

[2b-R-22] 時系列早期分類の確率的定式化と時系列基盤モデルの活用

東口慎吾

大阪大学 産業科学研究所
shingo88@sanken.osaka-u.ac.jp

勝木孝行

IBM東京基礎研究所
KATS@jp.ibm.com

坂井智哉

IBM東京基礎研究所
Tomoya.Sakai2@ibm.com

Haoxiang Qiu

IBM東京基礎研究所
Haoxiang.Qiu@ibm.com

櫻井保志

大阪大学 産業科学研究所
yasushi@sanken.osaka-u.ac.jp

松原靖子


大阪大学 産業科学研究所
yasuko@sanken.osaka-u.ac.jp

井手剛

IBM T.J. Watson Research Center
tide@us.ibm.com

① 問題設定: 時系列データの早期分類

早期分類: 完全なデータが得られる前に、現在まで観測されたデータのみを用いて系列の分類ラベルを推定したい。
医療や工場設備のモニタリングなど、早期の意思決定が必要な場面で重要である。

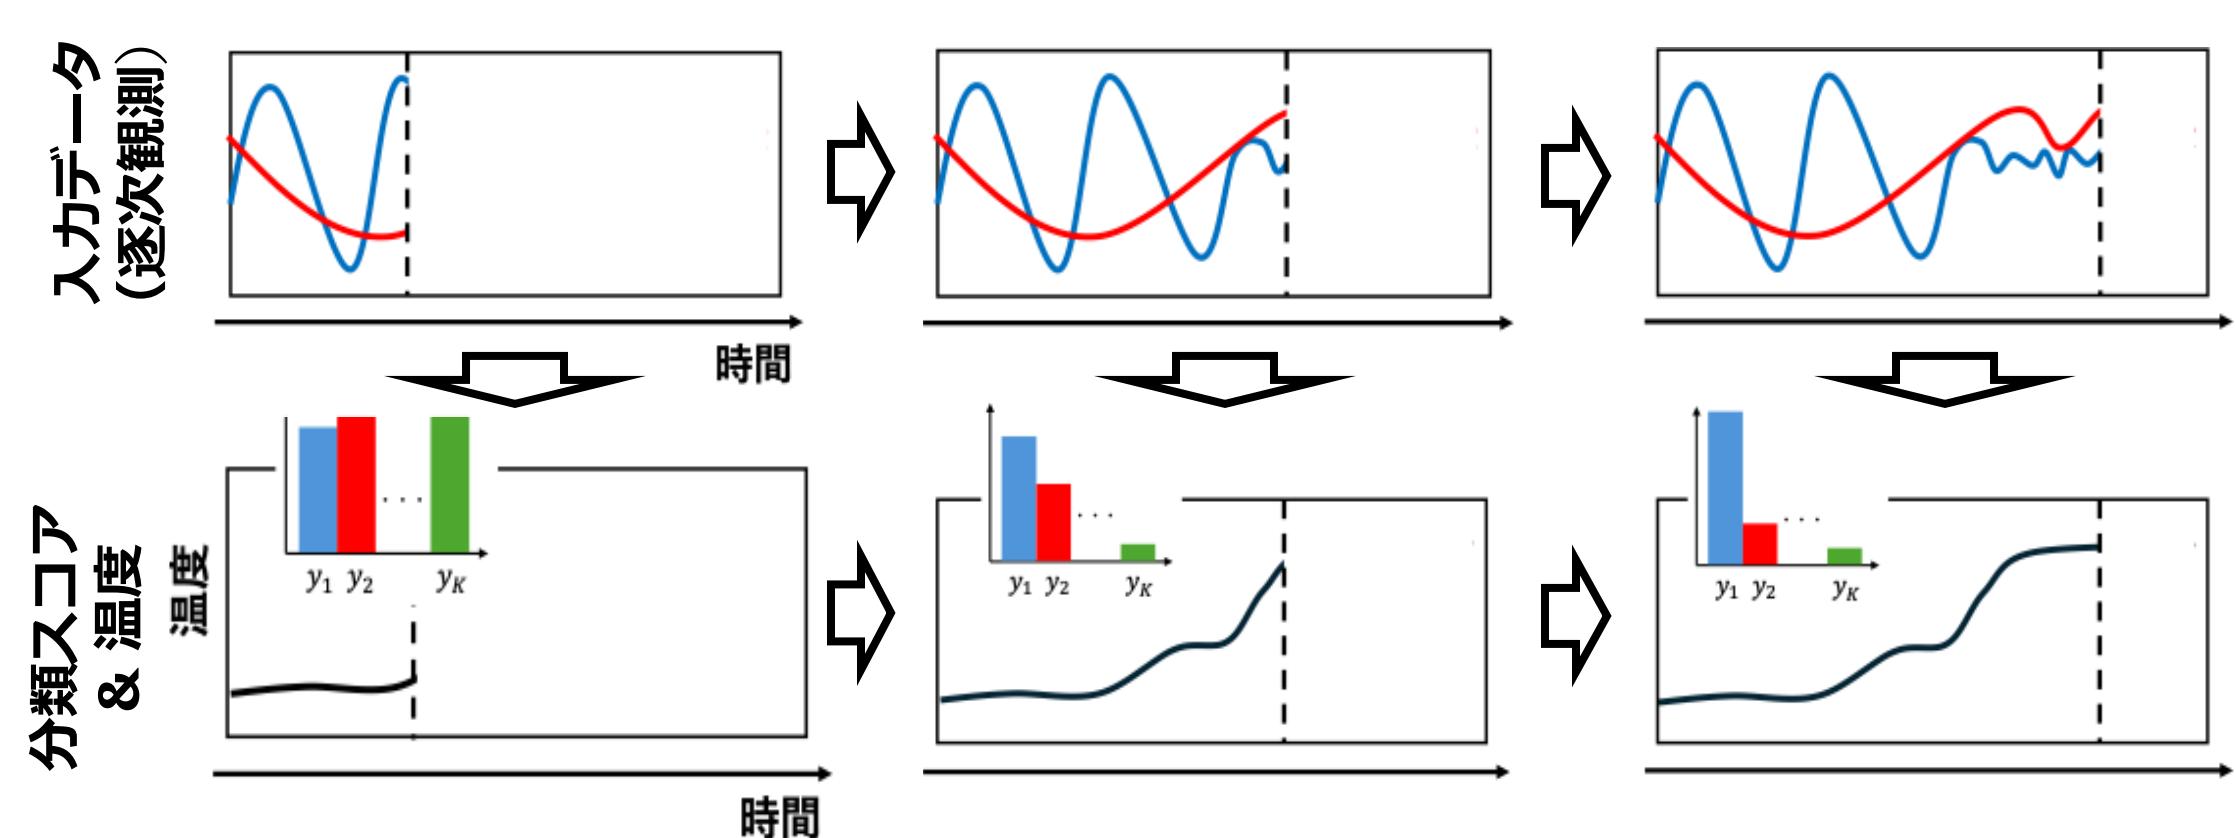


課題:

1. 判定タイミングの決定
どこまでデータを観測すれば信頼度の高い分類ができるか
2. 精度
限られたデータで高い分類精度を出せるか

② アプローチ

温度付き分類: 各時刻において、分類スコアだけでなくその分類結果に対する確信度を示す数値（温度）を同時に output



