アスファルトプラントにおける ベテランオペレータのバーナ運転を模倣する 運転支援システムの開発

浜辺拓真
HAMABE Takuma
日工株式会社　開発部　開発3課

要旨

製造業全体の課題として、次世代への技能継承という課題がある。本開発ではアスファルトプラント（以下、プラント）に関する技術継承を補助するために、AI技術を活用してベテランオペレータの運転技術を見える化し、プラント運転の専門知識を持たない新人オペレータでもベテランオペレータと同等の運転を可能とする運転支援システム（以下、運転支援システム）の開発に取り組んでいる。

具体的には、プラント装置のバーナに着目し、ベテランオペレータの運転を様々な条件下でAIに学習させて、バーナ開度の予測モデルを作成している。そして、各条件におけるバーナ開度の実測値と、予測モデルによる予測値とを比較し、平均絶対誤差を確認することで予測モデル作成の最適な条件について検証を行っている。

1. 背景

製造業全体の課題として、次世代への技能継承の成功率が低いという課題が存在している[1]。この原因の1つとして、ベテランオペレータの技術に暗黙知の要素が含まれており、勘所を見える化することが困難であるということが挙げられる。

そこで本開発では、アスファルトプラントの技術継承を補助するために、AI技術を活用してベテランオペレータの運転技術を見える化し、プラント運転の専門知識を持たない新人オペレータでもベテランオペレータと同等のプラント運転を実現できる運転支援システムの開発に取り組んだ。

2. 目的

本稿では、運転支援システムの中でも特に重要な機能である、ベテランオペレータのバーナ運転を模倣するための予測機能に焦点を当て、訓練データの適切な条件を明らかにし、バーナを着火してから骨材温度が設定温度に到達するまでの立ち上げ運転（以下、立ち上げ運転）において、本機能の実現可能性を検証することを目的としている。検証の対象とするバーナは、骨材の供給量や供給する骨材の種類と比率（供給配合）が変化する新規骨材の加熱乾燥用に用いるバーナ（以下、Vバーナ）とした。筆者は、検証結果を基にベテランオペレータの模倣を実現することで、プラント運転の専門知識を持たない新人オペレータであっても、予測モデルのガイダンスによりベテランオペレータと同等の運転が可能な運転支援システムの実現を目指している。さらに、プラントを制御する操作盤において骨材の加熱乾燥時に用いられているPID制御[2]の改良を含めたプラントの完全自動化や、プラントのリモート操作による運転サービスの実現に向けた取り組みを予定している。

ベテランオペレータの運転を模倣するための予測機能の実現可能性の検証は、プラントの専門知識を持たない新人オペレータがベテランオペレータと同等のプラント運転を実現するために必要であり、この予測機能は、当社が目指しているプラントの完全自動化に向けた重要な基礎技術となる。

3 試験内容

3.1 試験に用いるアルゴリズム

バーナ運転の模倣に使用する予測モデルは、LSTM（Long Short-Term Memory）およびCNN（Convolutional Neural Network：畳み込みニューラルネットワーク）を使用した。

LSTMは時系列データを処理できるニューラルネットワーク構造である。これはRNN（Recurrent Neural Network：再帰型ニューラルネットワーク）の一種であり、長期の記憶を保持できる記憶セル（memory cell）の導入によって、RNNが直面していた「長期記憶の消失」の問題を解決している。LSTMは、通常のRNNの隠れ状態の代わりに、再帰的に「記憶セルブロック」を使用する構造を採用しており、これによって長期および短期の記憶を同時に利用することができる。記憶セル内では、「全結合層 + 活性化関数」の出力値を重み付け係数として使用し、他の経路の値を調整するゲート機構（gating mechanism）を学習する[3]。

CNNは、局所的な特徴の抽出に特化したニューラルネットワーク構造である。このネットワークは入力データから局所的な特徴を抽出し、それらを畳み込み演算によって集約して最終的な出力を生成する。一般的にCNNは2次元の空間的特徴を抽出するために画像処理に使用されるが、1次元の時系列データにも適用することが可能である。この場合、固定時間幅の履歴情報に基づいて予測を行うことができる[4]。

