



## Regret Minimization

Alexander Kauer  
Freie Universität Berlin

05.11.2013

## Allgemeines

Motivation

Definitionen

## External Regret Minimization

Allgemeines

Algorithmen zur External Regret Minimization

Das Partial Information Model

## Swap Regret Minimization

Definitionen

Reduktion von External Regret zu Swap Regret

- ▶ Spiele können in unsicheren oder unbekanntem Umgebungen stattfinden:
  - ▶ Keine Informationen über die Strategien der anderen Spieler gegeben.
  - ▶ Keine Informationen über mögliche Gewinne oder Verluste gegeben.
- ▶ Es werden Online-Algorithmen benötigt, die trotz dieser Einschränkungen möglichst gute Ergebnisse erzielen.

- ▶ Menge der verfügbaren Aktionen des Spielers:  $X = \{1, 2, \dots, N\}$ .
- ▶ Online-Algorithmus  $H$  wählt zum Zeitpunkt  $t$  eine Wahrscheinlichkeitsverteilung  $p^t$  über  $X$  (sprich: die Strategie für den Spieler).
- ▶ Verlustvektor  $l^t \in [0, 1]^N$  wird anschließend ermittelt und  $H$  erfährt Verlust  $l_H^t = \sum_{i=1}^N p_i^t l_i^t$ .
- ▶ Gesamtverlust bis Zeitpunkt  $T$  der  $i$ -ten Aktion ist  $L_i^T = \sum_{t=1}^T l_i^t$ .
- ▶ Gesamtverlust von  $H$  bis Zeitpunkt  $T$  ist  $L_H^T = \sum_{i=1}^N l_H^t$ .

- ▶ Je nach *Information Model* erhält  $H$  eine unterschiedliche Menge an Informationen:
  - ▶ Im *Full Information Model* erhält  $H$  den kompletten Verlustvektor  $I^t$  und erfährt einen Verlust von  $I_H^t = \sum_{i=1}^N p_i^t I_i^t$ .
  - ▶ Im *Partial Information Model* erhält  $H$  hingegen ausschließlich den gesamten Verlust  $I_H^t$ .
- ▶ Wenn nicht anderweitig vermerkt, dann wird das *Full Information Model* genutzt.

## Allgemeines zur External Regret Minimization

- ▶ Gegeben: Menge an Algorithmen  $\mathcal{G}$  für das Spiel.
  - ▶ Im einfachsten Fall Algorithmen, welche immer die gleiche Aktion aus  $X$  wählen.
- ▶ Ziel: Möglichst nah an den besten dieser Vergleichsalgorithmen bezüglich der Verlustminimierung zu kommen.
- ▶ Sei  $L_{\mathcal{G},\min}^T = \min_{g \in \mathcal{G}} L_g^T$  der geringste Verlust, der von einem der Vergleichsalgorithmen erzeugt wird.
- ▶ Dann bezeichnet das External Regret  $R_{\mathcal{G}} = L_H^T - L_{\mathcal{G},\min}^T$  den Abstand zum besten dieser Vergleichsalgorithmen, welchen es zu minimieren gilt.







## Randomized-Greedy-Algorithmus

- ▶ Erweiterung des Greedy-Algorithmus mit Auswahl einer Wahrscheinlichkeitsverteilung  $p^t$  statt einer festen Aktion  $x^t$ :

Start:  $p_i^1 := \frac{1}{N}$

Zeitpunkt  $t$ :  $S^{t-1} := \{j : L_j^{t-1} = L_{\min}^{t-1}\}$

$$p_i^t := \begin{cases} \frac{1}{|S^{t-1}|} & \text{falls } i \in S^{t-1} \\ 0 & \text{sonst} \end{cases}$$

### ▶ Satz

*Für den Randomized-Greedy-Algorithmus gilt für jede beliebige Reihenfolge an Verlusten*

$$L_{RG}^T \leq (\ln N) + (1 + \ln N)L_{\min}^T$$

*(ohne Beweis)*

## Polynomial-Weights-Algorithmus

- ▶ Einbeziehung aller Aktionen in die Auswahl über Gewichte  $w^t$  über eine Wahrscheinlichkeitsverteilung:

Start:  $w_i^1 := 1, p_i^1 := \frac{1}{N}, i \in X$

Zeitpunkt  $t$ :  $w_i^t := w_i^{t-1}(1 - \eta l_i^{t-1})$

$p_i^t := \frac{w_i^t}{W^t}$  mit  $W^t := \sum_{i \in X} w_i^t$

### ▶ Satz

Für den Polynomial-Weights-Algorithmus gilt mit  $\eta \leq 0.5$ , jeder Verlustvektorsequenz und jedem  $k \in X$

$$L_{PW}^T \leq L_k^T + \eta Q_k^T + \frac{\ln N}{\eta}$$

mit  $Q_k^T = \sum_{t=1}^T (l_k^t)^2$ . Setzt man  $\eta = \min\{\sqrt{\frac{\ln N}{T}}, 0.5\}$ , dann ergibt sich mit dem Wissen von  $Q_k^T \leq T$  die Ungleichung  $L_{PW}^T \leq L_{\min}^T + 2\sqrt{T \ln N}$ .