時系列基盤モデルの活用: 事前学習された基盤モデルを使って特徴抽出することで、限られたデータでも高い精度

③ 貢献

本研究は、**時系列早期分類問題を確率的に定式化**した最初の研究
既存手法では、分類と判定タイミングの決定の両立のために複雑な定式化が必要
提案手法では、温度付き分類問題として、**ELBOの最適化による簡潔な定式化で早期分類を実現**できる

④ 早期分類の確率的定式化

問題定義

Given: 時系列とラベル $\{(X_i, y_i)\}_{i=1}^N$

Goal: 各時刻における分類スコアと温度を推定する

モデル

RNNを用いて潜在状態を逐次的に更新

分類/温度ヘッドを用いてそれぞれの時刻の分類スコアと温度を計算

$$\text{RNN backbone } \theta : \mathbf{h}_t = f_\theta(\mathbf{h}_{t-1}, \mathbf{x}_t),$$

$$\text{分類スコアの分布: } p(y_t = k | \mathbf{x}_{1:t}, \phi, \beta_t) = \frac{\exp(\beta_t s_{t,k})}{\sum_{j=1}^K \exp(\beta_t s_{t,j})}$$

温度付き softmax

$\beta > 1$: 確信度が高い

$\beta = 1$: 中立 (通常のsoftmaxと一致)