3.2 検証項目と試験結果

予測精度の高い予測モデルを作成するための適切な条件を評価することを目的に、以下の検証を実施した。

1. 学習期間の検証
2. 季節性の検証
3. 入力パラメータの検証
4. 立ち上げ運転のみを抽出した検証
5. 手動立ち上げ運転の検証
6. 入力パラメータに温度パラメータを追加した検証
7. 学習データを絞った検証

検証5.は検証4.と同様に学習データとして立ち上げ運転のみを抽出した検証となっている。検証4.は手動運転と自動運転の両方を学習対象とし、検証5.は手動運転のみを対象としている。なお、自動運転は操作盤によるバーナ開度の操作を、手動運転はベテランオペレータによるバーナ開度の操作を意味する。

3.2.1 学習期間の検証

適切な学習期間の条件を明らかにするため、予測モデルの学習期間（訓練データおよび検証データの期間）を変化させ、平均絶対誤差（MAE：Mean Absolute Error）の挙動を確認した。MAEは真の値と予測値の差の絶対値の平均を表し、予測がどれだけずれているかを評価できる。通常、MAEは誤差をできるだけ小さくしたいときに利用され、MAEが小さくなるほど真値と予測値の差が小さくなる。今回はバーナ開度に関する予測精度を検証するため、予測されたバーナ開度とベテランオペレータの操作の差を表す指標としてMAEを採用した。各検証で得られるMAEの平均を平均MAEと呼称して、予測モデルの性能評価値として使用した。

学習期間と平均MAEの関係を**表3.1**に示す。表から、全体の傾向として、学習期間が長いほど平均MAEが低くなることが確認できた。すなわち、予測モデルの性能が向上することが示された。

学習期間が2週間から1か月の間では平均MAEの改善が顕著であるが、1か月以上の学習期間では改善幅が緩やかとなった。この結果より、導入までの時間を短くするため、6カ月の改善幅の84%に1か月の学習期間で到達できることを根拠として、学習期間は1か月とするのが適切であると判断した。

図3-1に学習期間が2週間および1か月の予測モデルでバーナ開度を予測したトレンドグラフを示す。実線は予測値、破線は実測値を示している。グラフからも、1か月の予測モデルの方が実測値との誤差が少なくなり、学習期間が2週間の予測モデルよりも優れた予測結果を出力していることが確認できる。

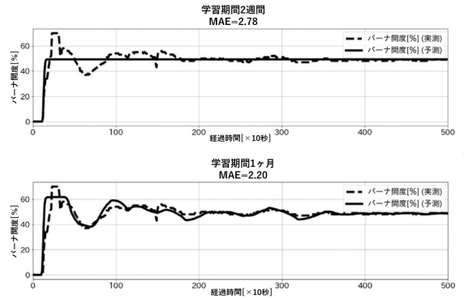

図3-1 学習期間2週間と1か月のモデルで比較したバーナ開度のトレンドグラフ

表3.1　学習期間と平均MAEの関係

学習期間	2 週間	1 か月	2 か月	3 か月	6 か月
平均 MAE [%]	10.5	5.93	5.87	5.44	4.99

3.2.2 季節性の検証

予測モデル作成に使用したデータの外気温と検証に使用したデータの外気温が乖離することにより予測精度が変化すると考え、予測モデル作成に使用するデータの取得時期（以下、学習時期）と予測モデルの精度検証に使用するデータの取得時期（以下、検証時期）を変化させて予測精度について検証を実施した。本検証は学習時期を2021年4月1日～2021年4月30日で固定し、検証時期を変化させることでMAEの挙動を確認した。

学習時期と検証時期のズレと平均MAEの関係を**表3.2**に示す。表より、学習時期とテスト時期のズレが1週間から3か月であれば、時期のズレが大きくなるほど平均MAEが大きくなる傾向があるが、1年および2年では平均MAEが1週間と同等もしくはそれ以下となっている。

以上より、1年ごとの周期性が現れており、予測精度は予測モデル作成に使用したデータと検証に使用したデータの外気温に強い相関があることが示唆された。以上の結果より、季節ごとに予測モデルを更新する必要があることが分かった。

