

Die Auswahl von Experten

- n Experten geben in mehreren Runden Ja/Nein Empfehlungen (wie etwa Kauf oder Verkauf einer Aktie) ab.
- Nach jeder Runde wird mitgeteilt, welche Empfehlung richtig ist.
- Können wir einen Algorithmus entwickeln, dessen Anzahl an Fehlentscheidungen nur unwesentlich größer ist als die des besten Experten?

Warum nicht einfach in jeder Runde den bisher besten Experten wählen?

- (1) Konstruiere eine Menge von n Experten, so dass sich diese Strategie immer irrt, obwohl der beste Experte nach t Runden höchstens t/n Fehler macht.
- (2) Katastrophale Strategie: Keine einzige richtige Entscheidung, obwohl die Experten nur mit Wahrscheinlichkeiten $1/n$ irren.

Der weighted Majority Ansatz

- (1) Setze $w_i = 1$ für alle Experten i .
/* Zu Anfang besitzen allen Experten dasselbe Gewicht. */
- (2) Wenn Experte i die Empfehlung $x_i \in \{\text{Ja}, \text{Nein}\}$ abgibt, dann treffe die Entscheidung „Ja“, falls

$$\sum_{i, x_i=\text{Ja}} w_i \geq \sum_{i, x_i=\text{Nein}} w_i$$

und ansonsten treffe die Entscheidung „Nein“.

/* Wir folgen der Mehrheit. */

- (3) Wenn Experte i eine falsche Empfehlung abgegeben hat, dann setze $w_i = w_i/2$. Ansonsten bleiben die Gewichte unverändert.
/* „Heftige“ Bestrafung falscher Entscheidungen */

- (1) Sei W_t das Gesamtgewicht aller Experten vor Beginn von Runde t . Dann ist anfänglich $W_1 = n$.
- (2) Wenn die Entscheidung in Runde t falsch ist, dann haben sich Experten mit einem Gesamtgewicht von mindestens $W_t/2$ geirrt:

$$W_{t+1} \leq \frac{1}{2} \cdot \frac{W_t}{2} + \frac{W_t}{2} = \frac{3}{4} W_t.$$

- (3) Wenn wir f falsche Entscheidungen bis zum Zeitpunkt t treffen, ist $W_t \leq n \cdot \left(\frac{3}{4}\right)^f$.
- (4) Wenn der beste Experte i bis zum Zeitpunkt t genau f_{opt} Fehler gemacht hat, dann ist $w_i = 2^{-f_{\text{opt}}}$ und als Konsequenz

$$\left(\frac{1}{2}\right)^{f_{\text{opt}}} \leq W_t \leq n \cdot \left(\frac{3}{4}\right)^f, \quad \text{bzw.} \quad \left(\frac{4}{3}\right)^f \leq 2^{f_{\text{opt}}} \cdot n.$$

Das Resultat

Da $(\frac{4}{3})^f \leq 2^{f_{\text{opt}}} \cdot n$:

Wenn der Weighted Majority Algorithmus bei n Experten bisher f falsche und der beste Experte f_{opt} falsche Entscheidungen getroffen haben, dann gilt

$$f \leq \frac{1}{\log_2(4/3)} \cdot (f_{\text{opt}} + \log_2 n).$$

- (1) Nach logarithmischer „Aufwärmzeit“ erreichen wir die Prognosekraft des besten Experten bis auf den Faktor $\frac{1}{\log_2(4/3)} \approx 2,41$.
- (2) Können wir bei entsprechend verlängerter Aufwärmzeit die Prognosekraft des besten Experten **fast exakt** erreichen?

Eine randomisierte Version von **Weighted Majority**

Ein allgemeineres Modell

Die Empfehlung eines Experten i zum Zeitpunkt t bewerten wir mit einer „Note“ c_i^t auf einer Skala von 0 (sehr gut) bis 1 (sehr schlecht).

Unser Algorithmus:

- (1) Setze $w_j = 1$ für alle Experten i .
- (2) Wähle einen Experten zufällig, wobei Experte i die Wahrscheinlichkeit

$$p_i = \frac{w_i}{\sum_{k=1}^n w_k}$$

erhält und übernimmt seine Entscheidung.

