

(403) 画像処理

## ごみ焼却炉における蒸気量予測のための因果関係に基づく特徴量抽出

### Feature extraction based on causal relationship for steam prediction in garbage incinerators

松林 幹大<sup>†</sup> 安食 拓哉<sup>††</sup> 前田 俊二<sup>††</sup>

Kanta Matsubayashi<sup>†</sup> Takuya Anjiki<sup>††</sup> Shunji Maeda<sup>††</sup>

<sup>†</sup>Hiroshima Institute of Technology, Graduate School <sup>††</sup>Hiroshima Institute of Technology

#### 1 概要

東日本大震災 (H23 年 3 月) による電力供給不足から、自立・分散型である再生可能エネルギーが重要視されている。再生可能エネルギーの中でも、ごみ発電[1][2]は、太陽光発電や風力発電と比べて安定した電力を供給できることから、その果たす役割が期待されている。H24 年に施行された再生可能エネルギーの固定価格買取制度(FIT)において、ごみ発電もバイオマス発電の一種とみなされるようになり、ごみ処理事業においても発電事業が重要な位置づけとなっている。

#### 2 技術課題

ごみ発電は、ごみ焼却時に発生する蒸気をエネルギー源としている。電力を安定かつ継続的に供給するため、蒸気量の安定制御が要求される。近年では、燃焼状態をカメラで撮影した燃焼画像等の視覚情報による設備の操作、制御が試みられている[3][4][5]。

図 1 に対象設備、図 2 に従来手法を示す。従来では、蒸気量の制御には燃切点と呼ばれる炉内映像の位置座標と蒸気量の目標値との偏差による制御が行われていた。しかし蒸気量は、燃焼状態に対して時間遅れが大きく、かつ燃切点はスカラー量であるため、制御を行うには情報が乏しく、安定制御が困難であった。本研究では、赤外線カメラから得られる画像から取得した特徴と蒸気量との因果関係を調べることで、より安定した蒸気量の制御を行える可能性を見つけることを目標とする。

今回、位相差も考慮した LiNGAM (Linear Non-Gaussian Acyclic Model:線形非ガウスモデル) [6][7][8]を用いる。

本報告では、蒸気量の安定化のため、炉内燃焼が蒸気量に与える影響の要因を LiNGAM による分析を行い、赤外線画像が蒸気量と因果関係を有することを示す。

#### 3 提案手法

図 3 に提案手法を示す。赤外線画像を対象に AE (Autoencoder) による低次元潜在空間に現れる特徴の導出、あるいは CNN (Convolutional Neural

Network:畳込みニューラルネットワーク) [9]や LSTM(Long Short-Term Memory)[10]を用いて、中間層の出力を特徴として活用し、因果関係を把握する。

導出した特徴を時系列データとし、設備に取り付けられた蒸気量のデータとともに時系列データの数理モデルである VAR(Vector Auto Regressive) モデルで表現する。そして、時間差を考慮した因果関係を明らかにする手法として LiNGAM を VAR モデルに適用する。以下、上述した各構成要素を説明する。

#### 3.1 Autoencoder

図 4 に AE の概要を示す。Autoencoder は符号化部と復号部で構成される。入力から符号化によって隠れ層 $\mathbf{y}$ の出力を得て、 $\mathbf{y}$ から入力 $\mathbf{x}$ を再構築した  $\mathbf{z}$ を出力する。 $\mathbf{x}$ と $\mathbf{z}$ 間に誤差関数を定義し、モデルパラメータ $\mathbf{W}, \mathbf{b}$ の最適化を行う。符号化と復号は式(1)(2) で与えられる。

符号化:  $\mathbf{y} = f_{\theta}(\mathbf{x}) = \text{act}(\mathbf{W}\mathbf{x} + \mathbf{b}) \dots \dots \dots (1)$

復号:  $\mathbf{z} = g_{\hat{\theta}}(\mathbf{y}) = \text{act}(\mathbf{W}\mathbf{y} + \mathbf{b}) \dots \dots \dots (2)$

ここで $\mathbf{W}$ は、重み行列、 $\mathbf{b}$  は、バイアスである。 $\text{act}(\cdot)$  は、非線形の活性化関数を表している。隠れ層の出力 $\mathbf{y}$ は、入力より低次元で表現し、特徴として利用する。