## Untere Grenzen für External Regret Minimization

- ▶ Der Polynomial-Weights-Algorithmus verhält sich bzgl. unterer Grenze nahezu optimal. Es gilt für jeden Algorithmus:
- ▶ Für kleine  $T < \log_2 N$ :  $R \in \Omega(T)$
- ▶ Für alle  $T$ :  $R \in \Omega(\sqrt{T})$

## Untere Grenzen für External Regret Minimization

## ▶ Satz

Sei  $T < \log_2 N$ . Dann gibt es für jeden Algorithmus  $A_1$  eine Verlustvektorsequenz, wodurch sich zwingend  $E[L_{A_1}^T] = \frac{T}{2}$  und  $L_{\min} = 0$  ergeben.

## ▶ Beweis.

Setze zu jedem Zeitpunkt  $t$  den Verlustvektor auf 1, falls es im Zeitpunkt  $t - 1$  einen Verlustvektor gab und  $i$  in diesem 1 war. Setze von den restlichen Elementen jeweils die Hälfte auf 0 und 1.

Somit ergeben sich  $E[L_{A_1}^T] = \frac{T}{2}$  als auch  $L_{\min} = 0$ . □

## Untere Grenzen für External Regret Minimization

### ► Satz

Angenommen  $N = 2$ . Dann gibt es für jeden Algorithmus  $A_2$  eine Verlustvektorsequenz, wodurch sich zwingend  $E[L_{A_2}^T - L_{\min}] \in \Omega(\sqrt{T})$  ergibt.

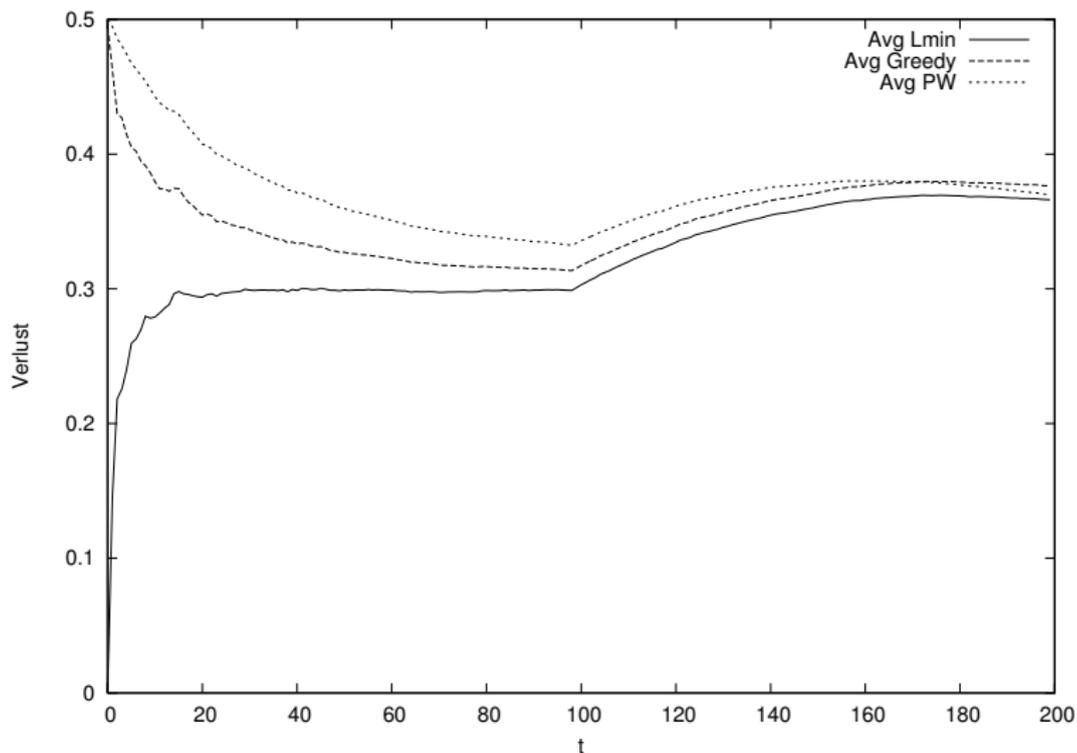
### ► Beweis.