- (3) Berechne neue Gewichte: Setze $w_i = w_i(1 - \varepsilon \cdot c_i^t)$.
Kommentar: Die von der Rundenzahl t unabhängige Konstante ε wird aus dem Intervall $]0, 1/2[$ gewählt. Beachte $\varepsilon \cdot c_i^t \in [0, 1/2[$.

- (1) w_i^t sei das Gewicht von Experte i zu Beginn von Runde t . Die Gewichtssumme aller Experten vor Runde t ist $W_t = \sum_{i=1}^n w_i^t$.
- (2) $K_t = \sum_{i=1}^n \frac{w_i^t}{W_t} \cdot c_i^t$ ist die erwartete Benotung unserer Entscheidung zum Zeitpunkt t .
- (3) Wie berechnet sich W_{t+1} aus W_t ?

$$\begin{aligned} W_{t+1} &= \sum_{i=1}^n w_i^t \cdot (1 - \varepsilon \cdot c_i^t) = \sum_{i=1}^n w_i^t - \varepsilon \cdot \sum_{i=1}^n w_i^t \cdot c_i^t \\ &= W_t - \varepsilon \cdot K_t \cdot W_t = W_t \cdot (1 - \varepsilon \cdot K_t) \end{aligned}$$

Wir expandieren und erhalten $W_{T+1} = W_1 \cdot \prod_{t \leq T} (1 - \varepsilon \cdot K_t)$.

Es ist $W_{T+1} = W_1 \cdot \prod_{t \leq T} (1 - \varepsilon \cdot K_t)$.

(4) Beachte $\log(1 - x) \leq -x$ und

$$\ln W_{T+1} = \ln W_1 + \sum_{t \leq T} \ln(1 - \varepsilon \cdot K_t) \leq \ln n - \sum_{t \leq T} \varepsilon K_t$$

Eine schlechte erwartete Benotung unserer Entscheidungen drückt das Gesamtgewicht.

(5) Ein Experte mit guter Benotung hingegen stärkt das Gesamtgewicht: Für Experte i gilt

$$W_{T+1} \geq w_i^{T+1} = \prod_{t \leq T} (1 - \varepsilon \cdot c_i^t).$$

Wir möchten wieder logarithmieren, um unsere erwartete Benotung mit der Benotung eines besten Experten vergleichen zu können: Beachte $\ln(1 - x) \geq -x - x^2$ für $x \in [0, 1/2]$.

Es ist $W_{T+1} \geq w_i^{T+1} = \prod_{t \leq T} (1 - \varepsilon \cdot c_i^t)$ und
 $\ln(1 - x) \geq -x - x^2$ für $x \in [0, 1/2]$.

(6) Nach Logarithmierung folgt wegen $0 \leq c_i^t \leq 1$:

$$\begin{aligned} \ln W_{T+1} &\geq \sum_{t \leq T} \ln(1 - \varepsilon \cdot c_i^t) \geq - \sum_{t \leq T} (\varepsilon \cdot c_i^t + (\varepsilon \cdot c_i^t)^2) \\ &\geq - \sum_{t \leq T} (\varepsilon \cdot c_i^t + \varepsilon^2 \cdot c_i^t) = -(\varepsilon + \varepsilon^2) \cdot \sum_{t \leq T} c_i^t. \end{aligned}$$

(7) Wir vergleichen die untere mit der oberen Gewichtsschranke:

$$-(\varepsilon + \varepsilon^2) \cdot \sum_{t \leq T} c_i^t \leq \ln W_{T+1} \leq \ln n - \sum_{t \leq T} \varepsilon K_t.$$

Das Ergebnis

- Es ist $-(\varepsilon + \varepsilon^2) \cdot \sum_{t \leq T} c_i^t \leq \ln n - \sum_{t \leq T} \varepsilon K_t$.
- Nach Division durch ε folgt:

Wenn K_{opt} die Gesamtbenotung des besten Experten ist und K_t die erwartete Benotung unserer Entscheidung in Runde t ist, dann folgt

$$\sum_{t \leq T} K_t \leq (1 + \varepsilon) \cdot K_{\text{opt}} + \frac{\ln n}{\varepsilon}.$$

- Wir erreichen die Benotung des besten Experten bis auf den Faktor $1 + \varepsilon$, wenn wir die „Aufwärmzeit“ $\frac{\ln n}{\varepsilon}$ erlauben.