$\beta < 1$: 確信度が低い

$$\text{分類ヘッドの出力: } s_{t,k} = [g_\phi(\mathbf{h}_t)]_k$$

$$\text{温度の事前分布 (ガンマ分布): } p(\beta_t) = \text{Gamma}(a_0 + \lambda t, b_0)$$

$$\text{温度の事後分布: } q(\beta_t | \mathbf{x}_{1:t}, \psi) = \text{Gamma}(\hat{a}_t(\mathbf{h}_t, \psi), \hat{b}_t(\mathbf{h}_t, \psi))$$

$$\mathbb{E}[\beta_t] = \frac{a_0 + \lambda t}{b_0}$$




図1: モデル概要。(左) 各時刻で分類スコアと温度を出力。(右) 入力系列からの特徴抽出に時系列基盤モデルを活用した場合。

系列全体の定式化:

$$p(y | \mathbf{x}_{1:T}, \phi, \beta_{1:T}) = \prod_{t=1}^T \text{softmax}_y(\beta_t, \mathbf{h}_t, \phi)$$

$$p(\beta_{1:T}) = \prod_{t=1}^T p(\beta_t)$$

$$q(\beta_{1:T} | \mathbf{x}_{1:T}, \psi) = \prod_{t=1}^T q(\beta_t | \mathbf{x}_{1:t}, \psi) = q(\beta_t | \mathbf{h}_t, \psi)$$

目的関数: ELBOの最大化

$$\begin{aligned} \log p(y | \mathbf{x}_{1:T}, \phi) &= \mathbb{E}_q[\log \frac{p(y | \mathbf{x}_{1:T}, \phi, \beta_{1:T})p(\beta_{1:T})}{q(\beta_{1:T} | \mathbf{x}_{1:T}, \psi)}] \\ &= \mathbb{E}_q[\log p(y | \mathbf{x}_{1:T}, \phi, \beta_{1:T})] - \text{KL}[q(\beta_{1:T} | \mathbf{x}_{1:T}, \psi) || p(\beta_{1:T})] \\ &= \log q(\beta_{1:T} | \mathbf{x}_{1:T}, \psi) \frac{p(y | \mathbf{x}_{1:T}, \phi, \beta_{1:T})p(\beta_{1:T})}{q(\beta_{1:T} | \mathbf{x}_{1:T}, \psi)} d\beta_{1:T} = \sum_{t=1}^T \mathbb{E}_q[\log \text{softmax}_y(\beta_t, \mathbf{h}_t, \phi)] - \text{KL}[q(\beta_t | \mathbf{h}_t, \psi) || p(\beta_t)] \\ &\geq \int q(\beta_{1:T} | \mathbf{x}_{1:T}, \psi) \log \frac{p(y | \mathbf{x}_{1:T}, \phi, \beta_{1:T})p(\beta_{1:T})}{q(\beta_{1:T} | \mathbf{x}_{1:T}, \psi)} d\beta_{1:T} = \mathcal{L}_{\text{ELBO}}(\theta, \phi, \psi) \end{aligned}$$

$$\hat{\mathcal{L}}_{\text{ELBO}} = \sum_{t=1}^T \mathbb{E}_{\beta_t \sim \text{Gamma}(\hat{a}(h_t, \psi), \hat{b}(h_t, \psi))} [\log \text{softmax}_y(\hat{\beta}_t, h_t, \phi)] - \text{KL}[\text{Gamma}(\hat{a}(h_t, \psi), \hat{b}(h_t, \psi)) || \text{Gamma}(a_0 + \lambda t, b_0)],$$