3.2.3 入力パラメータの検証

予測精度を向上させるため、予測モデルの作成に使用する骨材温度をはじめとするパラメータ（以下、入力パラメータ）を変化させることで、予測精度が向上するか検証を行った。

表3.2 学習～検証時期のズレと平均MAEの関係

学習時期と検証時期のズレ（検証データの取得時期）	1週間（2021/5/6~12）	2週間（2021/5/6~18）	1か月（2021/5/6~31）	2か月（2021/6/1~30）	3か月（2021/7/1~31）	1年（2022/4/1~30）	2年（2023/4/1~28）
平均MAE［%］	7.80	8.54	9.48	8.73	9.11	7.67	6.51

入力パラメータと平均MAEの関係を**表3.3**に示す。これまでの検証では、骨材温度、設定温度、供給量合計値の3つを入力パラメータとして使用していたため、この3つのパラメータをデフォルト条件とし、条件Aと呼称した。条件Aに、各フィーダの供給量を追加した場合、砂のフィーダ供給量のみを追加した場合、条件Aから供給量合計値を除いて砂のフィーダの供給量を追加した場合をそれぞれ条件B～Dと名付け、それぞれの平均MAEを導出した。

表より、条件Aの入力パラメータにおける平均MAEが最も低く、入力パラメータを増加させると予測精度が悪化する傾向にあるといえる。例として、条件AおよびBの予測モデルでバーナ開度を予測したトレンドグラフを**図3-2**に示す。実測値は破線で、予測値は実線で表現している。グラフからも、条件Aの予測モデルの方が実測値に適合する予測結果を出力していることが確認できる。しかし、バーナ開度の制御には供給している砂に含まれる水分量の影響が大きいと考えられるため、入力パラメータに関しては引き続き検証を行うこととした。

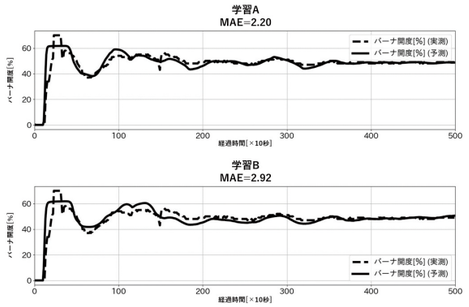

図3-2 条件A、Bのモデルで比較したバーナ開度のトレンドグラフ

3.2.4 立ち上げ運転のみを抽出した検証

これまでの検証ではバーナを着火してから消火するまで（以下、バーナ運転全体）を学習していたが、本開発ではバーナの立ち上げ運転に焦点を当てているため、立ち上げ運転のみを抽出した検証を行い、予測モデルの性能が向上するか確認した。なお、本検証では立ち上げ時の運転が自動運転であっても手動運転であっても学習の対象とした。立ち上がりの運転範囲はバーナが着火してから骨材温度が収束するまでとし、収束条件は「極値が3回連続で設定温度±8℃の範囲内（以下、整定範囲内）に入った時点、または6分間整定範囲内に収まった時点」とした。収束条件の説明図を**図3-3**に示す。図3-3の例では、灰色着色部を骨材温度が収束しているものとして扱っている。この収束条件は運転の再現性・品質や運転データ数の確保が十分にできると判断したものを筆者が設定して、検証を行った。

バーナ運転全体の学習と、骨材温度が収束した立ち上げ運転のみの学習を行った際の平均MAEの関係を**表3.4**に示す。表より、骨材温度が収束した立ち上げ運転のみの学習をすることで、平均MAEは高くなり、予測精度が低下していることがわかる。さらに、バーナ運転全体を使用した予測モデルと、骨材温度が収束した立ち上げ運転のみを使用した予測モデルでバーナ開度を予測したトレンドグラフを**図3-4**に示す。グラフの破線は実測値、実線は予測値である。トレンドグラフからも、バーナ運転全体を使用した予測モデルの方が実測値に適合する予測結果を出力していることが確認できる。一般的に、訓練データの数が少ないと予測精度が低下する傾向がある。今回、対象を立ち上げ運転に絞ることで訓練データ数が74%減少した。このデータ数の大幅な減少が予測精度低下の原因と考えられる。さらに、立ち上げ運転のみを評価対象としたことにより、予測しやすい骨材温度が収束したあとの予測部分がなくなったことで、MAEが低下したと考えられる。本検証では立ち上げ運転に焦点を当てているため、立ち上げ運転の予測精度を上げる方法について、引き続