Constant Rebalanced Portfolio

- Ein Vermögen V wird über m Anlagemöglichkeiten verteilt: Anlage i erhält das Vermögen $p_i \cdot V$.
- Zu jedem Anlagezeitpunkt: Anlage i erhält den Anteil $p_i \cdot V'$, wenn V' das gegenwärtige Vermögen ist.

CRP: Zwei Aktien mit $p_1 = p_2 = 0.5$

Wir arbeiten mit zwei Aktien, wobei sich die erste Aktie nicht bewegt, während sich die zweite Aktie stets erst halbiert und dann verdoppelt.

- Das Vermögen sinkt nach einem Anlagezeitpunkt auf $V \cdot (1/2 + (1/2) \cdot (1/2)) = 3 \cdot V/4$
- und steigt nach dem zweiten Anlagezeitpunkt auf $V \cdot (3/8 + 2 \cdot 3/8) = 9 \cdot V/8$.
- Vor dem Anlagetermin $2n + 1$ ist das Vermögen damit exponentiell auf $(\frac{9}{8})^n \cdot V$ angewachsen!

Der Universal Portfolio Algorithmus

- Welche Verteilung p sollte gewählt werden?

- **Risiko-Minimierung:**

Der Universal Portfolio Algorithmus versucht, die erwartete Vermögensentwicklung des CRP-Ansatzes zu erreichen.

- Wir arbeiten mit einer großen Anzahl N verschiedener Verteilungen.
- Rebalanciere jedes Portfolio nach seiner Verteilung ohne Gelder zwischen den verschiedenen Portfolios zu transferieren.

Der Universal Portfolio Algorithmus und Weighted Majority

- Anfänglich erhält jedes ausgewählte Portfolio das Gewicht $\frac{V}{N}$.
- Die Gewichte geben den Erfolg wieder.
- Gewichte werden vom Markt aktualisiert:
 - ▶ Der Markt übernimmt die Rolle von Weighted Majority.
 - ▶ Diesmal versuchen wir aber nicht die Leistung des besten Experten, sondern nur die durchschnittliche Leistung zu erreichen.

Wie gut ist der Universal Portfolio Algorithmus?

Wir arbeiten mit m Anlagemöglichkeiten über einem Zeitraum von n Anlageperioden.

opt_n sei das optimale Vermögen und e_n das erwartete Vermögen nach n Anlageperioden. Dann gilt:

$$e_n \geq \frac{opt_n}{(n+1)^{m-1}}.$$

- Der durchschnittliche **relative** Verlustfaktor pro Anlageperiode ist höchstens

$$((n+1)^{m-1})^{1/n} \approx (n^{m-1})^{1/n} = n^{(m-1)/n} = 2^{\frac{(m-1) \cdot \log_2 n}{n}} \approx 1.$$

- Wächst die optimale CRP-Strategie um den Faktor a_n^n für $a_n > 1$, dann wächst das erwartete Vermögen um den Faktor b_n^n mit $b_n > 1$ und $\lim_{n \rightarrow \infty} a_n = \lim_{n \rightarrow \infty} b_n$.

Wir arbeiten mit Spezialisten:

- Jeder Spezialist gibt eine Ja/Nein Empfehlung ab **oder** enthält sich.
- Unser Ziel: So gut zu sein, wie eine beste **Menge** E von Spezialisten:
 - ▶ Die Menge E erhält für jeden sich irrenden Spezialisten einen Strafpunkt.
 - ▶ Enthalten sich alle Spezialisten in E erhält E insgesamt einen Strafpunkt.

Unser Ziel ist sehr ambitioniert, da wir jetzt mit einer besten Menge von Spezialisten mithalten möchten:

Beste Spezialisten aus verschiedensten Fachgebieten können sehr viel stärker als Experten sein.

Der Winnow Algorithmus

- (1) Setze $w_1 = \dots = w_n = 1$.
- (2) Wenn eine Entscheidung zu treffen ist, dann gibt jeder Spezialist i bekannt, ob er sich enthält ($x_i = 0$) oder nicht ($x_i = 1$).
 - (2a) Winnow enthält sich, falls

$$\sum_{i=1}^n w_i \cdot x_i < n$$

gilt. Wenn Winnow sich enthält: **Verdopple die Gewichte aller Spezialisten, die sich nicht enthalten haben.**