- Zu Zeitpunkt  $t$  werfe Münze und setze  $I^t := z_1 = (0, 1)$  oder  $I^t := z_2 = (1, 0)$ .
- Nach  $T$  Würfeln ergeben sich  $\frac{T}{2} + y$  Verluste  $z_1$  und  $\frac{T}{2} - y$  Verluste  $z_2$  mit  $\frac{T}{2} - L_{\min} = |y|$ .
- Nun wird die untere Grenze für  $E[|y|]$  benötigt; Diese ergibt sich aus der Wahrscheinlichkeit von  $y$  mit  $\binom{T}{0.5T+y} \cdot 2^{-T} \in \mathcal{O}(\frac{1}{\sqrt{T}})$  nach Sterling zu

$$E[|y|] \in \Omega(\sqrt{T})$$



- Weiterhin kann jeder andere Fall mit  $N > 2$  auf  $N = 2$  zurückgeführt werden, indem an allen Positionen außer den ersten beiden ausschließlich immer ein Verlust von 1 über den Verlustvektor generiert wird und ansonsten wie oben verfahren wird.



- ▶ Problem bei diesen Betrachtungen: Oft bekommt Algorithmus  $H$  nur den Gesamtverlust  $\sum_i p_i^t l_i^t$  und nicht  $I^t \in [0, 1]^N$  mitgeteilt.
- ▶ Idee: Zerteilen Zeitpunkte  $1, \dots, T$  in  $K$  Blöcke  $B^\tau$  und führen pro Block “Erkundungen” aus und nutzen sonst während jedes Blocks die gleiche Auswahl  $p^\tau$ .
- ▶ Anschließend geben wir den durchschnittlichen Verlust  $c_i^\tau = \sum_{t \in B^\tau} \frac{p_i^\tau \cdot l_i^t}{|B^\tau|}$  an einen  $R$  Regret Algorithmus  $O$ , welcher anhand dessen die Verteilung für den nächsten Block  $B^{\tau+1}$  bestimmt (und ignorieren zunächst, dass wir kein  $I^t$  erhalten..).

## Das Partial Information Model

- ▶ Weiterhin sei  $C_i^K = \sum_{\tau=1}^K c_i^\tau$  und  $C_{\min}^K = \min_i C_i^K$ .
- ▶ Dann ergibt sich für  $O$  für die Sequenz der  $c^\tau$  maximal ein Verlust von  $C_{\min} + R$ .
- ▶ Und unter Einbeziehung aller Zeitpunkte ergibt sich somit ein Verlust von 
$$L_O^T = \sum_{\tau=1}^K \sum_{t \in B^\tau} p^\tau \cdot I^t = \frac{T}{K} \sum_{\tau=1}^K p^\tau \cdot c^\tau \leq \frac{T}{K} (C_{\min}^K + R)$$

- ▶ Jetzt muss  $H$  so entworfen werden, sodass trotz der Erkundungsphase  $L_O^T$  erhalten bleibt.
- ▶ Statt  $c^\tau$  zu generieren, generiere stattdessen eine Zufallsvariable  $c'^\tau$  mit  $E[c'^\tau] = c^\tau$ :
  1. Wähle für jedes ein  $i \in X$  zufällig  $t_i \in B^\tau$  mit  $i \neq j \rightarrow t_i \neq t_j$ .
  2. Spiele zum Zeitpunkt  $t_i$  Aktion  $i$  mit Wahrscheinlichkeit 1 und setze  $c'_i{}^\tau$  auf den erzielten Verlust. Somit gilt  $E[c'^\tau] = c^\tau$ .
  3. Ansonsten spiele nach Verteilung  $p^\tau$ .
- ▶ Somit ergibt sich im Erwartungswert  $L_O^T$  zzgl. der Verluste beim Erkunden:  
$$E[L_H^T] \leq NK + \frac{T}{K} (C_{\min}^K + R).$$

## Swap regret: Definitionen

- ▶ Eine Modification Rule ist eine Funktion  $F$ , welche sämtliche in Vergangenheit als auch die aktuell vom Algorithmus selektierte Strategie erhält und womöglich eine neue Strategie zurückliefert, welche stattdessen gespielt werden soll.  $F^t$  beschreibt die Funktion zum Zeitpunkt  $t$ .
- ▶ Für  $x_1, b_1, b_2 \in X$  sei  $\text{switch}_i(x_1, b_1, b_2)$  für Spieler  $i$  die folgende Funktion:

$$\text{switch}_i(x_1, b_1, b_2) = \begin{cases} b_2, & \text{falls } x_1 = b_1 \\ x_1, & \text{sonst} \end{cases}$$

- ▶ Gegeben eine Modification Rule  $F$  (und  $s_i(x) = s_i(x_i, x_{-i}) = I_H^t$  mit  $x$  als Verteilungsvektor aller Spieler, siehe vorherige Vorträge), lässt sich Regret allgemeiner definieren:

