

# Online Kombinatorische Optimierung unter Berücksichtigung von Gruppenfairness-Bedingungen

Seminar Künstliche Intelligenz SoSe 2025

Julian Vandeven

16.07.2025

# Agenda

- 1 Einleitung
- 2 Relevante Vorarbeiten
- 3 Ergebnisse
- 4 Zusammenfassung und Diskussion

- 1 Einleitung
- 2 Relevante Vorarbeiten
- 3 Ergebnisse
- 4 Zusammenfassung und Diskussion

- Titel: Online Combinatorial Optimization with Group Fairness Constraints
- Autoren: Golrezaei, Negin and Niazadeh, Rad and Patel, Kumar Kshitij and Susan, Fransisca
- Konferenz: International Joint Conferences on Artificial Intelligence Organization
- Seitenzahlen: 394–402
- Jahr: 2024

- Empfehlungsdienste versuchen Nutzerengagement aller Nutzer (Marktanteil) zu maximieren
- Maximierung vom Marktanteil kann bei unterschiedlichen Präferenzen zu unfairen Behandlung mancher Nutzer führen
- Personenbezogene Daten können individuelle Empfehlungen liefern, sind aber häufig nicht zugänglich
- Golrezaei u. a. 2024 liefert eine Lösung, die gleichzeitig:
  - 1 Den Marktanteil maximiert
  - 2 Faire Behandlung aller Nutzer sicherstellt

# Beispiel: Filmempfehlungen I

Ziel: Eine Top-3 Filmempfehlung für zwei Gruppen finden, die Filmbewertungen maximiert und keine Gruppe benachteiligt

## Gruppe 1

- Präferenzen
  - ① Action
  - ② Science-Fiction
  - ③ Horror

## Gruppe 2

- Präferenzen
  - ① Dokumentationen
  - ② Animation
  - ③ Science-Fiction

Marktanteil berechnen:

- vorgeschlagener Film 1. Präferenz  $\rightarrow 3 \star$  Bewertung
- vorgeschlagener Film 2. Präferenz  $\rightarrow 2 \star$  Bewertung
- vorgeschlagener Film 3. Präferenz  $\rightarrow 1 \star$  Bewertung
- sonst  $\rightarrow 0 \star$  Bewertung

Filmvorschlag 1: Actionfilm, Science-Fiction-Film, Horrorfilm

Gruppe 1

- Präferenzen
  - 1 Action
  - 2 Science-Fiction
  - 3 Horror

Gruppe 2

- Präferenzen
  - 1 Dokumentationen
  - 2 Animation
  - 3 Science-Fiction

Marktanteil berechnen:

- Marktanteil Gruppe 1 = 6 \*
- Marktanteil Gruppe 2 = 1 \*
- Marktanteil gesamt = 7 \*

Filmvorschlag 2: Animationsfilm, Science-Fiction-Film, Horrorfilm

## Gruppe 1

- Präferenzen
  - 1 Action
  - 2 Science-Fiction
  - 3 Horror

## Gruppe 2

- Präferenzen
  - 1 Dokumentationen
  - 2 Animation
  - 3 Science-Fiction

Marktanteil berechnen:

- Marktanteil Gruppe 1 = 3 \*
- Marktanteil Gruppe 2 = 3 \*
- Marktanteil gesamt = 6 \*

## Filmvorschlag 1:

- Marktanteil Gruppe 1 = 6 ★
- Marktanteil Gruppe 2 = 1 ★
- Marktanteil gesamt = 7 ★

## Filmvorschlag 2:

- Marktanteil Gruppe 1 = 3 ★
- Marktanteil Gruppe 2 = 3 ★
- Marktanteil gesamt = 6 ★

## Beobachtung:

- Filmvorschlag 1 liefert höheren gesamten Marktanteil, Gruppe 2 erhält deutlich geringeren Marktanteil
- Filmvorschlag 2 liefert niedrigeren Marktanteil, beide Gruppen erhalten gleichen Marktanteil

# Formulierung des Problems I

Formal	Beispiel: Filmempfehlungen
$L :=$ Anzahl demographischer Gruppen	$L = 2$ , Gruppe 1 und 2
$\mathcal{F} :=$ Menge aller Rewardfunktionen	Alle möglichen Filmbewertungsfunktionen
$\{f_t^i \in \mathcal{F}\}_{i \in [L]} :=$ Menge von Rewardfunktionen zum Zeitpunkt $t \in [T]$ für Gruppen $i \in [L]$	Rewardfunktionen gibt an, wie sehr ein Film den Nutzern gefällt
$\{\tau^i\}_{i \in [L]} :=$ Menge von Fairness-Schwellenwerten	$\tau^1 = \tau^2 = 2$ , Gruppe 1 und 2 erhalten mindestens 2 $\star$