- (2b) Sonst ist $\sum_{i=1}^n w_i \cdot x_i \geq n$ und Winnow trifft eine Mehrheitsentscheidung: Wenn Spezialist i die Empfehlung $y_i \in \{\text{Ja}, \text{Nein}\}$ abgibt, dann entscheidet Winnow auf „Ja“, wenn

$$\sum_{i, x_i=1, y_i=\text{Ja}} w_i \cdot x_i \geq \sum_{i, x_i=1, y_i=\text{Nein}} w_i \cdot x_i$$

und ansonsten auf „Nein“. **Die Gewichte aller Spezialisten, die die falsche Entscheidung unterstützt haben, werden halbiert.**

Sei E eine beliebige Teilmenge von insgesamt n Spezialisten. Dann macht Winnow nach T Runden höchstens

$$5 \cdot \text{Strafe}_T(E) + 5 \cdot |E| \cdot \lceil \log_2 n \rceil + 4$$

Fehler, wobei ein Fehler entweder eine Enthaltung oder eine falsche Entscheidung ist.

- (1) Unsere Strafpunktzahl ist durch das 5-fache der Strafpunktzahl von E beschränkt: Die Aufwärmzeit $5 \cdot |E| \cdot \lceil \log_2 n \rceil + 4$ wächst mit der Größe von E .
- (2) To winnow: Den Spreu vom Weizen trennen.
Der Winnow Algorithmus isoliert relativ schnell die erfolgreichen Spezialisten.

Analyse: Die Enthaltungen von Winnow

- Für $i \in E$ ist f_i die Anzahl falscher Entscheidungen nach T Runden.
- Alle Spezialisten in E enthalten sich in genau e Runden.
- Wie groß ist e^* , die Anzahl der Enthaltungen von Winnow?

- (1) Winnow enthält sich nicht, wenn sich mindestens ein „Schwergewicht“ (mit $w_i \geq n$) nicht enthält.
- (2) Jeder Spezialist $i \in E$, der sich mindestens $f_i + \log_2 n$ Mal **nicht** enthält, während sich Winnow jedesmal enthält, wird zu einem Schwergewicht.
Sein Gewicht, unter Einrechnung der Halbierungen nach Fehlentscheidungen, ist auf n angestiegen.
- (3) In $e^* - e$ Enthaltungsschritten von Winnow wird sich aber mindestens ein Spezialist aus E nicht enthalten.

Analyse: Die Fehlentscheidungen von Winnow

$$\begin{aligned} e^* &\leq e + \sum_{i \in E} f_i + |E| \cdot \lceil \log_2 n \rceil \\ &= \text{Strafe}_T(E) + |E| \cdot \lceil \log_2 n \rceil. \end{aligned}$$

- (4) Warum? Wenn e^* größer als die rechte Seite ist, dann blockiert ein Schwergewicht in E eine Enthaltung von Winnow.
- (5) Wie groß ist die Anzahl der Fehlentscheidungen von Winnow?
- ▶ Sei W_t die Summe aller Gewichte vor Runde t .
 - ▶ Es ist $W_1 = n$ und $W_t > 0$.
 - ▶ Wenn Winnow sich in Runde t enthält, dann ist $\sum_{i=1}^n w_i \cdot x_i < n$.
Nach Verdopplung für Nicht-Enthaltungen ist $W_{t+1} \leq W_t + n$.
 - ▶ Bei einer Fehlentscheidung von Winnow ist $\sum_{i=1}^n w_i x_i \geq n$.
Das Gesamtgewicht der sich irrenden Spezialisten ist mindestens $n/2$.
Nach Halbierung folgt $W_{t+1} \leq W_t - \frac{n}{4}$.

- Es ist $e^* \leq \text{Strafe}_T(E) + |E| \cdot \lceil \log_2 n \rceil$.
- Enthält sich Winnow in Runde t , dann ist $W_{t+1} \leq W_t + n$.
- Bei einer Fehlentscheidung von Winnow in Runde t ist $W_{t+1} \leq W_t - \frac{n}{4}$.

(1) Sei f^* die Anzahl der Fehlentscheidungen von Winnow. Dann ist

$$f^* \leq 4e^* + 4.$$

(2) Also ist die Anzahl der Enthaltungen und Fehlentscheidungen von Winnow durch

$$e^* + f^* \leq 5e^* + 4 \leq 5 \cdot \text{Strafe}_T(E) + 5 \cdot |E| \cdot \lceil \log_2 n \rceil + 4$$

beschränkt.