表3.3 入力パラメータと平均MAEの関係

条件名	A	B	C	D
入力パラメータ	・骨材温度［℃］ ・設定温度［℃］ ・供給量合計値［×0.1 t/h］	・骨材温度［℃］ ・設定温度［℃］ ・供給量合計値［×0.1 t/h］ ・各フィーダ（No.1～10）の供給量［×0.1 t/h］	・骨材温度［℃］ ・設定温度［℃］ ・供給量合計値［×0.1 t/h］ ・砂フィーダの供給量［×0.1 t/h］	・骨材温度［℃］ ・設定温度［℃］ ・砂フィーダの供給量［×0.1 t/h］
平均MAE［%］	5.93	7.16	6.54	8.90

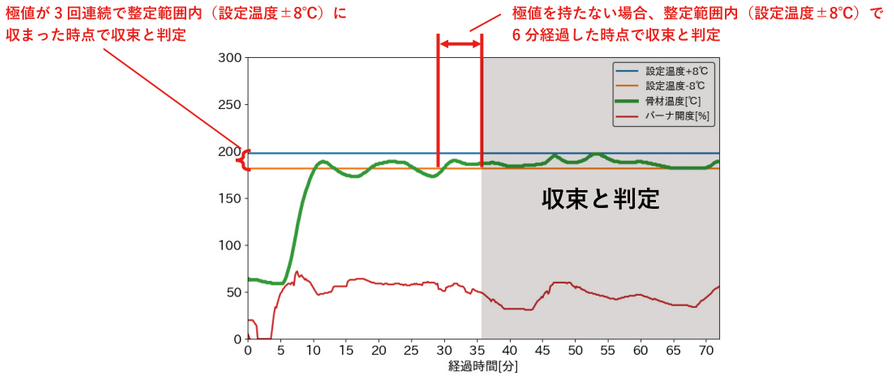

図3-3 収束条件の説明図

表3.4 立ち上げ運転抽出前後で比較した平均MAE

学習範囲	平均MAE［%］	データ数
バーナ運転全体	5.93	81
骨材温度が収束した立ち上げ運転のみ	9.99	21

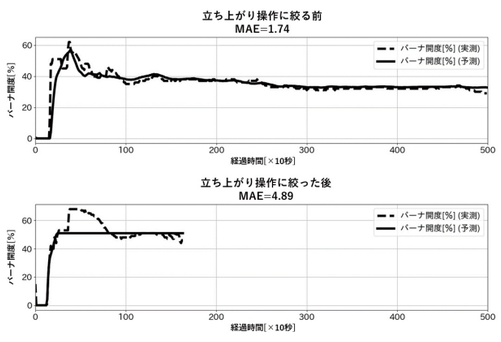

図3-4 立ち上げ運転抽出前後で比較したトレンドグラフ

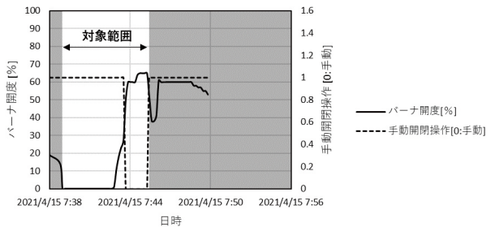

図3-5 手動立ち上げ運転の対象範囲

3.2.5 手動立ち上げ運転の検証

これまでの検証では立ち上げ時の運転が自動運転であっても手動運転であっても学習の対象としていたが、自動運転部はベテランオペレータの意思が介在していない。運転支援システムが目指しているベテランオペレータの運転を模倣するため、立ち上げ時の自動運転部と手動運転部の両方を含む予測モデルと、ベテランオペレータの意思が介在する立ち上げ時の手動運転部のみを抽出した予測モデルを比較し、性能が向上するかどうかを検証した。具体的な立ち上げ時の手動運転の対象範囲を**図3-5**に示す。対象範囲は運転を開始後、手動運転から自動運転に切り替えるまでとした。なお、本検証は同一データを使用し、学習する範囲を変化させる検証のため、データ数に変更はない。