#### 3.2 CNN(畳込みニューラルネットワーク)

図 5 に CNN の概要を示す。CNN は畳込み層、プーリング層、全結合層から構成される。畳込み層では入力画像の特徴を強調する。プーリング層では画像を各領域に区切り、各領域を代表する値を抽出することにより、入力画像の特徴を残したまま画像サイズを小さくしている。これら畳込み層とプーリング層のあとにすべてのノードが結合された全結合層が配置されている。本研究では、全結合層の前の層から抽出した特徴を利用する。この特徴に対して、後述の LiNGAM により蒸気量との因果関係を求める。そこで、この特徴を可視化することにする。

#### 3.3 LSTM

LSTM は Recurrent Neural Network(RNN)と呼ばれる中間層が帰還路を持ち再帰的にその中間層に

入力されるネットワークであり、LSTMはRNNの中間層をLSTMブロックに置き換えた構造である。LSTMは時系列データに対する強力な予測モデルである。

### 3.4 VARモデル

センサデータは、時系列データであるため、VARモデルで表現できる。ここで、VARモデルとは、時系列データ $\mathbf{y}_t$ を、定数と自身の $p$ 期前の過去の値に回帰したものであり、次数 $p$ のVAR( $p$ )モデルは

$$\mathbf{x}_t = \mathbf{c} + \Phi_1 \mathbf{x}_{t-1} + \dots + \Phi_p \mathbf{x}_{t-p} + \boldsymbol{\varepsilon}_t, \quad \boldsymbol{\varepsilon}_t \sim \mathbf{W.N.}(\boldsymbol{\Sigma}) \quad (3)$$

と表現できる。例えば、次数 $p=1$ の2変量のVARモデル(3)は、式(4)で表される。

$$\begin{cases} x_{t,1} = \phi_{11}x_{t-1,1} + \phi_{12}x_{t-1,2} + c_1 + \varepsilon_{t,1} \\ x_{t,2} = \phi_{21}x_{t-1,1} + \phi_{22}x_{t-1,2} + c_2 + \varepsilon_{t,2} \end{cases} \quad (4)$$

上記モデルから分かるように、時系列 $x_{t,1}$ と $x_{t,2}$ とはお互いに影響を与え、かつ受ける構造となっている。センサデータの個数を $n$ とすると、VAR( $p$ )モデルは $n$ 個の回帰式からなる。

### 3.5 LiNGAM

LiNGAMでは、連続な観測変数 $x_{t,1}$ の線形関係が下記モデルで表される。

$$\mathbf{x}_{t,i} = \sum \mathbf{B}_{t-k,ij} \mathbf{x}_{t-k,j} + \mathbf{e}_i \quad (5)$$

回帰係数 $\mathbf{B}_{t-k,ij}$ の係数項 $b_{t-k}$ は、観測変数 $x_{t,1}$ に与える影響の強さを示す。また、回帰係数 $\mathbf{B}_{t-k,ij}$ は、行成分を変数が生成される順序に並べると、下三角行列となる。ここでICA(Independent Component Analysis: 独立成分分析)[11]とコレスキー分解[12]を用いる。

図6に回帰係数 $\mathbf{B}_{t-k,ij}$ の推定モデルのフローチャートを示す。以下、手順を説明する。

式(3)の誤差項 $\boldsymbol{\varepsilon}_t$ の分散共分散行列 $\boldsymbol{\Sigma}$ は次式にて表される。

$$\boldsymbol{\Sigma} = \text{Var}(\boldsymbol{\varepsilon}_t) = \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix} \quad (6)$$

ここで $\rho$ は $\varepsilon_{t,1}$ と $\varepsilon_{t,2}$ の相関係数 $\text{Corr}(\varepsilon_{t,1}, \varepsilon_{t,2})$ である。次に、 $\boldsymbol{\Sigma}$ にICAを行い、その行列を分散共分散行列 $\boldsymbol{\Sigma}_{ICA}$ とする。

$$\boldsymbol{\Sigma}_{ICA} = \text{ICA}(\boldsymbol{\Sigma}) \quad (7)$$

$\boldsymbol{\Sigma}_{ICA}$ に対し、コレスキー分解し、下三角行列 $\mathbf{P}$ を生成する。

$$\mathbf{P}\mathbf{P}^{-1} = \text{chol}(\boldsymbol{\Sigma}_{ICA}) \quad (8)$$

ここで下三角行列 $\mathbf{P}$ は、以下のように表される。

$$\mathbf{P} = \begin{pmatrix} P_{11} & 0 \\ P_{21} & P_{22} \end{pmatrix} \quad (9)$$

