

正規表現に基づく乗算型重み更新アルゴリズムの効率化
改め

オンライン予測の理論と応用

東北大学大学院情報科学研究科

A01班 瀧本 英二

クイズ王に匹敵する問題

「タイガーウッズは寅年生まれである。○か×か？」



迷う参加者たち




この人たちを
参考にしよう！



クイズ王達
発見!!

正解は



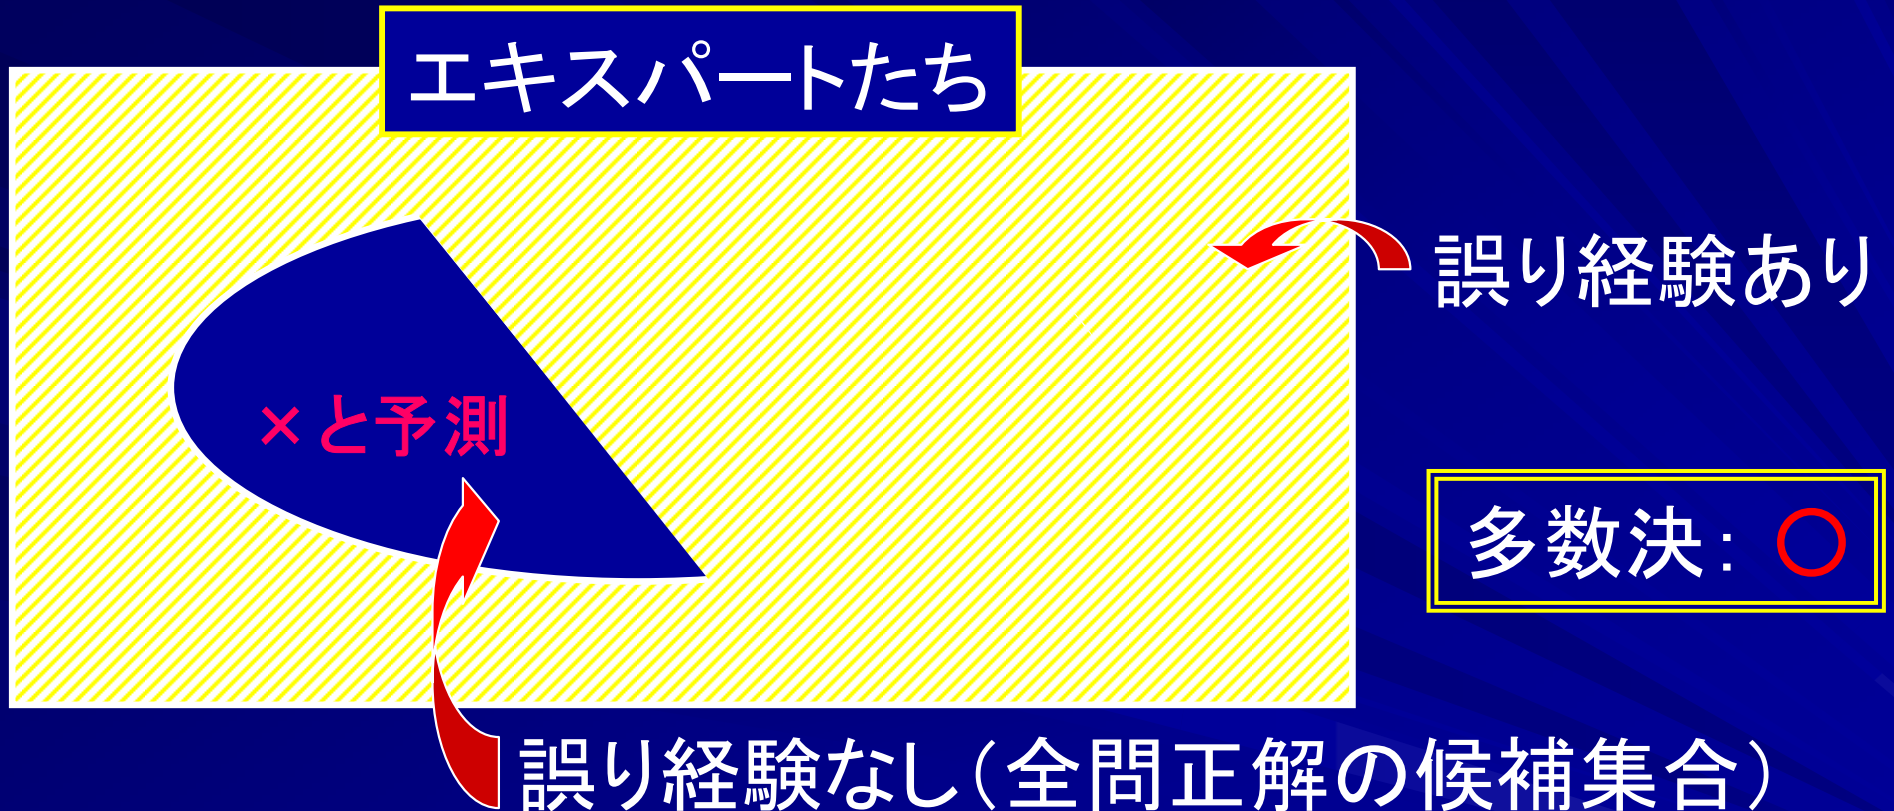
タイガーウッズはウサギ年生まれ

二分法 (Halving Algorithm)

- クイズ王 (エキスパート) N 人のうち少なくとも1人は全問正解すると仮定
- 二分法:
「これまで一度も間違えていないエキスパートたちの予測の多数決に従う」

誤り回数は高々 $\lceil \log_2 N \rceil$

二分法の解析



- 間違えたとき, 候補は半分以下
- 誤り回数が $m \Rightarrow$ 候補数 $\leq N / 2^m$ $m \leq \lfloor \log_2 N \rfloor$
- 仮定より, $1 \leq$ 候補数

二分法 ∈ 乗算型重み更新

- $v_i \in [0,1]$: エキスパート i の重み
- 初期重み $v_i = 1/N$
- $x_i \in \{-1,1\}$: エキスパート i の予測値
- 二分法の出力: 重みつき多数決

$$\text{sgn}(\sum_{i=1}^N v_i x_i \geq 0)$$

- 重み更新

$$v_i \leftarrow v_i b_i / \text{規格化}$$

ただし,

$$b_i = \begin{cases} 1 & \cdots \text{エキスパート } i \text{ が正しかったとき} \\ 0 & \cdots \text{エキスパート } i \text{ が間違えたとき} \end{cases}$$