学習範囲を立ち上げ時の手動運転のみに変更する前後で比較した平均MAEを**表3.5**に示す。

さらに、自動運転と手動運転を含む予測モデルと、手動運転のみを抽出した予測モデルでバーナ開度を予測したトレンドグラフを**図3-6**に示す。実線が予測値、破線が実測値である。

表と図より、手動立ち上げ運転のみを抽出した運転データを学習することで平均MAEが低くなっており、予測モデルの性能が向上していることを確認できた。この結果から、予測モデルの予測精度を上げるためには模倣したい運転のみを学習し、訓練データの質を向上させる必要があることがわかった。

表3.5 手動立ち上げ運転抽出前後で比較した平均MAE

学習範囲	平均MAE［%］
全運転	12.5
手動運転部のみ	6.8

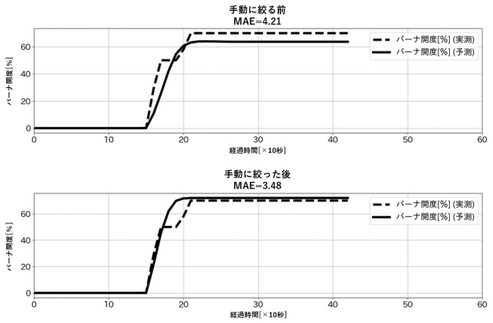

図3-6 手動立ち上げ運転抽出前後で比較したバーナ開度のトレンドグラフ

3.2.6 入力パラメータに温度パラメータを追加した検証

予測精度向上を図るため、外気温を入力パラメータに追加することを考えた。しかし、既存のプラントでは外気温を測定していないため、バグ入口温度、煙道温度（以下、温度パラメータ）を入力パラメータに用いることで、間接的に外気温を入力パラメータとし、予測モデルの性能が向上するかどうかを確認した。温度パラメータはプラントの運転状況に大きく依存し、骨材供給が終了してから十分な冷却時間の経過により外気温と同等の温度に近づくと考えられる。しかし、データ数を確保するため、十分に冷却時間を確保しているデータを抽出した検証は行わず、入力パラメータに追加するという方法で検証を行った。

入力パラメータに温度パラメータを追加する前後で比較した平均MAEの関係を**表3.6**に示す。表より、入力パラメータに温度パラメータを追加することで、平均MAEは低くなっていることから予測モデルの性能が向上したことが確認できた。

表3.6 温度パラメータを追加する前後で比較した平均MAEの関係

学習範囲	平均MAE［%］
温度パラメータ追加前	7.31
温度パラメータ追加後	6.69

温度パラメータを入力パラメータに追加した予測モデルと、温度パラメータを追加しない予測モデルでバーナ開度を予測したトレンドグラフを**図3-7**に示す。実線は予測値、破線は実測値を表す。グラフからも、温度パラメータを追加した方が、実測値に適合する予測結果を出力していることが確認できる。さらに、十分に冷却時間を確保したデータのみを抽出した予測モデルは、訓練データの質が上がることにより予測精度が向上することが示唆された。

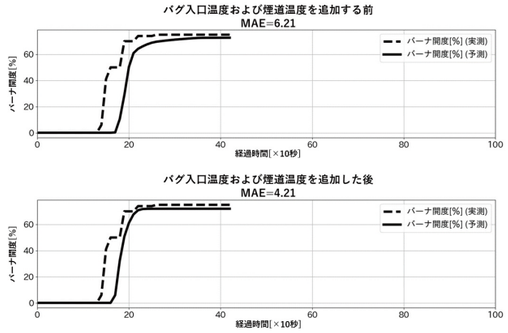

図3-7 温度パラメータを追加する前後で比較したバーナ開度のトレンドグラフ

3.2.7 学習データを絞った検証

季節変化による外気温の変化が予測モデルの性能に影響を及ぼすと考えられるため、気温の変動が小さい期間において学習およびテストを行い、予測モデルの性能向上に関する検証を行った。2020年11月～2021年3月の気温変動を**図3-8**に示す。11月から12月では気温の差が大きく、12月から2月では気温の変動が小さくなることから運転データの対象期間を2020年12月～2021年2月とした。学習期間は2021年1月の2週間、テストに用いたデータは2020年の12月と2021年2月のデータとなる。