Reparameterization trick

ガンマ分布のKLダイバージェンスは
解析的に計算可能

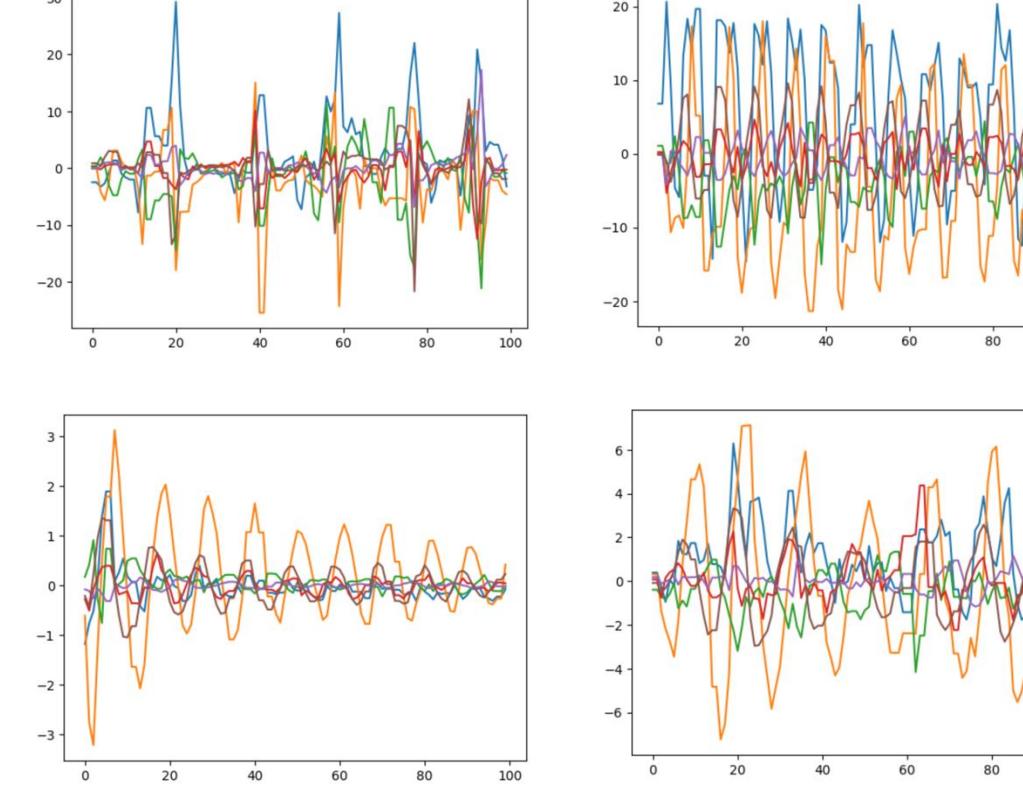
$$\text{KL}(\hat{a}, \hat{b}, a, b) = (\hat{a} - a)\psi(\hat{a}) - \ln \Gamma(\hat{a}) + a \ln \frac{\hat{b}}{b} + \ln \Gamma(a) + \hat{a} \frac{b}{\hat{b}} - 1$$