重みつき平均アルゴリズム

—— 全問正解者がいない場合 ——

■ 重み更新

$$v_i \leftarrow v_i b_i / \text{規格化}$$

ただし,

$$b_i = 1 \quad \dots \text{エキスパート } i \text{ が正しかったとき}$$

$$\epsilon^n \quad \dots \text{エキスパート } i \text{ が間違えたとき}$$

$$\text{誤り回数} \leq m^* + O\left(\sqrt{m^* \ln N} + \ln N\right)$$

m^* は最も成績の良かったエキスパートの誤り回数

パーセプトロン ∈ 加算型重み更新

- 学習目標 $v^* = (0, \dots, 1, \dots, 0)$ の線形分離関数 (シングルトン) の学習

- パーセプトロンの出力: 重みつき多数決

$$y' = \text{sgn}(\sum_{i=1}^N v_i x_i \geq 0)$$

- 重み更新

$$v_i \leftarrow v_i + \eta (y - y') x_i$$

ただし, y は真の値, η は学習定数

- 誤り回数 = $\Omega(N)$ cf. 二分法は $\lfloor \log N \rfloor$

パーセプトロン vs Winnow

加算型重み更新

乗算型重み更新

- 学習目標が $v^* = (1, 0, 1, 0, 0, \dots, 1)$ のとき
ただし, $k = \sum_i v_i^*$

- パーセプトロン

$$v_i \leftarrow v_i + \eta (y - y') x_i$$

誤り回数 = $\Omega(kN)$

カーネル手法と整合する

- Winnow

$$v_i \leftarrow v_i \exp(\eta (y - y') x_i) / \text{規格化}$$

誤り回数 = $O(k \log N)$... attribute efficient

一般に, カーネル手法と整合しない

この問題と解析の特徴

■ オンライン性

- 予測と結果の提示が交互に繰り返される

■ ユニバーサル性

- エキスパートの予測や結果の系列に対して何の仮定もおかない

■ 最悪値評価

- アルゴリズムの性能を最悪の場合で評価する

■ 相対評価

- アルゴリズムの性能を, 最適なエキスパートの成績を用いて相対的に評価する

オンライン予測

■ モデル化

- エキスパート統合モデル

■ 統合アルゴリズム

- Winnow (1988)
- Aggregating Algorithm (1990)
- Weighted Majority, Weighted Averaging (1993,1994,1999)
- GD, EG family (1994)
- Potential-Based (2001)
- Following Perturbed Leader (2003)

■ 応用

- 学習, 符号化, 統計的推定, 投資, ゲーム理論, 最適化, ...

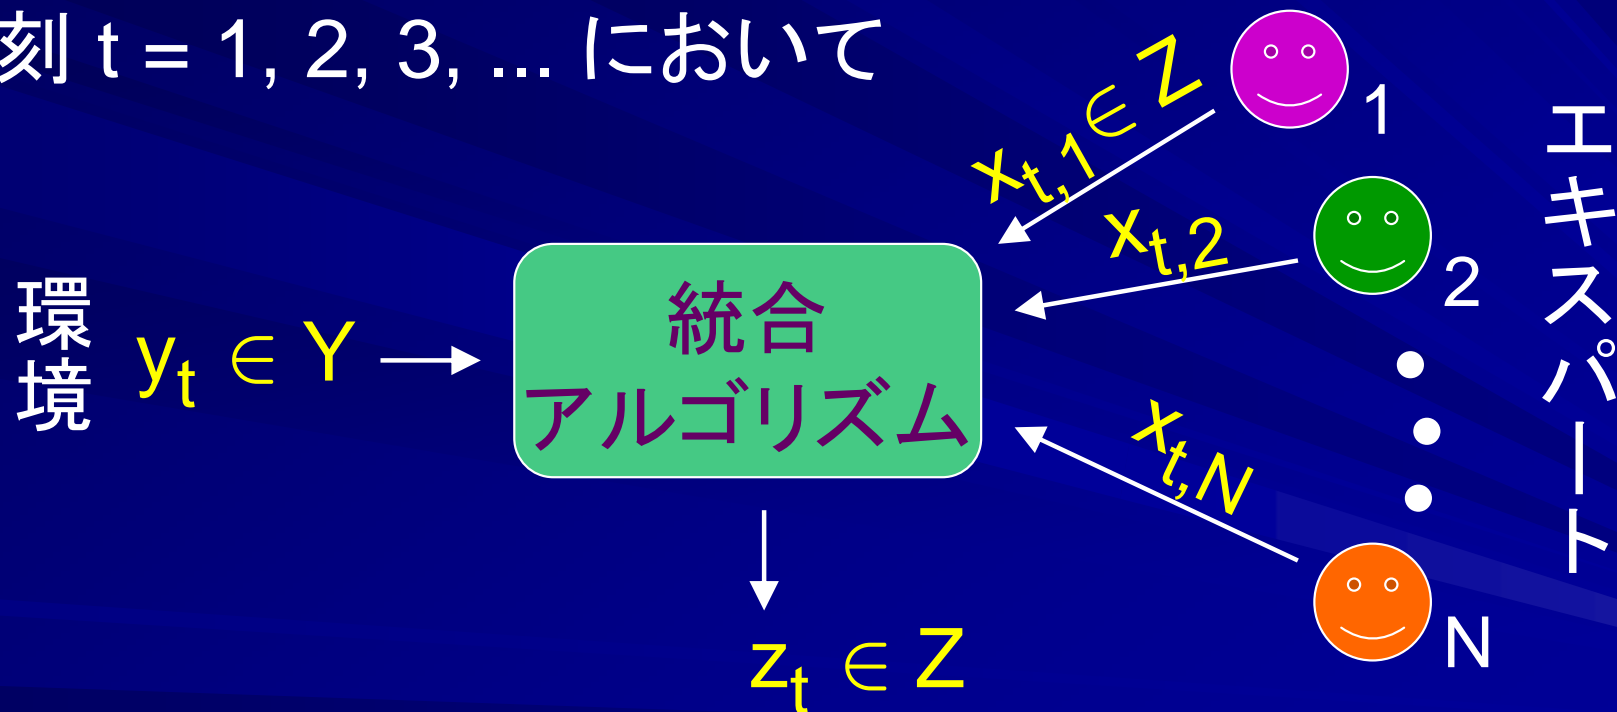
エキスパート統合モデル

Y …… 真の結果値の集合

Z …… 予測値の集合

$L: Y \times Z \rightarrow [0, \infty]$ …… 損失関数

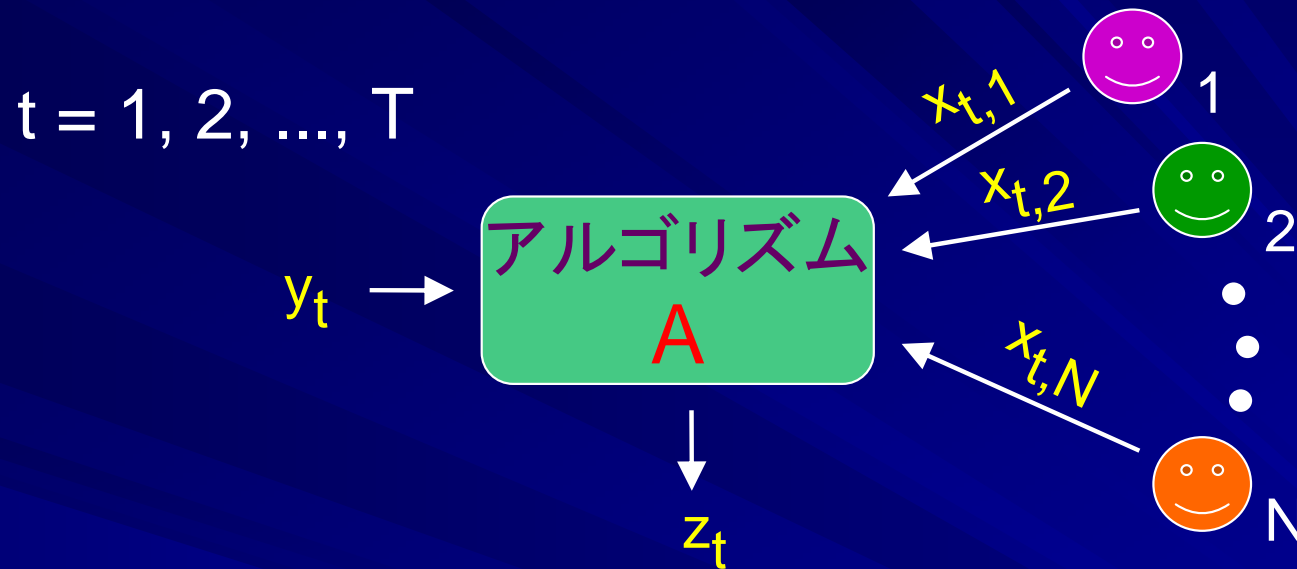
各時刻 $t = 1, 2, 3, \dots$ において



アルゴリズムの損失: $L(y_t, z_t)$

エキスパート i の損失: $L(y_t, x_{t,i})$

相対損失 (regret)