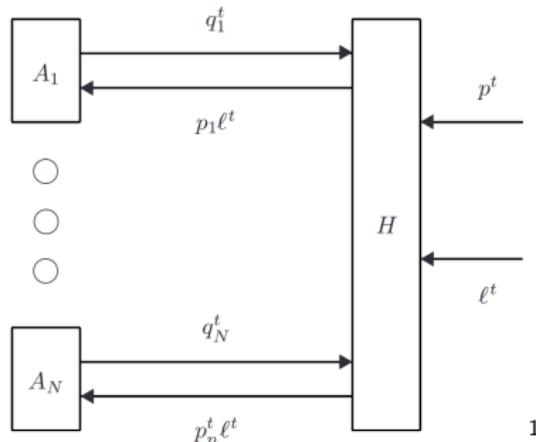
$$\text{regret}_i(x, F) = s_i(x) - s_i(F(x_i), x_{-i})$$

- ▶ Falls  $F(x_1) = \text{switch}_i(x_1, b_1, b_2)$ , dann handelt es sich um Swap Regret.

- ▶ Mit diesen Definitionen kann man nun das korrelierte Equilibrium anders auffassen:
- ▶ Ein Spiel mit den Spielern  $M = \{1, \dots, m\}$  und den gewählten Strategien  $x$  der Spieler befindet sich in einem korreliertem Equilibrium genau dann, wenn gilt  $\forall i \in M \forall F : X_i \rightarrow X_i E[\text{regret}_i(x, F)] \leq 0$

## External Regret zu Swap Regret: Idee

- ▶ Um einen Algorithmus  $H$  mit gutem Swap Regret zu erhalten, kann man einen Algorithmus  $A$  mit (gutem) External Regret  $R$  wiederverwenden.
- ▶ Idee: Wir nutzen  $N$  Instanzen  $A_1, \dots, A_N$ , kombinieren die gewählten Wahrscheinlichkeiten  $q_i$  zu einem  $p$  und geben den Verlust  $l$  abhängig von  $p$  wieder an die  $A_i$  zurück.



1

<sup>1</sup>aus Nisan, Roughgarden, Tardos, Vazirani: Algorithmic Game Theory, Seite 92

## External Regret zu Swap Regret

- ▶ Führe zu jedem Zeitpunkt  $t$  die  $A_i$  aus und erhalte jeweils eine Verteilung  $q_i$
- ▶ Berechne einzelne Verteilung  $p^t$  mit  $p_j^t = \sum_i p_i^t q_{i,j}^t$  bzw.  $p^t = p^t Q^t$ , wobei  $Q^t$  eine Matrix aus den  $q_{i,j}^t$  darstellt.
  - ▶  $p^t = p^t Q^t$  ist immer und effizient lösbar.
  - ▶ Erste Möglichkeit zur Betrachtung:  $p_j^t$  selektiert Aktion  $j$  mit gewisser Wahrscheinlichkeit.
  - ▶ Zweite Möglichkeit zur Betrachtung:  $p_i^t$  selektiert  $A_i$  mit gewisser Wahrscheinlichkeit, welche dann die Aktion wählt.
- ▶ Nachdem  $I$  erhalten, gebe jedem  $A_i$  sein  $p_i^t I^t$  zurück.
  - ▶ Somit erhält jedes  $A_i$  einen Verlust von  $(p_i^t I^t) \cdot q_i^t = p_i^t (q_i^t \cdot I^t)$
- ▶ Zusammen ergibt sich  $\forall i, j \in \{1, \dots, N\} \sum_{t=1}^T p_i^t (q_i^t \cdot I^t) \leq \sum_{t=1}^T p_i^t I_j^t + R.$

## External Regret zu Swap Regret

- ▶ Zusammen ergibt sich  $\forall i, j \in \{1, \dots, N\} \sum_{t=1}^T p_i^t (q_i^t \cdot l^t) \leq \sum_{t=1}^T p_i^t l_j^t + R$ .
- ▶ Wenn man die Verluste über alle  $A_i$  summiert, ergibt sich  $\sum_i p_i^t (q_i^t \cdot l^t) = p^t Q^t l^t = p^t l^t$ , da  $p^t = p^t Q^t$ .
- ▶ Summiert man nun die obige Formel über alle  $i$  und beachtet, dass die Aussage für beliebige  $j$  und somit auch für alle  $F : \{1, \dots, N\} \rightarrow \{1, \dots, N\}$  gilt, so ergibt sich

$$L_H^T \leq \sum_{i=1}^N \sum_{t=1}^T p_i^t l_{F(i)}^t + NR = L_{H,F}^T + NR$$