⑤ 実験

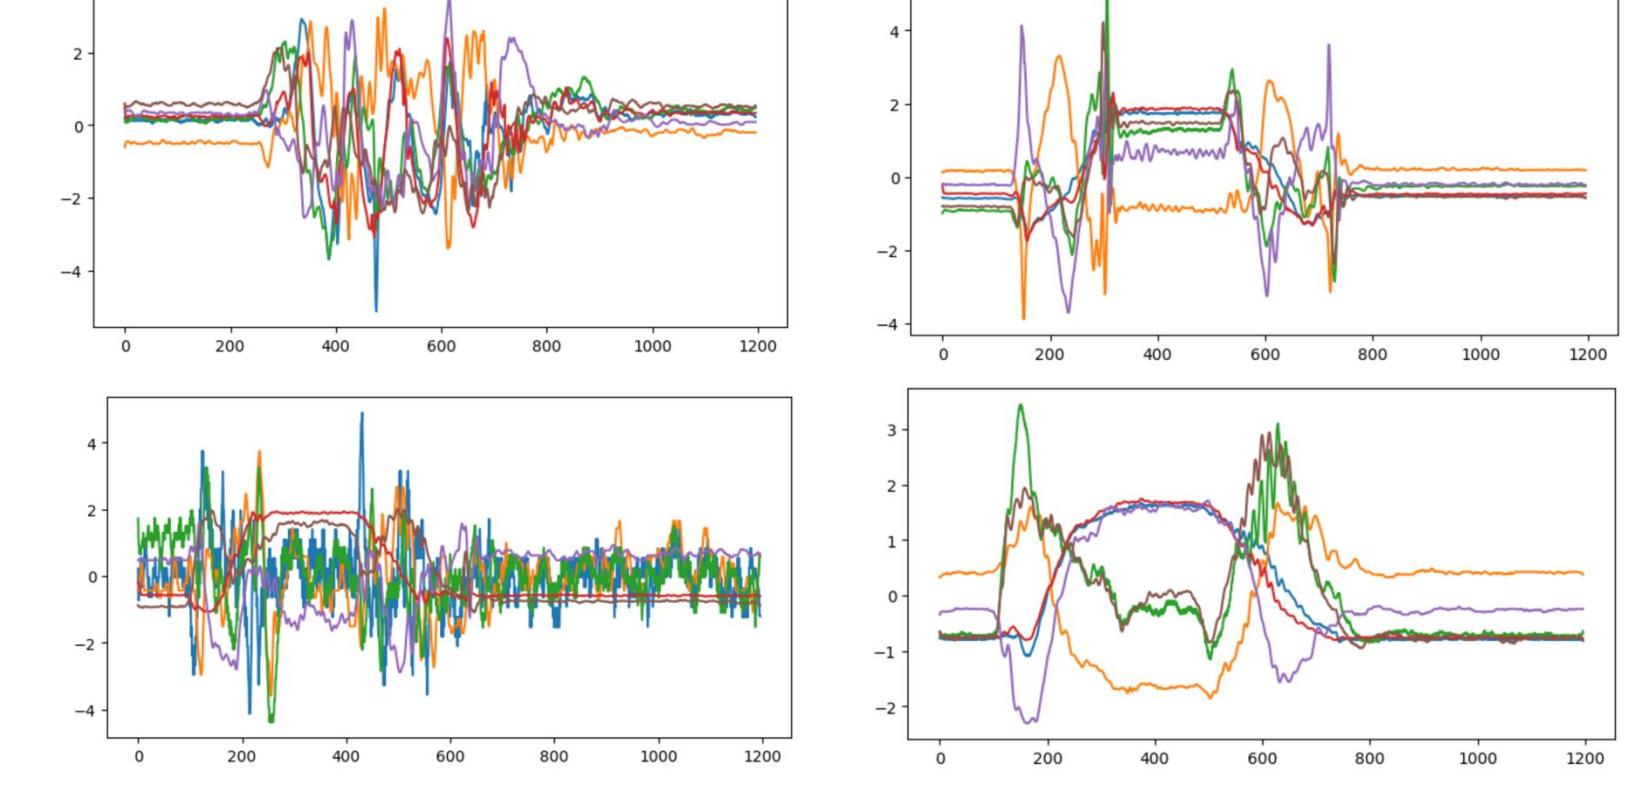
Dataset

モーションキャプチャデータセットを使用

1. BasicMotions
 $T = 100, D = 6, K = 4$



2. Cricket
 $T = 1194, D = 6, K = 12$

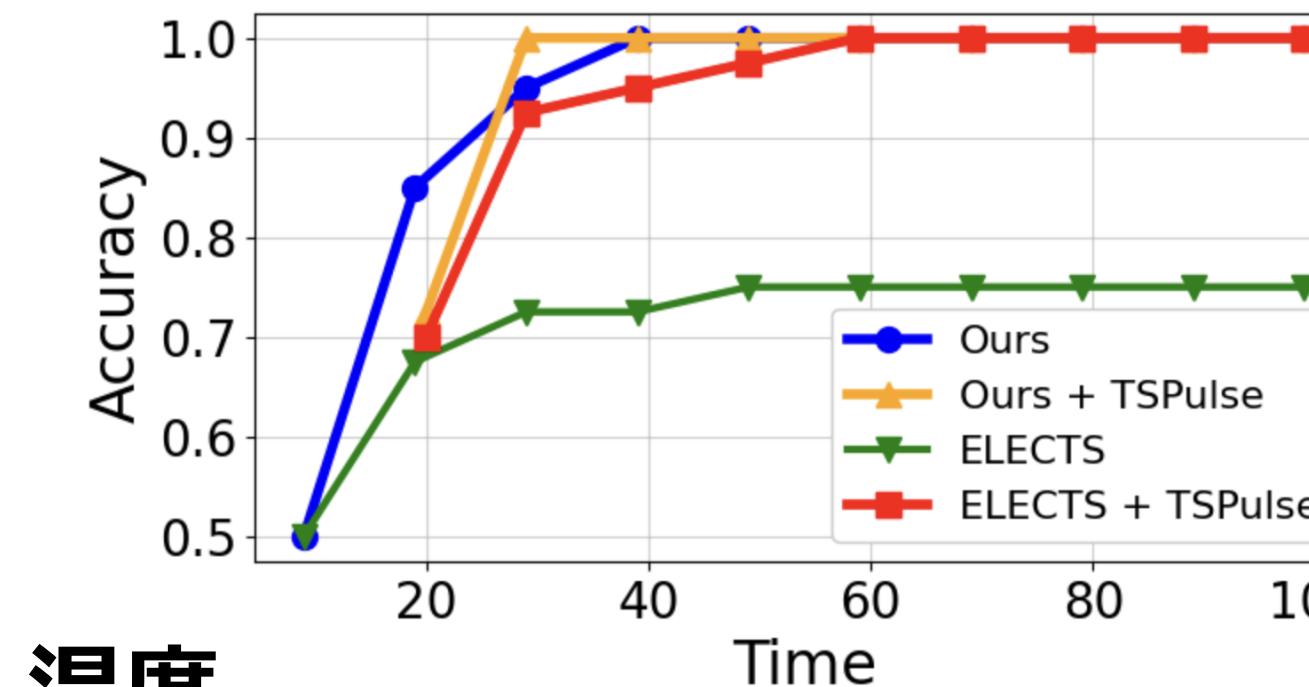