- アルゴリズム A の累積損失: $\text{Loss}_A^T = \sum_{t=1}^T L(y_t, z_t)$
- エキスパート i の累積損失: $\text{Loss}_i^T = \sum_{t=1}^T L(y_t, x_{t,i})$
- アルゴリズム A の相対損失: $R_A^T = \text{Loss}_A^T - \min_i \text{Loss}_i^T$

目標: $R_A^T \rightarrow \text{small}$

クイズ王に匹敵する問題

- $Y = \{0,1\}$
 - $Z = \{0,1\}$
 - $L(y, z) = |y - z|$
- } に相当

$\text{Loss}_A^T =$ アルゴリズム A の誤り回数

$\text{Loss}_i^T =$ エキスパート i の誤り回数

$$m^* = \min_i \text{Loss}_i^T$$

$$\exists A, \quad R_A^T \leq 4\sqrt{m^* \ln N} + 2.5 \log_2 N$$

統合アルゴリズムの原理

Vovk の Aggregating Algorithm (AA)

- 各エキスパート i に対し, 重み $v_{t,i}$ を保持
($v_{t,i} \geq 0, \sum_{1 \leq i \leq N} v_{t,i} = 1$)

- 予測の統合

$$\forall y \in Y, L(y, z_t) \leq -c(\eta) \ln \sum_{i=1}^N v_{t,i} e^{-\eta L(y, x_{t,i})}$$

を満たす $z_t \in Z$ を出力

$c(\eta)$: 問題 (Y, Z, L) に固有の値

- 重み更新

$$v_{t+1,i} = \frac{v_{t,i} e^{-\eta L(y_t, x_{t,i})}}{\text{規格化係数}}$$

AAの性能

■ 定理

任意のエキスパート, 任意の環境の振る舞いに対し,
最適なエキスパートを $i^* = \operatorname{argmin}_i \operatorname{Loss}_i^T$ とすると,


$$\operatorname{Loss}_{AA}^T \leq c(\eta) \left(\eta \operatorname{Loss}_{i^*}^T + \ln \frac{1}{v_{1,i^*}} \right)$$

特に, 初期重みが一様 ($v_{1,i} = 1/N$) のとき,

$$\begin{aligned} \operatorname{Loss}_{AA}^T &\leq c(\eta) \left(\eta \operatorname{Loss}_{i^*}^T + \ln N \right) \\ &\equiv a(\eta) \operatorname{Loss}_{i^*}^T + c(\eta) \ln N \end{aligned}$$

AAの最適性

$$\text{LOSS}_{AA}^T \leq a(\eta) \text{LOSS}_{i^*}^T + c(\eta) \ln N$$



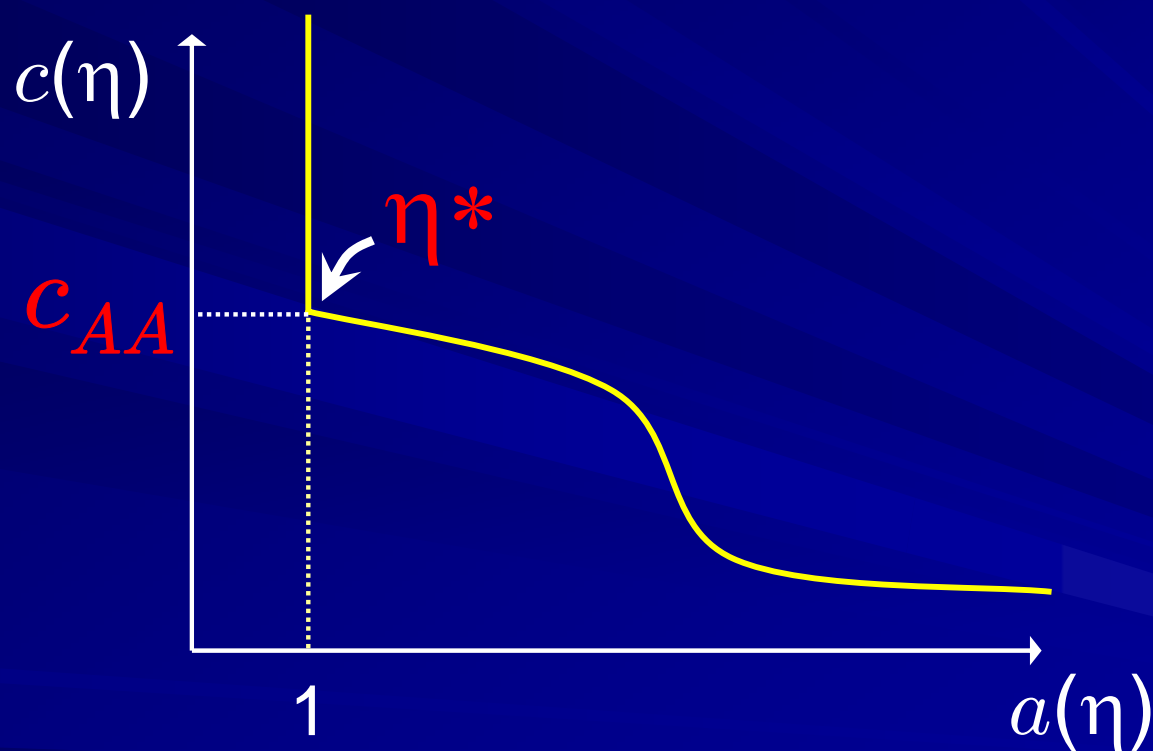
■ 定理

問題 (Y, Z, L) が“自然”ならば,
 $\forall A, \exists$ エキスパート, \exists 環境

$$\text{LOSS}_A^T > a \text{LOSS}_{i^*}^T + c \ln N$$

凸損失関数に対する性質

$L(y,z)$ が z に関して下に凸のとき
(2次損失, 相対エントロピー損失, Hellinger損失, . . .)



$$\text{LOSS}_{AA}^T \leq \text{LOSS}_{i^*}^T + c_{AA} \ln N$$

Weighted Averaging Algorithm (WAA)