下三角行列 $\mathbf{P}$ と $\mathbf{P}$ の対角成分を抽出した対角行列 $\mathbf{D}$ より復元行列 $\mathbf{W}$ が生成される。ICAでは復元行列 $\mathbf{W}$ の行の順序は求められないが、非ガウスと独立を仮

定したLiNGAMモデルにより復元行列 $\mathbf{W}$ が推定できる[13]。

$$\mathbf{D} = \begin{pmatrix} P_{11} & 0 \\ 0 & P_{22} \end{pmatrix} \quad (\text{diag}(\mathbf{D}) = \text{diag}(\mathbf{P})) \quad (10)$$

$$\begin{aligned} \mathbf{W} &= \mathbf{D}\mathbf{P}^{-1} = \begin{pmatrix} P_{11} & 0 \\ 0 & P_{22} \end{pmatrix} \frac{1}{P_{11}P_{22}} \begin{pmatrix} P_{22} & 0 \\ -P_{21} & P_{11} \end{pmatrix} \\ &= \frac{1}{P_{11}P_{22}} \begin{pmatrix} P_{11}P_{22} & 0 \\ -P_{12}P_{22} & P_{11}P_{12} \end{pmatrix} = \begin{pmatrix} 1 & 0 \\ -\frac{P_{21}}{P_{11}} & 1 \end{pmatrix} \quad (11) \end{aligned}$$

算出した復元行列 $\mathbf{W}$ と単位行列 $\mathbf{I}$ より、以下の式に従って、基準回帰係数 $\mathbf{B}_0$ が生成される。

$$\mathbf{B}_0 = (\mathbf{I} - \mathbf{W}) = \begin{pmatrix} 0 & 0 \\ \frac{P_{21}}{P_{11}} & 0 \end{pmatrix} \quad (12)$$

基準回帰係数 $\mathbf{B}_0$ とVAR係数 $\Phi$ を用いて回帰係数 $\hat{\mathbf{B}}$ が算出される。

$$\hat{\mathbf{B}} = (\mathbf{I} - \mathbf{B}_0)\Phi \quad (13)$$

この回帰係数 $\hat{\mathbf{B}}$ が過去の各時刻から現在への影響の強さを表す。

$\hat{\mathbf{B}}$ の値を評価することで因果関係を明らかにすることが可能となる。また、その正負から影響方向の推定が可能である。

## 4 実験条件と実験結果

### 4.1 実験条件

赤外線画像を対象にAE, CNN, LSTMをそれぞれ適用し特徴抽出を行う。抽出した特徴を時系列データとし、設備に取り付けられた蒸気量のデータとともにVARモデルで表現する。そして、LiNGAMを適用し蒸気量に対する因果関係を明らかにする。

実験条件を表1に示す。赤外線画像のサイズは、64×48画素である。赤外線カメラは4fpsの速度で48,732sの期間画像を取得している。AEではこの画像データを対象とし、4層の符号化部で4次元の特徴を抽出する。学習回数は200回とした。CNNでは層の数は4層とし、抽出する特徴は6次元、学習回数は100回とした。また、LiNGAMのLagを10とし、蒸気量への影響を同時刻から1分毎に10分前まで求めた。

### 4.2 実験結果

図7にCNNとLSTMを用いて抽出した特徴量と蒸気量の波形を示す。赤線が蒸気量であり、その他が特徴量を示す。図8に実験結果を示す。蒸気量に影響を与えると考えられる要因を左側に置き、右側に影響を与えられている蒸気量を置き、矢印で結び、影響の向きを示している。矢印の上の数値は影響の大きさを表している。

図の左半分にある5つの要因は設備管理者が実際に制御に使用している炉内温度、赤外線画像における輝度値や可視光カメラで取得した燃切点を示し、同図の右半分は赤外線画像からAEおよびCNNよ

