis entweder relativ simpel (meist bei kleineren Playern und Industrien), oder **extrem** komplex und nur für wenige Fachleute verständlich
 - Braucht es diese spezialisierten Fachleute Inhouse?
- Müssen Algorithmen für die Behördenarbeit von Mitarbeitenden programmiert werden?
 - Warum den nächsten Kartell-»Screen« nicht von KI-Experten programmieren lassen?

Vielen Dank für Ihre Aufmerksamkeit

Nicolas Eschenbaum


nicolas.eschenbaum@swiss-economics.ch

Swiss Economics, Ottikerstrasse 7, CH-8006 Zürich

www.swiss-economics.ch




Reward-and-Punishment



Quelle: Calvano et al., 2019, Figure 4.

[Zurück zu Algorithmic Collusion](#)

Gewinne ausserhalb der Trainingsumgebung



—○— Training —○— New Context —○— Re-Convergence

Quelle: Eschenbaum, Mellgren, Zahn, 2021, Figure 2.

Zurück zu Algorithmic Collusion

Price Reset in der Nacht





Figure 2: A Typical Cycle in the Pricing Data.



(a) The Reset Times of Daily Cycles

Quelle: Musolff, 2022, Figure 2 and Figure 5.

Zurück zu Algorithmic Collusion