- 簡便なアルゴリズム (AAの近似)
- $Y = Z = [0,1]$, L : 凸損失関数と仮定
- 予測の統合

$$z_t = \sum_{i=1}^N v_{t,i} x_{t,i}$$

- 定理

$$\text{Loss}_{WAA}^T \leq \text{Loss}_{i^*}^T + c_{WAA} \ln N$$

$$(c_{AA} \leq c_{WAA})$$

さまざまな凸損失関数と c_{AA} , c_{WAA}

$$\text{Loss}_{AA}^T \leq \text{Loss}_{i^*}^T + c_{AA} \ln N$$

$$\text{Loss}_{WAA}^T \leq \text{Loss}_{i^*}^T + c_{WAA} \ln N$$

損失関数	$L(y, z)$	c_{AA}	c_{WAA}
2次損失	$(y - z)^2$	1/2	2
相対エントロピー損失	$(1 - y) \ln \frac{1 - y}{1 - z} + y \ln \frac{y}{z}$	1	1
Hellinger 損失	$\frac{1}{2}((\sqrt{1 - y} - \sqrt{1 - z})^2 + (\sqrt{y} - \sqrt{z})^2)$	$1/\sqrt{2}$	1
絶対値損失	$ y - z $	凸関数ではない	

ダイバージェンスを用いた導出

■ KLダイバージェンス(相対エントロピー)

確率ベクトル v, u に対し,

$$RE(v \parallel u) = \sum_i v_i \ln (v_i / u_i)$$

■ 重み更新の導出


$$v_{t+1} = \operatorname{argmin}_v (\eta \sum_i v_i L(y_t, x_{t,i}) + RE(v \parallel v_t))$$

$$= \frac{v_{t,i} e^{-\eta L(y_t, x_{t,i})}}{\text{規格化係数}}$$

上界の導出

■ $v^* = (0, \dots, 1, \dots, 0) \in [0,1]^N$ (第 i^* 成分のみ1)

$$\begin{aligned} L(y_t, z_t) - L(y_t, x_{t,i^*}) \\ \leq c (\text{RE}(v^* \parallel v_t) - \text{RE}(v^* \parallel v_{t+1})) \end{aligned}$$



v_t が v^* に“時刻 t における”
相対損失分以上近づく

■ $t=1, \dots, T$ で和を取ると,
相対損失 $\leq c \text{RE}(v^* \parallel v_1) = c \ln N$

オンライン予測の応用

オンラインアルゴリズムの統合

- オンライン問題を解くアルゴリズム A_1, \dots, A_N
- 入力系列 $S = y_1, \dots, y_T$

$\max_S \min_i A_i(S)$ の損失 $\leq \min_i \max_S A_i(S)$ の損失

AA の損失 $\leq \min_i A_i$ の損失 $+ c_{AA} O(\ln N)$

確率モデルの統合と情報圧縮

... so she was considering in her ?



言語モデル θ_i



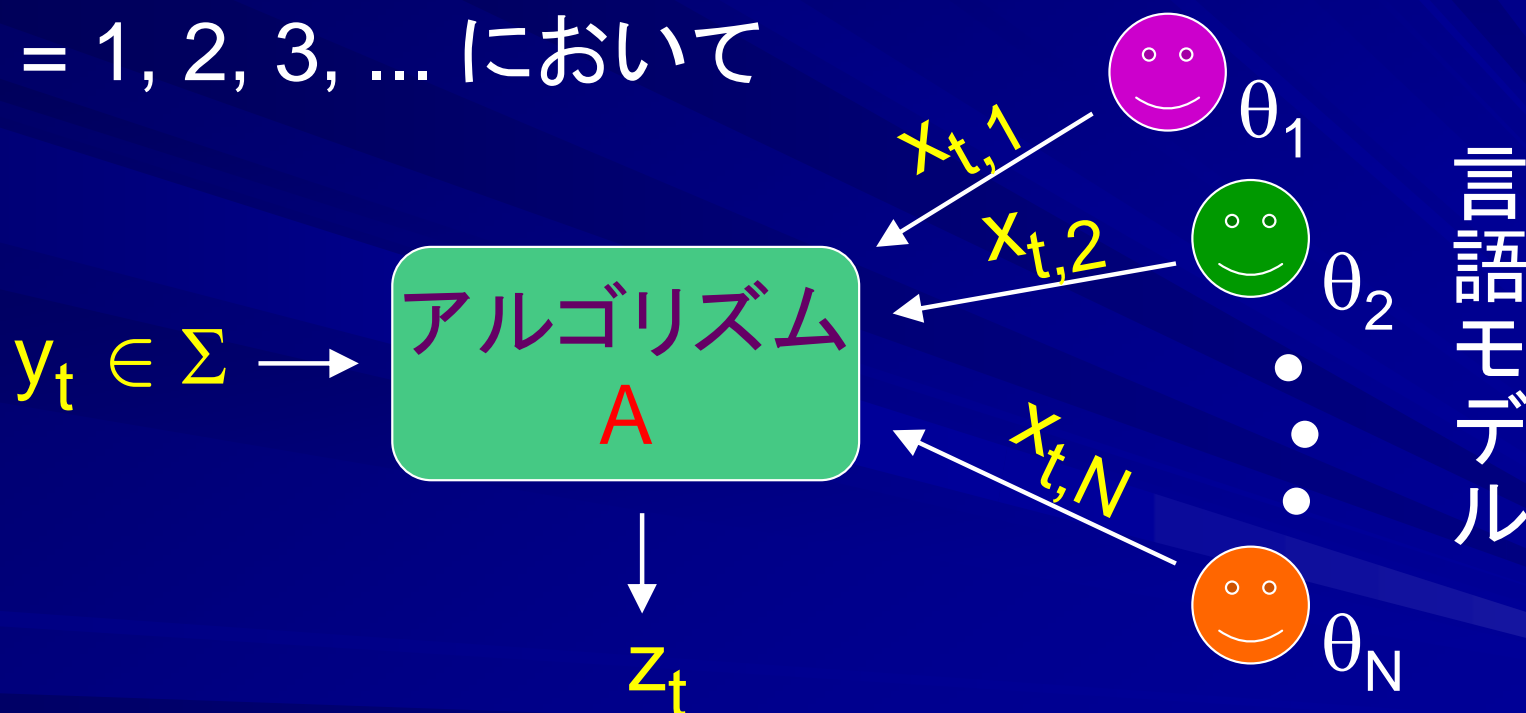
	$\Pr(\cdot \text{context}, \theta_i)$
mind	0.232
thought	0.183
own	0.129
office	0.073
:	:

確率モデルの統合モデル

$\Sigma = \{1, \dots, K\}$: アルファベット

$y_1, y_2, \dots, y_{t-1} \in \Sigma \rightarrow \boxed{\theta_i} \rightarrow x_{t,i}(\cdot) = \Pr(\cdot | y_1, \dots, y_{t-1}, \theta_i)$