り抽出した特徴を示している。

燃焼帯温度と後燃焼帯温度の影響が蒸気量に大きく出ている。これらは容易に理解できる関係である。輝度値は大きな影響を確認することができなかった。燃切点は上記温度と輝度の中間に位置する。AE は特徴量の各要素の影響は小さいが、これらの二乗和平方根を求めると燃切点に近い値であることが確認できた。これに対し CNN の特徴量は、各要素の影響が大きくなり、これらの二乗和平方根は従来指標の燃切点を超える値となった。これらの結果から、赤外線画像に着目し CNN により求めた特徴量が蒸気量と因果関係があることが確認できた。また、図7に示している LSTM の特徴量は赤線の蒸気量波形と類似しており、因果関係は明らかであるため LiNGAM による評価は割愛している。

上記結果を踏まえ、CNN と LSTM による特徴量を LSTM の入力として蒸気量の予測[14]を行った。結果を図9に示し、表2はそれぞれの予測誤差を示す。LSTM を用いて抽出した特徴量での予測が最も誤差が小さく、赤外線画像から蒸気量の予測を行なうのに必要な情報を有し、蒸気量の安定制御に有効であると考えられる。

## 5 結論

本報告では、ごみ発電量安定化のために炉内燃焼において蒸気量に影響を与える要因の分析を行った。LSTM を用いて抽出した赤外線画像の特徴が蒸気量に強い因果関係があることが確認できた。適切な特徴抽出により、赤外線画像は制御指標としてのポテンシャルを有すると考えられる。

## 参考文献

[1] タクマ環境技術研究会「基礎からわかるごみ焼却技術」, オーム社(2017)

[2] Paul Guyer, “An Introduction to Solid Garbage Incineration”, Independently published, 2018.8.

[3] 國政瑛大, 吉川充, 岡島重伸, 桂木格, 藤田志津男「遠隔監視・支援システムの運用」, 第38回全国都市清掃研究・事例発表会講演論文集, pp.64-66(2017.1).

[4] 株式会社クボタ: 自動燃焼制御装置.  
[http://www.keisoku.kubota.ne.jp/keisokusystem/cat\\_files/acc.pdf](http://www.keisoku.kubota.ne.jp/keisokusystem/cat_files/acc.pdf).

[5] 黒田学他「高感度センサーによる燃焼制御システム」, NKK 技報, No.176, pp.26-29(2002.3).

[6] Aapo Hyvärinen, Kun Zhang, Shouhei Shimizu, Patrik O. Hoyer, “Estimation of a Structural Vector Autoregression Model Using Non-Gaussianity”, Journal of Machine Learning Research, Vol. 11, pp.1709-1731, May 2010.

[7] Aapo Hyvärinen, Kun Zhang, Shouhei Shimizu, Patrik O. Hoyer, “Estimation of a Structural Vector

Autoregression Model Using Non-Gaussianity”, Journal of Machine Learning Research, Vol. 11, pp.1709-1731, May 2010.

[8] Wolfgang Wiedermann and Alexander von Eye : Statistics and Causality, “Methods for Applied Empirical Research”, Wiley, pp.152-183, May 2016

[9] 中山英樹「深層畳み込みニューラルネットワークによる画像特徴抽出と転移学習」, 電子情報通信学会音声研究会7月研究会, 2015.

[10] Xingjian Shi et all, Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting, NIPS(2015)

[11] A. Hyvärinen, J. Karhunen and E. Oja. “Independent Component Analysis”, John Wiley & Sons. 2001

[12] Nicholas J. Higham, “Accuracy and Stability of Numerical Algorithms”, Society for Industrial and Applied Mathematics, August 2002

[13] 清水昌平「統計的因果探索」, 講談社(2017)

[14] Kanta Matsubayashi, Takuya Anjiki, Shunji Maeda, “analyzing causal relationships of sensor data and infrared images to stabilize garbage power generation”, ICMLC2019, (2019, 7, 9).