# Formulierung des Problems II

- Algorithmus ALG wählt in Zeitschritt  $t \in [T]$  Aktion  $x_t$  nach Wahrscheinlichkeitsverteilung  $P$  und erhält:
  - im Full-Information-Setting die Funktionen  $\{f_t^i \in \mathcal{F}\}_{i \in [L]}$
  - oder im Bandit-Information-Setting nur die Funktionswerte  $\{f_t^i(x_t) \in \mathcal{F}\}_{i \in [L]}$
- ALG erhält als Reward  $\sum_{i \in [L]} f_t^i(x_t)$
- Der erwartete Reward für Gruppe  $i$  zum Zeitpunkt  $t$  entspricht dem Mittelwert  $f^i(x)$ :

$$\mathbb{E}[f_t^i(x) | \mathcal{H}_t, x] = f^i(x)$$

- $\mathcal{H}_t :=$  aktueller Informationsstand zum Zeitpunkt  $t$  auf Basis vorheriger Funktionen und Aktionen

# Formulierung des Problems III

Die zu maximierende online-Benchmark mit Fairness-Bedingung, Online-OPT, mathematisch ausgedrückt:

$$\begin{aligned} & \max_P \frac{1}{T} \sum_{t,i} \mathbb{E}_{x_t \sim P} [f_t^i(x_t) | \mathcal{H}_t] \\ & \text{s.d. } \frac{1}{T} \sum_t \mathbb{E}_{x_t \sim P} [f_t^i(x_t) | \mathcal{H}_t] \geq \tau^i, \forall i \in [L] \\ & = \max_P \sum_i \mathbb{E}_{x \sim P} [f^i(x)] \\ & \quad \text{s.d. } \mathbb{E}_{x \sim P} [f^i(x)] \geq \tau^i, \forall i \in [L] \end{aligned} \tag{1}$$

- Die Werte  $\tau^i, \forall i \in [L]$  beeinflussen wie stark Fairness bei Maximierung vom Marktanteil berücksichtigt wird
- Für  $\tau^i = 0, \forall i \in [L]$ , wird nur der Marktanteil ohne Fairness-Bedingungen maximiert

# Formulierung des Problems IV

durchschnittlicher  $\gamma$ -Regret:

$$\gamma \cdot \text{Online-OPT} - \frac{1}{T} \sum_{i \in [L], t \in [T]} \mathbb{E}_{x_t, f_t^i} [f_t^i(x_t) | \mathcal{H}_t] \quad (2)$$

Fairness-Bedingung wird für alle Gruppen approximativ erfüllt:

$$\gamma \cdot \tau^i \approx \frac{1}{T} \sum_{t \in [T]} \mathbb{E}_{x_t, f_t^i} [f_t^i(x_t) | \mathcal{H}_t] \quad (3)$$

- 1 Einleitung
- 2 Relevante Vorarbeiten**
- 3 Ergebnisse
- 4 Zusammenfassung und Diskussion

- Maschinelles Lernen wird immer häufiger bei Optimierung von algorithmischer Fairness eingesetzt
- Fokus bei Vorarbeiten mehr auf individueller Fairness, weniger auf Gruppenfairness
- Vorteile der Resultaten aus Golrezaei u. a. 2024 gegenüber Vorarbeiten:
  - ① Algorithmus kann mit Gruppenfairness umgehen
  - ② Algorithmus ist leicht zu implementieren und numerisch stabiler als vergleichbarer Algorithmus aus Tang und Yuan 2023
  - ③ liefert auch Lösung für online Szenarien, welche in der Praxis häufiger vorkommen

- 1 Einleitung
- 2 Relevante Vorarbeiten
- 3 Ergebnisse**
- 4 Zusammenfassung und Diskussion

$\gamma$ -no-Regret online Orakel  $\mathcal{Z}$

- $\mathcal{Z}$  generiert Folge von Wahrscheinlichkeitsverteilungen  $\{P_t\}_{t \in [T]}$ , s.d. durchschnittlicher Regret mit wachsendem  $T$  abnimmt:

$$\max_x \frac{\gamma}{T} \sum_{t \in [T]} f_t(x) - \frac{1}{T} \mathbb{E}_{x_t \sim P_t} [f_t(x_t)] = \frac{o(T)}{T} \quad (4)$$

