

Ćwiczenie 1. Przedstaw dowód twierdzenia 4.12 lub 4.13 z książki.

Ćwiczenie 2. Rozszerz sformułowanie algorytmu PW i twierdzenia 4.6 z książki tak, aby obejmowało maksymalizację dowolnych wypłat ograniczonych od dołu i pokrótce omów niewielkie potrzebne zmiany w dowodzie. Uniezależnij wynik od znajomości górnego ograniczenia (sum kwadratów) wypłat – przedstaw modyfikację algorytmu (zapoznaj się pobieżnie z dowodem). Patrz *Improved second-order bounds for prediction with expert advice*, lemat 2 i paragraf 3.1, <http://arxiv.org/pdf/math.ST/0602629>.

Ćwiczenie 3. W definicji straty algorytmu H : $L_H^T = \sum_{t=1}^T \sum_{i=1}^N p_i^t l_i^t$, w modelu minimalizacji strat, posługujemy się wartością oczekiwaną. Zamiast tego, zdefiniujmy zmienną losową $\hat{L}_H^T = \sum_{t=1}^T \sum_{i=1}^N l_{i_t}^t$, gdzie $i_t \sim \bar{p}_i^t$ (zmienna losowa z rozkładu zadanego przez algorytm H w chwili t). Znajdź nietrywialne oszacowanie straty z prawdopodobieństwem $1 - \delta$: $P\{\hat{L}_H^T > f(T, \delta)\} < \delta$ dla małych dodatnich δ , dla algorytmu $H = \text{PW}'$ minimalizacji niezadowolenia, z pełną informacją, nazwanego w książce *PolynomialWeights* – lub jego modyfikacji (np. zmniejszającej wariancję strat algorytmu). (Patrz paragraf 4.3 w *Improved second-order bounds for prediction with expert advice*. Paragraf 6 pracy *The non-stochastic multi-armed bandit problem* znajduje takie oszacowanie dla algorytmu częściowej informacji Exp3.P.)

Ćwiczenie 4. Przedstaw dowód twierdzenia 4.17 z książki (oszacowanie dla algorytmu minimalizacji niezadowolenia z częściową informacją MAB).

Ćwiczenie 5. Przedstaw algorytm Exp3 z pracy *The non-stochastic multi-armed bandit problem* (<http://cseweb.ucsd.edu/~yfreund/papers/bandits.pdf>) – paragraf 3. Uzasadnij jego postać porównując go z algorytmem MAB, przytaczając odpowiednie fragmenty dowodów.

Ćwiczenie 6. Algorytmy minimalizacji niezadowolenia przy częściowej informacji (tzn. dla problemu wielorękiego bandyty) są wrażliwe na dużą ilość akcji ze względu na konieczność oszacowania strat/wypłat dla każdej akcji osobno. Załóżmy że mamy do dyspozycji dużo ekspertów $i \in \{1, \dots, N\}$ dostarczających rozkładu prawdopodobieństw $\xi^i(t)$ dla małej liczby akcji $j \in \{1, \dots, K\}$. Wzorując się na algorytmie Exp4 z *The non-stochastic multi-armed bandit problem*, zmodyfikuj algorytm MAB (bazującego na PW) oraz wyprowadź dla niego górne oszacowanie na oczekiwane niezadowolenie w klasie porównawczej, które zależy tylko logarytmicznie od liczby ekspertów.

Ćwiczenie 7. Trudnością strategii dokonującej wyborów j_1, \dots, j_T nazywamy liczbę zmian akcji w ciągu j_t : $1 + |\{1 \leq t < T: j_t \neq j_{t+1}\}|$. Wyprowadź nietrywialne oszacowanie niezadowolenia w porównaniu z dowolną strategią dla algorytmu MAB (bazującego na PW) lub jego modyfikacji, zależne od trudności porównywanej strategii. (Patrz paragraf 8 artykułu *The non-stochastic multi-armed bandit problem* – algorytm Exp3.S.)

Wybieranie deterministycznie najlepszego eksperta w modelu z pełną informacją przynosi niezadowolenie względem najlepszego eksperta rzędu „ilość zmian lidera”, w najgorszym przypadku $T/2$ dla strat z przedziału $[0, 1]$. Okazuje się, że strategię tę można w prosty sposób poprawić.

Ćwiczenie 8. Strategia „podążaj za zabużonym liderem” polega na przechowywaniu strat do chwili t poszczególnych ekspertów/akcji $L_{i,t}$, i wybieraniu akcji $\text{argmin}_{i=1, \dots, N}(L_{i,t-1} + Z_{i,t})$ dla pewnych zmiennych losowych $Z_{i,t}$. Gdy $Z_{i,t}$ są niezależnymi zmiennymi z rozkładu jednostajnego na $[0, \Delta]$, wtedy oczekiwane niezadowolenie algorytmu jest ograniczone przez

$$L_T - \min_{i=1, \dots, N} L_{i,T} \leq \Delta + \frac{NT}{\Delta}$$

Skonstruuj środowisko (zależne od Δ), w którym strata tego algorytmu jest możliwie duża (tzn. znajdź nietrywialne, być może pasujące, dolne ograniczenie).

Gdy rozkład zaburzeń skupimy wokół najlepszych akcji, zmniejszymy wrażliwość strategii na ilość ekspertów – czy widać to dla skonstruowanego przez ciebie środowiska? Dla strategii „podążaj za zabużonym liderem” z rozkładem zaburzeń $\mathbf{Z}_t = (Z_{1,t}, \dots, Z_{N,t})$ o gęstości $f(\mathbf{z}) = (\eta/2)^N e^{-\eta \|\mathbf{z}\|_1}$ (gdzie $\|\mathbf{z}\|_1 := \sum_{i=1}^N |z_i|$), ograniczenie górne zależy tylko logarymicznie od ilości ekspertów (*Prediction, Learning and Games* rozdział 4.3).