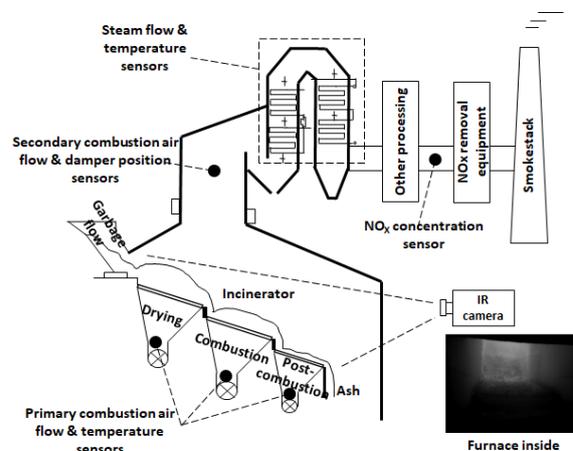


図1 対象設備

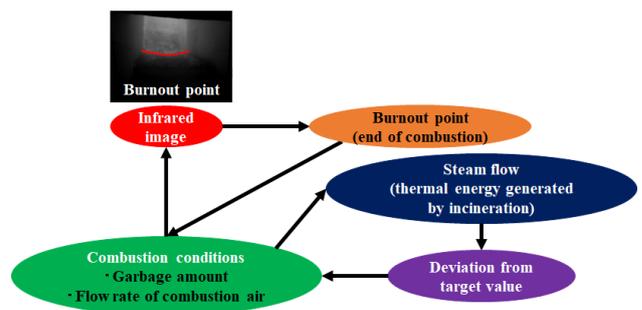


図2 従来手法

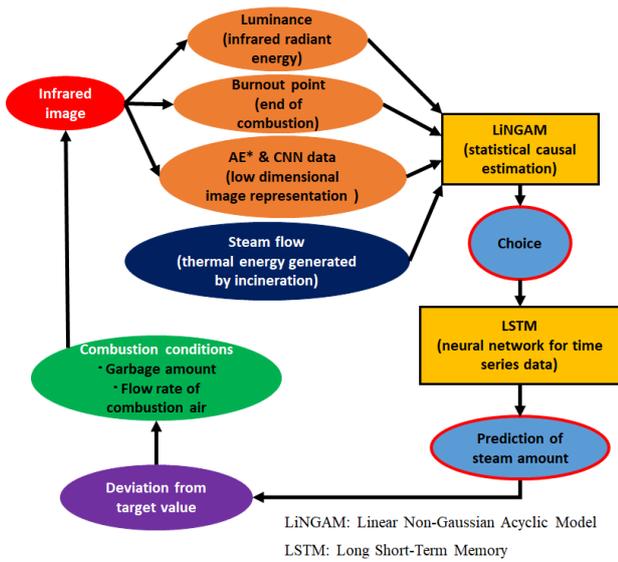


図3 提案手法

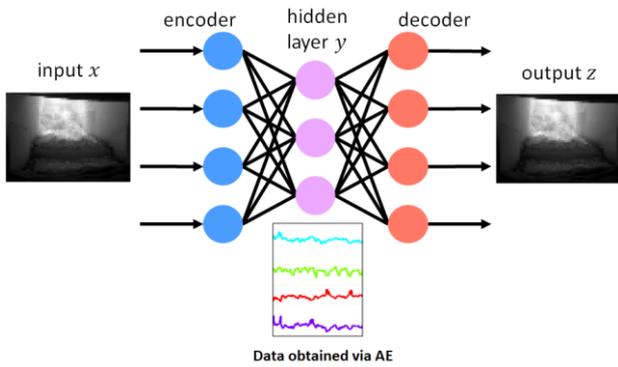


図4 AEの概要

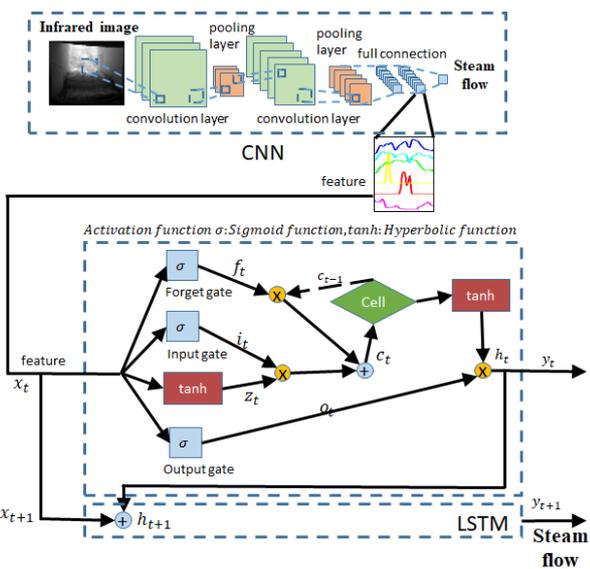


図5 CNNによる特徴抽出とLSTM

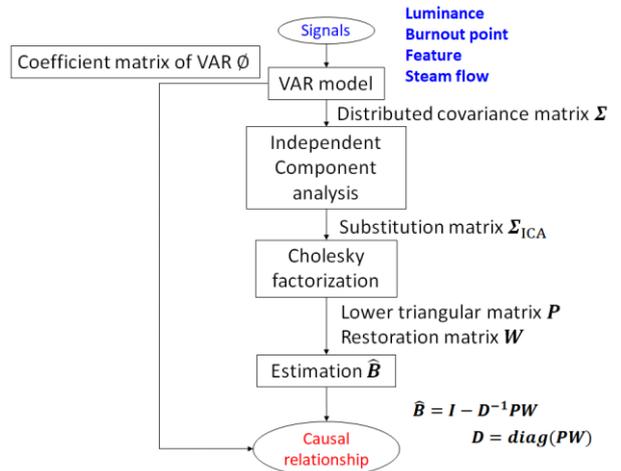


図6 LiNGAMのフローチャート

表1 実験条件

Image size		64×48 pixels
AE	Number of data points	48,732