No-Regret Online Linear Optimization (OLO) Orakel  $\mathcal{A}$

- durchschnittlicher Regret  $R^{\mathcal{A}}(T)$  geht für  $T \rightarrow \infty$  gegen Null

$$R^{\mathcal{A}}(T) := \frac{1}{T} \sum_{t \in [T]} \langle \ell_t, x_t \rangle - \inf_x \frac{1}{T} \sum_{t \in [T]} \langle \ell_t, x \rangle \quad (5)$$

- $\ell_t$  := Loss-Vektor misst Differenz zwischen Reward und Schwellenwert für alle Gruppen zum Zeitpunkt  $t$

---

**Algorithm** Robust Online Algorithm (vereinfacht)

---

- 1: Initialisiere Gruppengewichtung  $\alpha_1$
  - 2: **for**  $t = 1, \dots, T$  **do**
  - 3:     Max-Spieler erhält  $P_t$  von  $\mathcal{Z}$
  - 4:     Max-Spieler wählt  $x_t \sim P_t$
  - 5:     Max-Spieler bekommt Feedback:  
       Full-Information-Setting:  $\{f_t^i \in \mathcal{F}\}_{i \in [L]}$   
       Bandit-Information-Setting:  $\{f_t^i(x_t) \in \mathcal{F}\}_{i \in [L]}$
  - 6:     Min-Spieler erhält Loss-Vektor  $\ell_t$
  - 7:     Min-Spieler setzt  $\alpha_{t+1} \leftarrow \mathcal{A}(\alpha_t, \{\ell_k\}_{1 \leq k \leq t})$
  - 8: **end for**
- 


- Max-Spieler maximiert den Marktanteil
- Min-Spieler zwingt Max-Spieler benachteiligte Gruppen in nächster Iteration zu verbessern

# Aufbau: Auswertung vom Robust Online Algorithm

Ziel: Eine optimale Top-5 Filmempfehlung berechnen


- Marktanteil: Wahrscheinlichkeit, dass Nutzer einen der empfohlenen Filme anschaut
- Gruppeneinteilung nach Geschlecht
- Verwendeter Datensatz: MovieLens 1M Dataset
- Vorgehen:
  - Wähle einen Fairness-Schwellenwert  $\tau$
  - Berechne über 50 Auswertungen den durchschnittlichen Marktanteil vom offline Algorithmus und Robust Online Algorithm
  - Wiederhole den vorherigen Schritt mit neuen Fairness-Schwellenwerten
- Implementierung Robust Online Algorithm
  - Orakel  $\mathcal{Z}$ : Multiplicative Weight/Hedge Algorithm
  - Orakel  $\mathcal{A}$ : Projected Online Gradient Descent

# Auswertung: Gesamter Marktanteil offline




- vertikale gestrichelte Linie markiert Grenze von erreichbaren Fairness-Schwellenwert
- Marktanteil bleibt bei für  $\tau < 0.74$  nahezu konstant
- Marktanteil sinkt für  $0.74 \leq \tau \leq 0.76$ , warum?
- Wenn Fairness-Schwellenwerte nicht mehr erreichbar, wird Marktanteil ohne Fairness-Bedingungen maximiert

# Auswertung: Marktanteil pro Gruppe offline




- Gestrichelte Gerade markiert Fairness-Schwellenwert
- Für  $0.74 \leq \tau \leq 0.76$  versucht der offline Algorithmus den Marktanteil der benachteiligten Gruppe (female) zu verbessern  $\rightarrow$  Marktanteil anderer Gruppe (male) sinkt

# Auswertung: Gesamter Marktanteil online




- Marktanteil steigt bei erreichbaren Fairness-Schwellenwerten proportional zum Schwellenwert
- Marktanteil sinkt für  $0.74 \leq \tau \leq 0.76$ , warum?
- Marktanteil erreicht globales Maximum bei nicht erreichbaren Fairness-Schwellenwerten

# Auswertung: Marktanteil pro Gruppe online



- Für  $0.74 \leq \tau \leq 0.76$  versucht der online Algorithmus den Marktanteil der benachteiligten Gruppe (female) zu verbessern  $\rightarrow$  Marktanteil anderer Gruppe (male) sinkt

# Auswertung: Verletzung der Fairness-Schwellenwerte



- Horizontale gestrichelte Linie markiert erlaubte Verletzung der Fairness-Schwellenwerte
- Online werden Fairness-Schwellenwerte früher und stärker verletzt als Offline