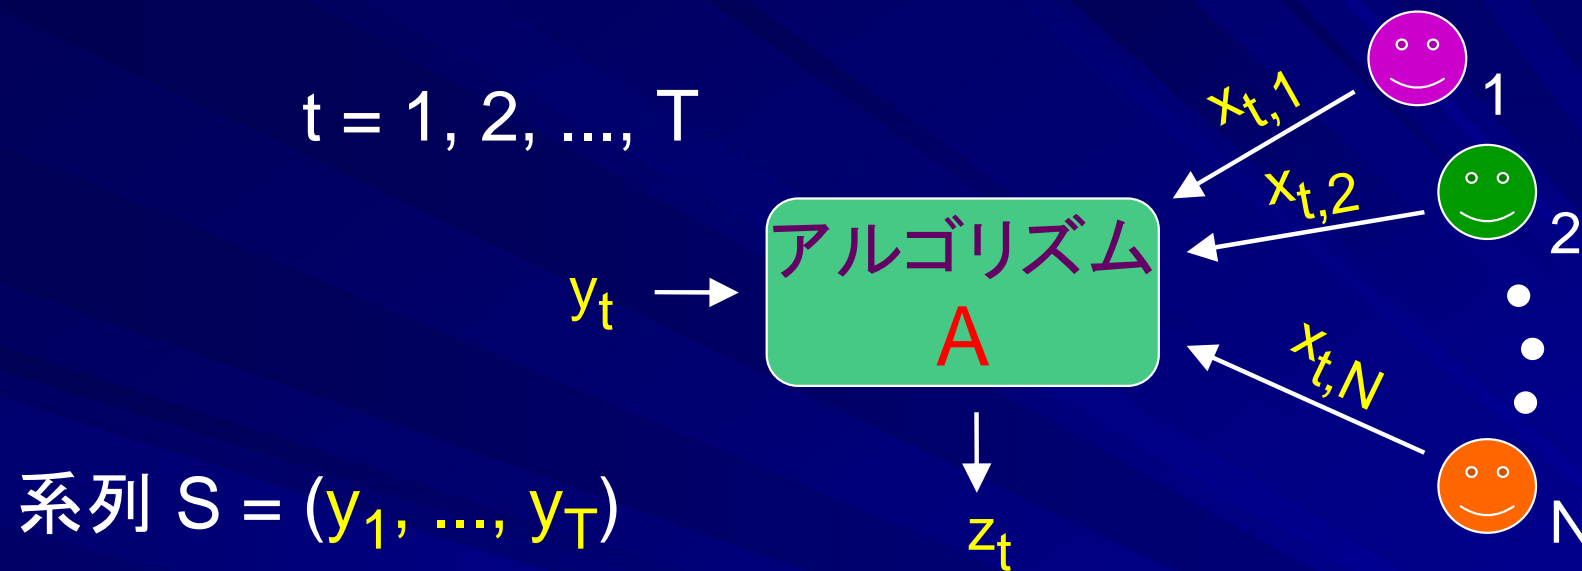
各時刻 $t = 1, 2, 3, \dots$ において



アルゴリズムの尤度: $z_t(y_t) = \Pr(y_t | y_1, \dots, y_{t-1}, A)$

モデル θ_i の尤度: $x_{t,i}(y_t) = \Pr(y_t | y_1, \dots, y_{t-1}, \theta_i)$

ユニバーサル符号と冗長度



- Aの尤度: $P(S | A) = \prod_t P(y_t | y_{1..t-1}, A) = \prod_t z_t(y_t)$
- θ_i の尤度: $P(S | \theta_i) = \prod_t x_{t,i}(y_t)$
- A + ユニバーサル符号 \Rightarrow 符号長 = $-\log_2 P(S | A)$
 θ_i + ユニバーサル符号 \Rightarrow 符号長 = $-\log_2 P(S | \theta_i)$
- 冗長度 = $-\log_2 P(S | A) - \min_i (-\log_2 P(S | \theta_i))$

AAの適用とベイズ混合

以下の問題 (Y, Z, L) と等価

- $Y = \Sigma = \{1, \dots, K\}$

- $Z = \{z \in [0,1]^K : \Sigma \text{ 上の分布}\}$

- $L(y, z) = -\ln z(y) \cdots$ 対数損失

- $\Rightarrow \text{Loss}_A^T = -\ln P(S | A) \cdots$ 符号長

- AA の出力 = WAA の出力 = ベイズ混合

$$z_t(j) = \sum_{i=1}^N v_{t,i} x_{t,i}(j)$$

$$= \sum_{i=1}^N \Pr(\theta_i | y_{1..t-1}) \Pr(j | y_{1..t-1}, \theta_i)$$

$$\text{冗長度} = \text{相対損失} = \text{Loss}_A^T - \text{Loss}_{i^*}^T \leq \ln N$$

無限のエキスパートの統合

- $Y = \{0, 1\}$

- エキスパート $\theta \in [0, 1]$

$$x_{t,\theta}(1) = \Pr(1 \mid y_{1..t-1}, \theta) = \theta$$

$$x_{t,\theta}(0) = \Pr(0 \mid y_{1..t-1}, \theta) = 1 - \theta$$

- AAの出力 = KT-Estimator

$$\begin{aligned} z_t(y) &= \int v_{t,\theta} x_{t,\theta}(y) d\theta \\ &= \frac{\sum_{s=1}^{t-1} y_s + 1/2}{t} \end{aligned}$$