	Number of features	4
	Layer structures	4 (encoder/decoder)
	Learning iteration	200
	Batch size	5
CNN	Number of data points	1,900
	Number of features	12
	Layer structures	4
	Learning iteration	100
LiNGAM	Batch size	40
	Sampling interval	60 s
	VAR order	2
	Lag	10

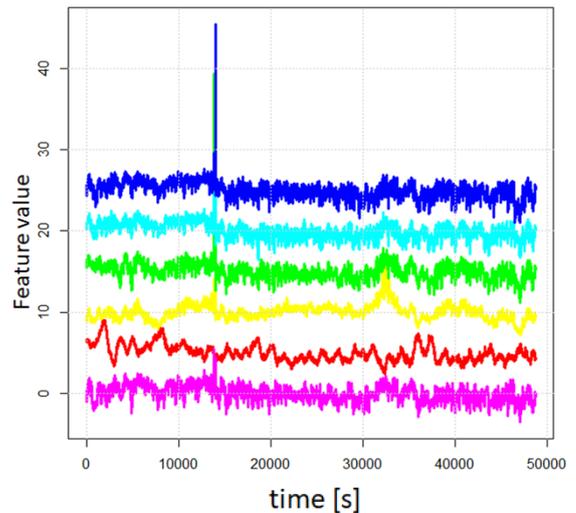


図7 特徴量の可視化結果 (CNN)

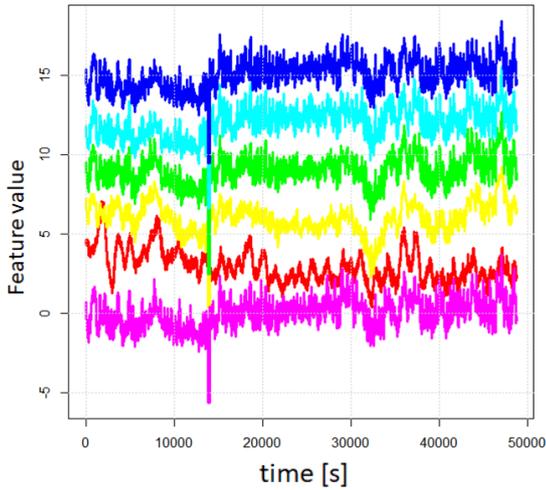


図 8 特徴量の可視化結果 (LSTM)