- 1 Einleitung
- 2 Relevante Vorarbeiten
- 3 Ergebnisse
- 4 Zusammenfassung und Diskussion**

## Stärken vom Robust Online Algorithm:

- Der Robust Online Algorithm berücksichtigt maximiert den Marktanteil unter Berücksichtigung von Fairness-Bedingungen für Gruppen
- Auswertungen auf dem MovieLens 1M Dataset bestätigen praktische Anwendbarkeit vom Robust Online Algorithm

## Grenzen vom Robust Online Algorithm:

- Fairness-Bedingungen können nicht über die Zeit angepasst werden
- Strategisches Nutzerverhalten wird nicht berücksichtigt

- Wer profitiert von den Resultaten?

- Wer profitiert von den Resultaten?
  - Betreiber digitaler Marktplätze können den Robust Online Algorithm für Produktvorschläge nutzen
  - Fairness sinnvoll, weil bestehende Kunden bleiben bestehen und neue Kunden werden angezogen

- Wer profitiert von den Resultaten?
  - Betreiber digitaler Marktplätze können den Robust Online Algorithm für Produktvorschläge nutzen
  - Fairness sinnvoll, weil bestehende Kunden bleiben bestehen und neue Kunden werden angezogen
- Wie geeignet ist die Wahl vom MovieLens 1M Dataset?

- Wer profitiert von den Resultaten?
  - Betreiber digitaler Marktplätze können den Robust Online Algorithm für Produktvorschläge nutzen
  - Fairness sinnvoll, weil bestehende Kunden bleiben bestehen und neue Kunden werden angezogen
- Wie geeignet ist die Wahl vom MovieLens 1M Dataset?
  - Streaminganbieter nutzen personenbezogene Daten, um personalisierte Vorschläge zu liefern, daher Filmempfehlungen eher unpassend
  - Alternative: Verteilung von Impfstoff in unterschiedlichen Regionen, gruppiert nach Regionen der Bewohner

-  Custers, Bart u. a. (2019). *EU personal data protection in policy and practice*. Bd. 29. Springer.
-  Golrezaei, Negin u. a. (2024). „Online Combinatorial Optimization with Group Fairness Constraints“. In: *Proceedings of the Thirty-Third International Joint Conference on Artificial Intelligence, IJCAI-24*. International Joint Conferences on Artificial Intelligence Organization, S. 394–402.
-  Harper, F Maxwell und Joseph A Konstan (2015). „The movielens datasets: History and context“. In: *Acm transactions on interactive intelligent systems (tiis)* 5.4, S. 1–19.
-  Niazadeh, Rad u. a. (2021). „Online learning via offline greedy algorithms: Applications in market design and optimization“. In: *Proceedings of the 22nd ACM Conference on Economics and Computation*, S. 737–738.



Tang, Shaojie und Jing Yuan (2023). „Beyond submodularity: a unified framework of randomized set selection with group fairness constraints“. In: *Journal of Combinatorial Optimization* 45.4, S. 102.

# Fragen?

## 5 Anhang

**Require:**  $\mathcal{Z}$ :  $\gamma$ -no-Regret online approximations Orakel mit Entscheidungsraum  $\Delta(\mathcal{C})$ ;  $\mathcal{A}$ : no-Regret OLO Orakel mit Entscheidungsraum  $[0, \frac{L}{\delta}]^L$ ;  $\delta$ : Toleranz der Fairness-Abweichung;  $T$ : gesamte Zeitperiode

**Ensure:** eine zufällig gewählte Aktion pro Zeitschritt

- 1:  $\alpha_1 \leftarrow (\frac{L}{\delta}, \frac{L}{\delta}, \dots, \frac{L}{\delta})$
- 2: **for**  $t = 1, \dots, T$  **do**
- 3:     Max-Spieler erhält  $P_t \in \Delta(\mathcal{C})$  von  $\mathcal{Z}$
- 4:     Max-Spieler wählt  $x_t \sim P_t$
- 5:     Max-Spieler bekommt als Feedback:
  - im Full-Information-Setting: Funktionen  $\{f_t^i \in \mathcal{F}\}_{i \in [L]}$
  - im Bandit-Information-Setting: Funktionswerte  $\{f_t^i(x_t) \in \mathcal{F}\}_{i \in [L]}$

- 6: Min-Spieler erhält den Loss-Vektor:

$$\ell_t \leftarrow \begin{bmatrix} f_t^1 - \gamma \tau^1 \\ \vdots \\ f_t^i - \gamma \tau^i \\ \vdots \\ f_t^L - \gamma \tau^L \end{bmatrix}$$