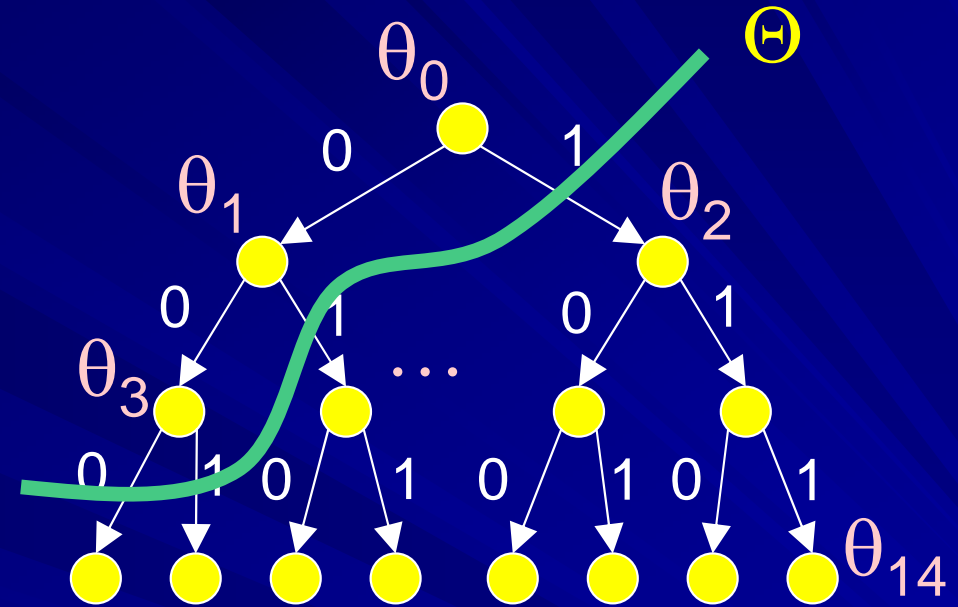
- 相対損失 = $O(\log T)$

Context Tree Weighting

各枝刈り Θ : モデル

$$\Pr(y \mid \dots 001, \Theta) = \theta_2$$

$$\Pr(y \mid \dots 010, \Theta) = \theta_4$$

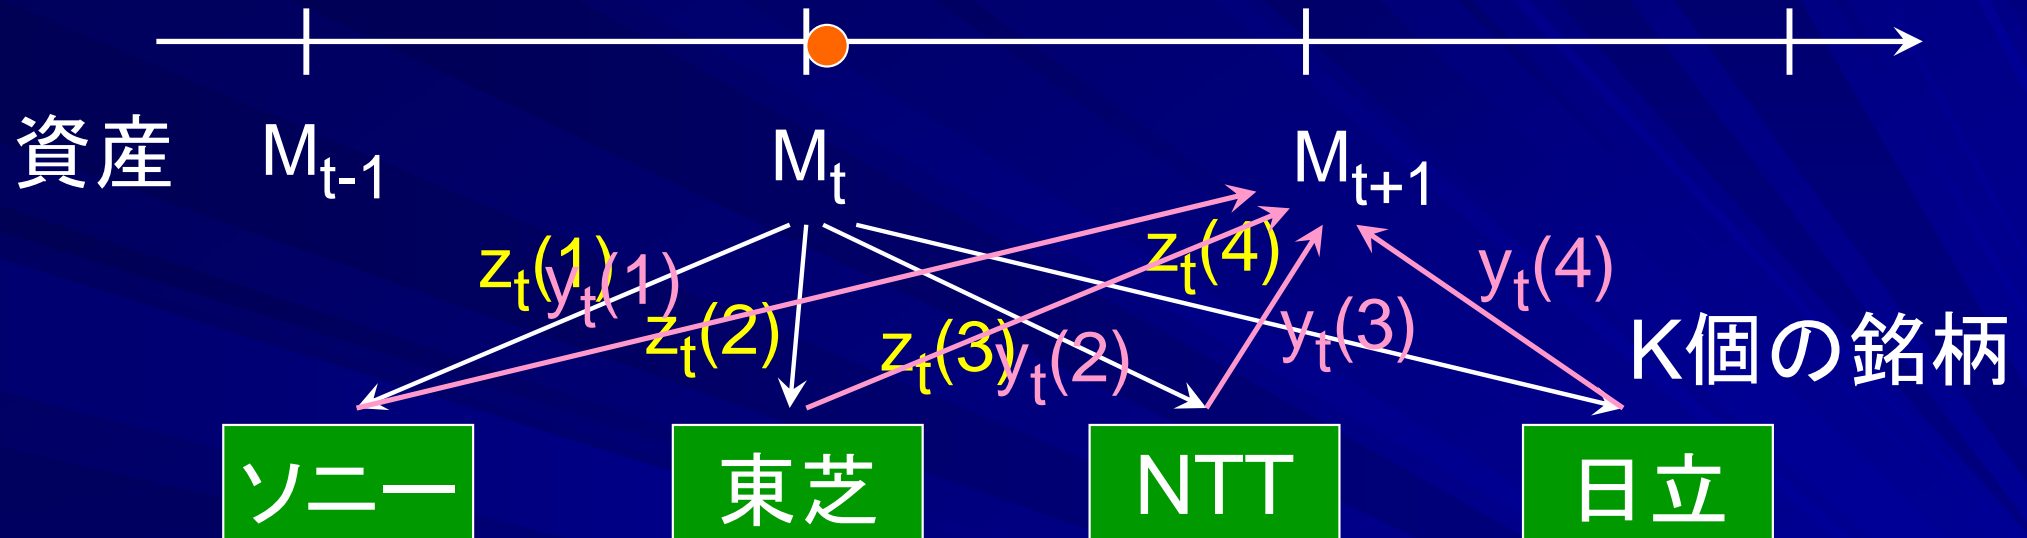


Nグラムモデル

符号長 = 最適な Θ の符号長 + $O(\Theta$ の葉の数)

ポートフォリオ

第 t 取引期間

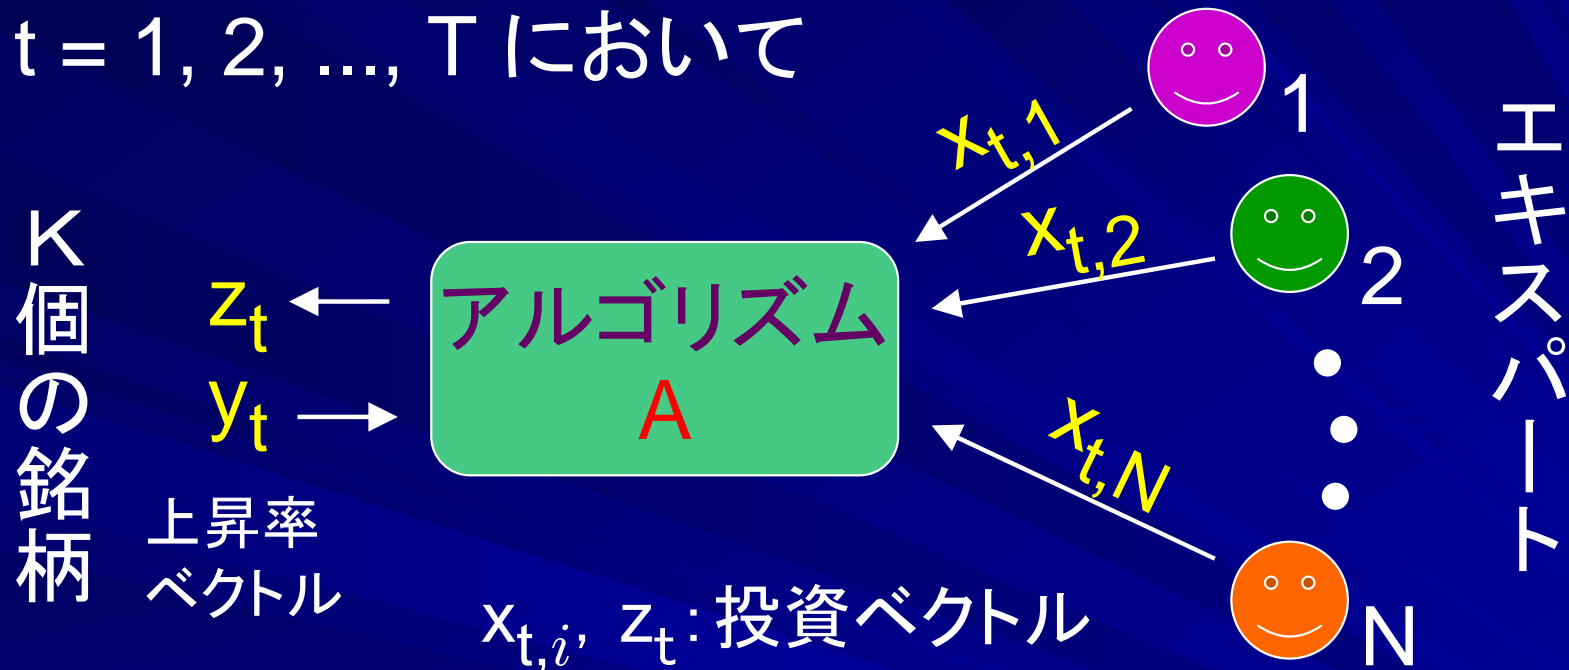


- 全額投資. 銘柄 j の株を $M_t z_t(j)$ の金額で購入
($z_t(1) + \dots + z_t(K) = 1$)
- ◆ 株をすべて売却. 銘柄 j の株価の上昇率を $y_t(j)$ とする

$$\text{新しい資産 } M_{t+1} = M_t \sum_j y_t(j) z_t(j) = M_t (y_t \cdot z_t)$$

投資アドバイスの統合

各時刻 $t = 1, 2, \dots, T$ において



- Aの資産: $M_{T+1} = M_1 \prod_t z_t \cdot y_t$
- エキスパート i のアドバイスに従ったときの資産:

$$M_{T+1,i} = M_1 \prod_t x_{t,i} \cdot y_t$$

- 競合比: $M_{T+1} / \max_i M_{T+1,i}$

AAの適用

以下の問題 (Y, Z, L) と等価

■ $Y = [0, \infty]^K$

■ $Z = \{ z \in [0, 1]^K \mid z(1) + \dots + z(K) = 1 \}$

■ $L(y, z) = -\ln(y \cdot z)$... ポートフォリオ損失

■ $\text{Loss}_A^T = -\ln M_{T+1}$

■ AA の出力 = WAA の出力

$$z_t = \sum_{i=1}^N v_{t,i} x_{t,i}$$

競合比 = $e^{-\text{相对損失}} \geq 1 / N$

オンライン投資

- ポートフォリオ問題において, 毎時刻全額投資するかわりに, 定額(例えば1万円)投資
- 株価の上昇率に上限 $B > 0$ を仮定
(相対損失を有限に抑えるため)