比較手法

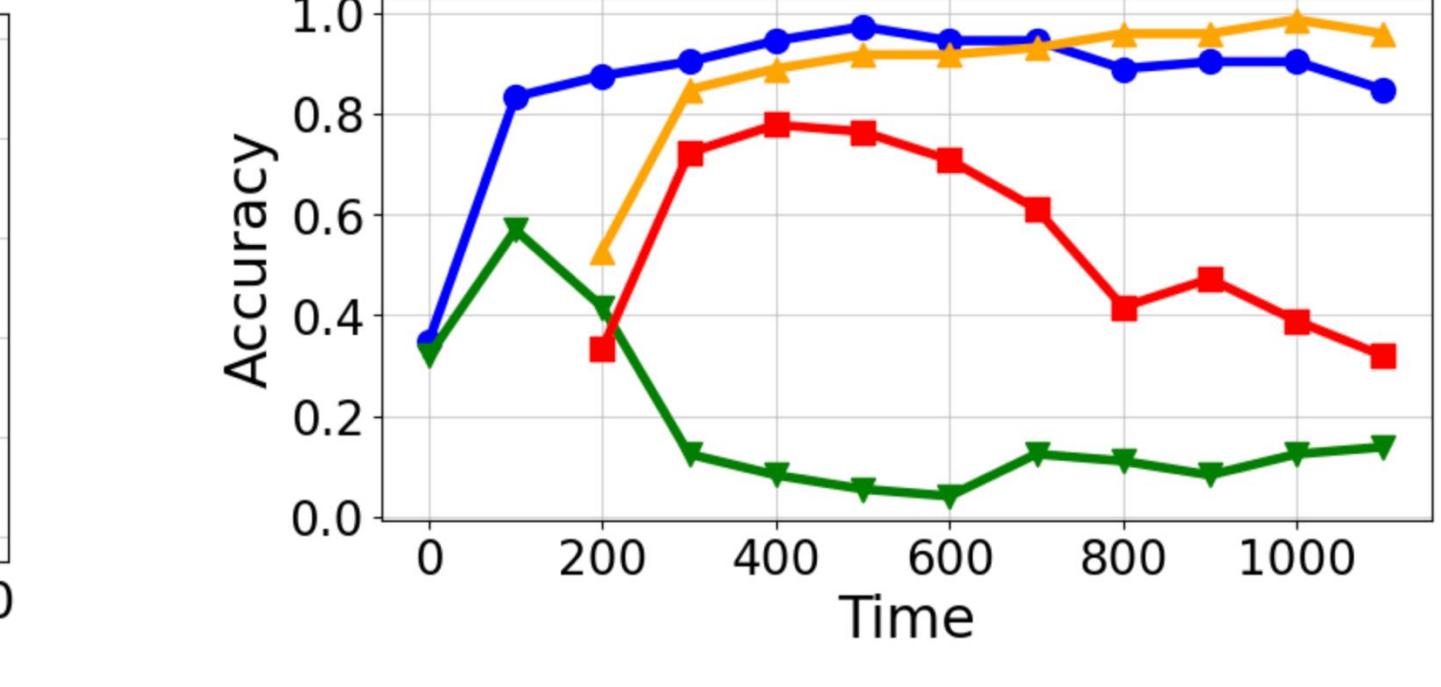
ELECTS: RNNベースで各時刻に分類スコアと信頼度を出力する手法

分類精度

1. BasicMotions




2. Cricket



分類精度

1. BasicMotions



2. Cricket