- 7: Min-Spieler setzt  $\alpha_{t+1} \leftarrow \mathcal{A}(\alpha_t, \{\ell_k\}_{1 \leq k \leq t})$   
8: Orakel  $\mathcal{Z}$  bekommt als Feedback:  
im Full-Information-Setting:

$$g_t := \sum_{i \in [L]} (1 + \alpha_t^i) f_t^i$$

im Bandit-Information-Setting:

$$g_t(x_t) = (1 + \alpha_t^i) f_t^i(x_t)$$

9: **end for**

- 1 Folge gewählter Aktionen ist für alle Gruppen  $\gamma$ -approximativ fair
- 2 Abweichung von Fairness-Schwellenwerten konvergiert für  $T \rightarrow \infty$  gegen  $\delta f_{\max}$ 
  - $\delta$  := Schwellenwert für Verletzung der Fairness-Bedingungen
  - $f_{\max}$  := maximaler Wert den eine Rewardfunktion  $f_t^i$  annehmen kann

$$\begin{aligned} & \frac{1}{T} \sum_{t \in [T]} \mathbb{E}_{x_t \sim P_t, f_t^i} [f^i(x_t) | \mathcal{H}_t] \\ & \geq \gamma \cdot \tau^i - \delta f_{\max} - \frac{\delta}{L} R^{\mathcal{A}}(T) - \frac{\delta}{L} R^{\mathcal{Z}}(T) \end{aligned}$$

- ③ Gesamter Reward entspricht Faktor  $\gamma$  vom optimalen Wert Online-OPT
- $R^Z(T)$  misst Abweichung vom berechneten Marktanteil (ohne Fairness-Bedingungen) gegenüber optimalem Marktwert
  - $R^A(T)$  misst sehr die Fairness-Bedingungen verletzt werden

$$\begin{aligned} & \frac{\gamma}{T} \cdot \text{Online-OPT} - \frac{1}{T} \sum_{i \in [L], t \in [T]} \mathbb{E}_{x_t \sim P_t, f_t^i} [f_t^i(x_t) | \mathcal{H}_t] \\ & \leq R^A(T) + R^Z(T) \end{aligned}$$

MovieLens 1M Dataset (bestehend aus 3 Dateien)

- 1 *ratings*-Datei enthält Nutzer, Film und Bewertung vom Nutzer
- 2 *users*-Datei enthält Informationen über Nutzer
- 3 *movies*-Datei enthält Informationen über Filme

Aktueller Informationsstand zum Zeitpunkt  $t$  auf Basis vorheriger Funktionen und Aktionen:

$$\mathcal{H}_t := \sigma \left( \{f_k^i\}_{i \in [L], k \in [t-1]}, \{x_k\}_{k \in [t-1]} \right)$$

Beispiel  $\sigma$ -Algebra:

- $\Omega = \{a, b, c, d\}$
- $\sigma$ -Algebra  $\Sigma = \{\emptyset, \{a, b\}, \{c, d\}, \{a, b, c, d\}\}$
- $\Sigma$  ist  $\sigma$ -Algebra, wenn:
  - 1  $\Omega \in \Sigma$
  - 2 wenn  $B \in \Sigma$ , dann auch  $B^c \in \Sigma$
  - 3 wenn  $A_1, A_2, \dots \in \Sigma$ , dann auch  $\bigcup_{i \in \mathbb{N}} A_i \in \Sigma$

- Für kegelförmige geschlossene Funktionsklasse  $\mathcal{F}$  gilt:

$$\forall f_1, f_2 \in \mathcal{F}, \forall c_1, c_2 \geq 0 : c_1 f_1 + c_2 f_2 \in \mathcal{F}$$

- Beispiel:

- $f_1$  := Bewertungsfunktion für Frauen
- $f_2$  := Bewertungsfunktion für Männer
- $c_1 f_1 + c_2 f_2$  := gewichteter Durchschnitt beider Bewertungsfunktionen ebenfalls in  $\mathcal{F}$  enthalten

## Full-Information-Setting

- schnelles Lernen, da alle Informationen bekannt
- theoretisches Ideal als Referenz für die Bewertung von Algorithmen
- Fairness-Bedingungen können gut eingehalten werden
- selten realistisch, da Berechnungsaufwand zu teuer

## Bandit-Setting

- realistische praxisnahe Annahme
- langsames Lernen wie beim Full-Information-Setting
- höheres Risiko für Verletzung von Fairness-Bedingungen