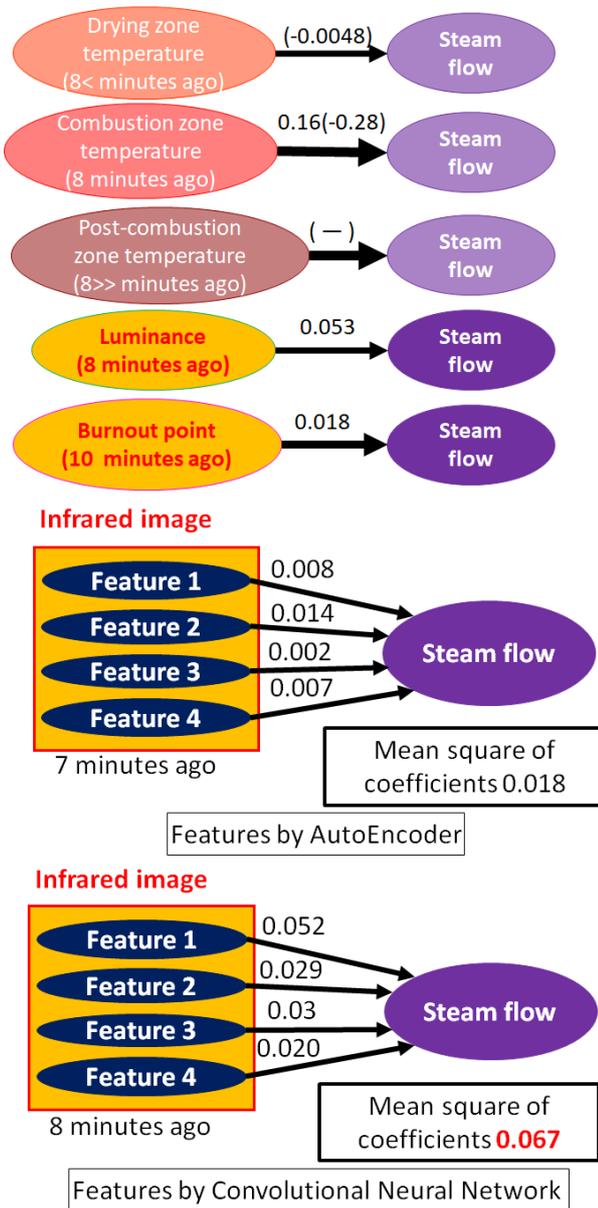
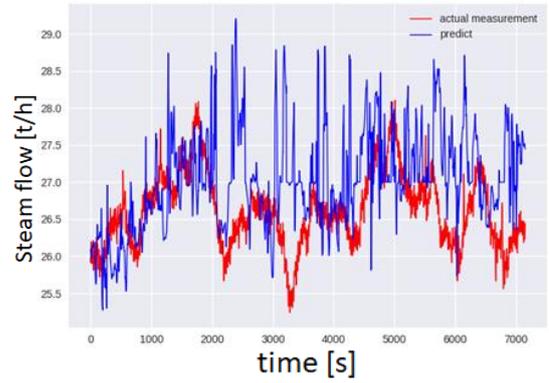
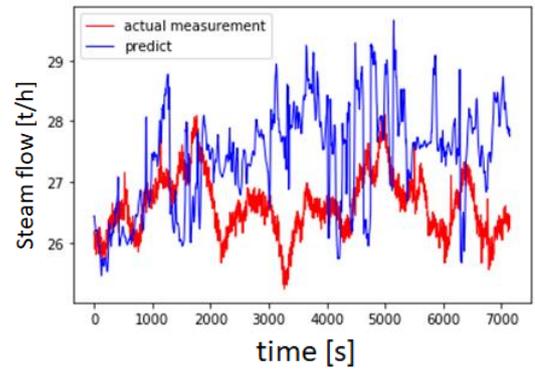


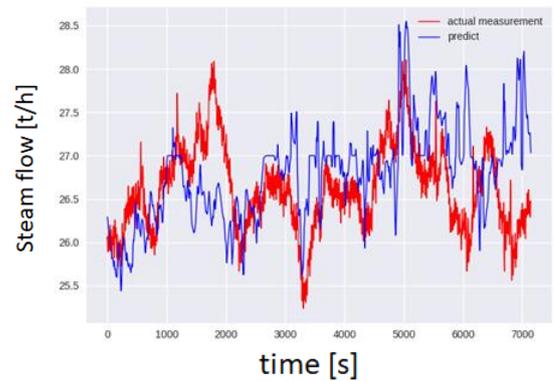
図 9 LiNGAM の実験結果



(a) AE



(b) CNN



(c) LSTM

図 10 蒸気量の予測結果

表 2 蒸気量の予測誤差

特徴抽出	AE	CNN	LSTM
MAE(t/h)	0.65	0.85	0.53