以下の問題 (Y, Z, L) と等価

- $Y = [0, B]^K$
- $Z = \{ z \in [0, 1]^K \mid z(1) + \dots + z(K) = 1 \}$
- $L(y, z) = y \cdot z$... 内積損失

WAAの適用

- 内積損失 $L(y, z) = y \cdot z$ は凸ではない
- 適当な η に対して


$$\text{相対損失} = O\left(\sqrt{2BL^* \ln N} + B \ln N\right)$$

L^* = 最適なエキスパートの損失

Path Kernel 法

オンライン最短路問題


入力: G



1. あるs-t 道 P を(確率的に)選ぶ. この確率を $z_t(P)$ とする.
2. 各辺の遅延時間 $d_t(e) \in [0,1]$ が明らかとなる.
道 P に沿って s から t に到達する時間は $y_t(P) = \sum_{e \in P} d_t(e)$
3. 到達時間の期待値 $\sum_P y_t(P) z_t(P) = y_t \cdot z_t$

目標: $\sum_t y_t \cdot z_t - \min_P \sum_t y_t(P) \rightarrow$ 小

オンライン投資への還元




■ $B = \max_p |P|$

■ $Y = [0, B]^N$


■ $Z = s-t$ 道上の分布の集合

■ $L(y, z) = y \cdot z$


エキスパート




P1




P2




P3



P4



P5



P6



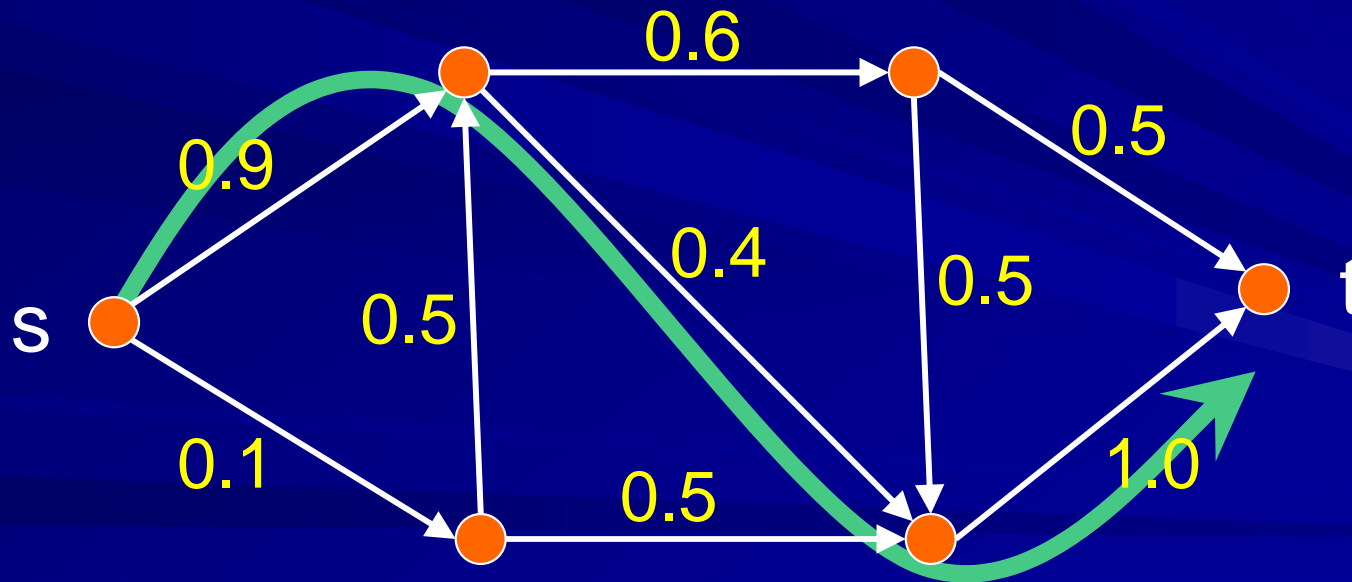
P7

■ エキスパート i は道 P_i を確率1で選ぶ

■ $N = s-t$ 道の総数

Path Kernel 法

- N (道の総数)は指数的になりうる
- すべての道 P に対し, 重み $v_{t,P}$ を保持できない
- その代わりに, 各辺 e に対し, 遷移確率 $a_t(e)$ を保持
- 関係式 $v_{t,P} = \prod_{e \in P} a_t(e)$ によって間接的に $v_{t,P}$ を表現



$$v_{t,P} = 0.9 * 0.4 * 1.0 = 0.36$$

重み更新の模倣

条件:

$$\text{(更新前)} \quad v_{t,P} = \prod_{e \in P} a_t(e)$$

$$v_{t+1,P} = \frac{v_{t,P} e^{-\eta y_t(P)}}{\text{normalize}}$$

$$\text{(更新後)} \quad v_{t+1,P} = \prod_{e \in P} a_{t+1}(e)$$

を満たすような辺上の重み更新

$$a_t \rightarrow a_{t+1}$$

を行う必要がある

重み更新の模倣

- 任意の P に対し, 次の式を満たす a_{t+1} を求めればよい

$$v_{t+1,P} = \prod_{e \in P} a_{t+1}(e) = \frac{\prod_{e \in P} a_t(e) b_t(e)}{\sum_P \prod_{e \in P} a_t(e) b_t(e)}$$

ただし, $b_t(e) = \exp(-\eta d_t(e))$

道 P の損失 = 辺の損失の和
($L(y_t, x_{t,P}) = \sum_{e \in P} d_t(e)$)

Path Kernels

- 辺の重みベクトル: $\mathbf{a} = (a(e_1), \dots, a(e_m))$
- パスの重みベクトル: $\mathbf{v} = (v_{P_1}, \dots, v_{P_N}),,$

$$\forall P, v_P = \prod_{e \in P} a(e)$$

この関係を, $\mathbf{v} = \Phi(\mathbf{a})$ と表す.

- 係数ベクトル: $\mathbf{b} = (b(e_1), \dots, b(e_m))$

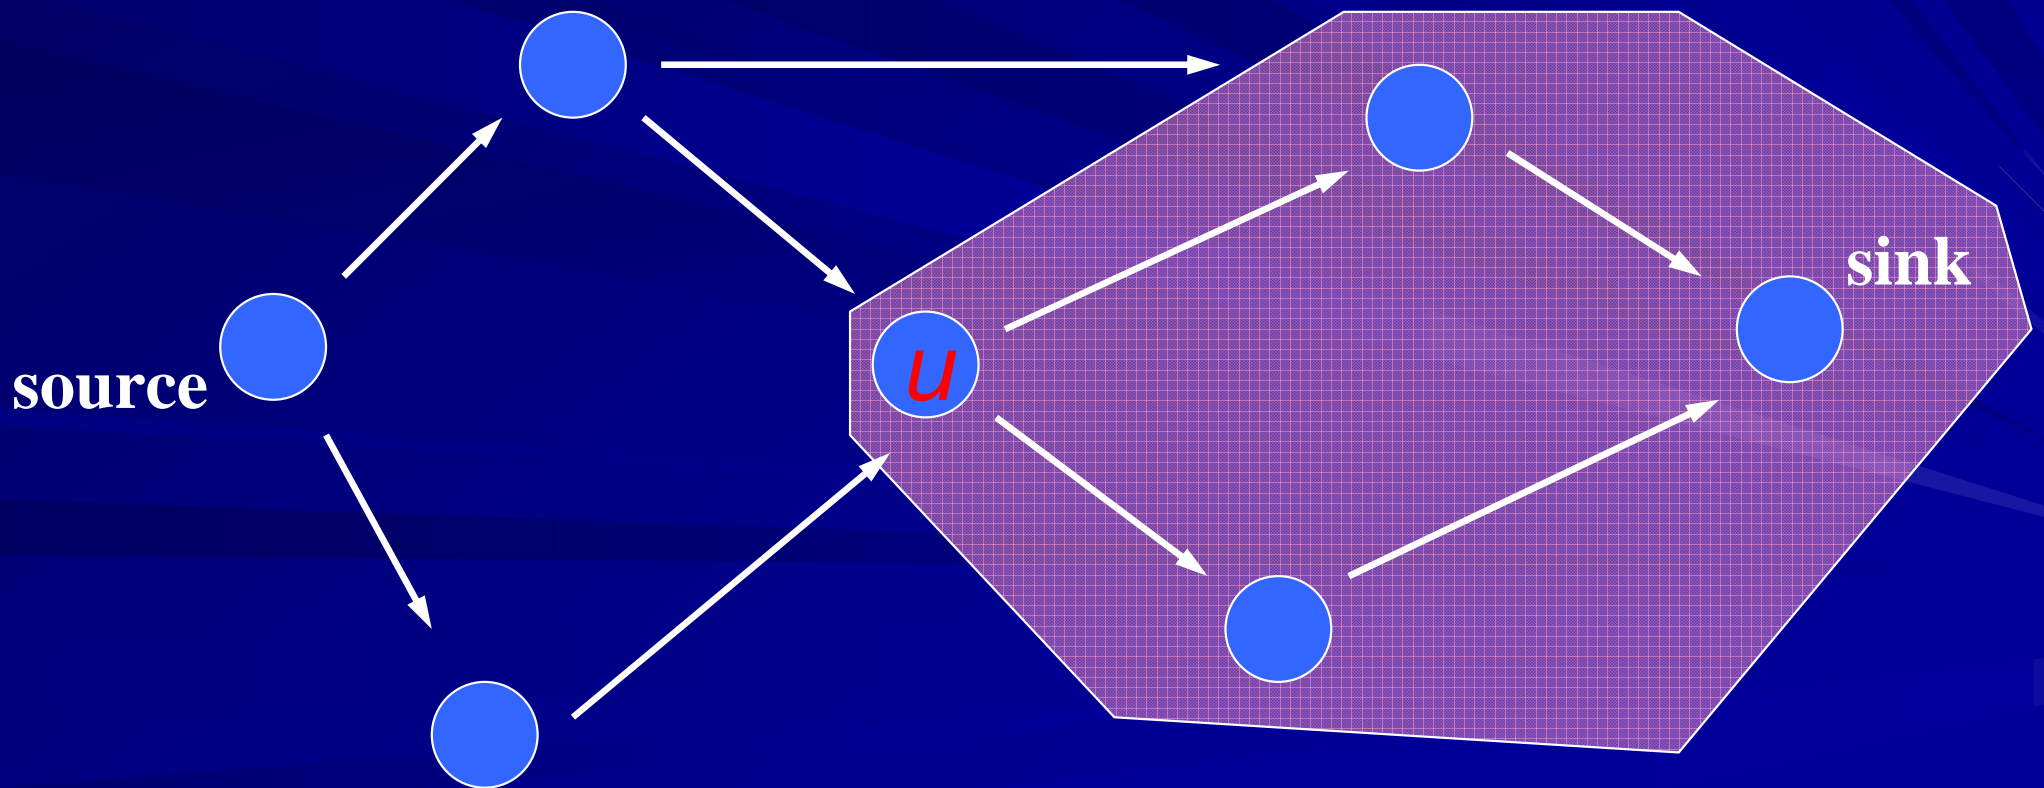
Path Kernel

$$K(\mathbf{a}, \mathbf{b}) = \Phi(\mathbf{a}) \cdot \Phi(\mathbf{b}) = \sum_P \prod_{e \in P} a(e)b(e)$$

normalization factor


Path Kernel の計算

$$K_u = \sum_{P:\text{from } u} \prod_{e \in P} a(e)b(e)$$



Path Kernel の計算

- $K_{\text{sink}} = 1$
- $K_u = \sum_{u': (u, u') \in E} v(u, u') b(u, u') K_{u'}$

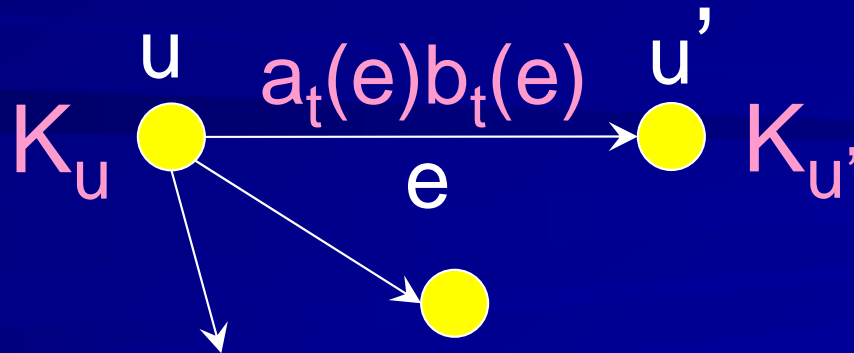


Weight Pushing Algorithm

- 目標 $\forall P, \prod_{e \in P} a_{t+1}(e) = \frac{\prod_{e \in P} a_t(e) b_t(e)}{K_{\text{source}}(\mathbf{a}_t, \mathbf{b}_t)}$
- 漸化式 $K_u = \sum_{u': (u, u') \in E} a_t(u, u') b_t(u, u') K_{u'}$

$$a_{t+1}(e) = \frac{a_t(e) b_t(e) K_{u'}}{K_u}$$

目標達成！



まとめ

- さまざまなオンライン最適化問題が、共通の統合スキーム(AA, WAA)を用いて解ける
- 一般の最適化問題への適用
 - 各時刻 t における損失が、それまでの履歴に依存する
 - オフラインで最適な解を求めるのが困難
- 構造的エキスパートの統合の可能性
 - 決定リストの効率の良いオンライン学習
- モデルのさらなる拡張
 - リスク情報を用いた統合