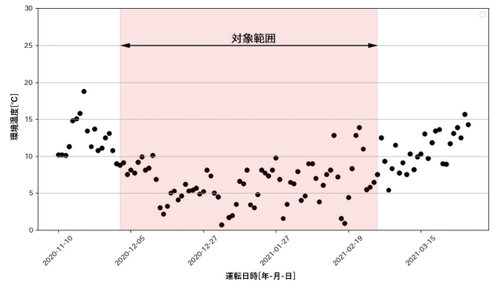

図3-8 2020年11月～2021年3月の気温変動

バーナを着火してからバーナ開度を手動で最初に操作した時間（以下、バーナ開度を最初に操作した時間）に関して

は、人為的な変動が予想され、予測モデルの性能に悪影響を及ぼす可能性がある。そこで、バーナ開度を最初に操作した時間の変動による悪影響を排除するために、バーナ開度を最初に操作した時間に着目して、**図3-9**の模式図における着色部が示すようにデータ全体の80%を選択して、学習データを絞ることで予測モデルの性能が向上するか検証を行った。なお、使用したデータの割合は運転データ数の確保が十分にできると判断したものを筆者が設定して、検証を行った。実際に検証に使用したデータにおけるバーナ開度を

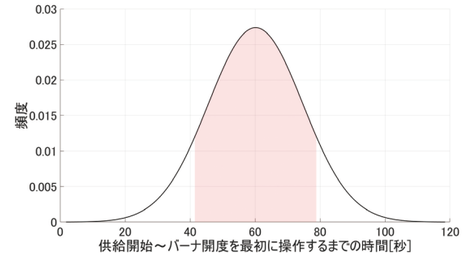

図3-9 検証に使用したデータの模式図

学習データを絞る前後と平均MAEの関係を**表3.7**に示す。表より、気温の変動が小さく、かつバーナ開度を最初に操作した時間が近いデータに絞って学習することで、平均MAEが低くなっており、予測モデルの性能が向上していることが確認できた。

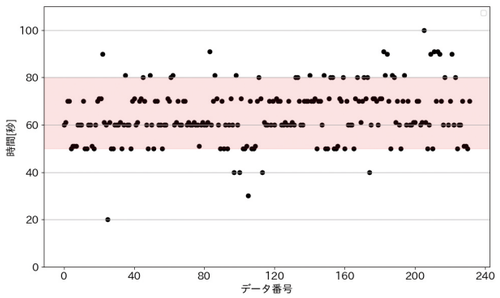

図3-10 2020年12月～2021年2月の供給開始からバーナ開度を最初に操作するまでの時間

表3.7 学習データを絞る前後と平均MAEの関係

学習範囲	平均MAE［%］
データを絞る前	6.80
データを絞った後	4.13

学習データを絞る前後の予測モデルでバーナ開度を予測したトレンドグラフを**図3-11**に示す。実線が予測値、破線が実測値を表す。グラフからも、学習データを絞った後の方が実測値に適合する予測結果を出力していることが確認できる。

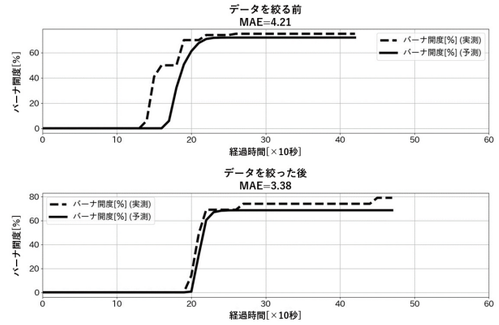

図3-11 学習データを絞る前後で比較したバーナ開度のトレンドグラフ

4 まとめ

本稿では、ベテランプラントオペレータのバーナ運転を基にVバーナ開度予測モデルを作成し、訓練データの適切な条件を評価した。

試験により得られた適切な条件は、手動立ち上げ運転に焦点を当て、気温の変動が小さい条件のもと、バーナ開度を最初に操作するタイミングが近いデータを選別することである。一方で、気温変動が大きい季節に関する予測や、作成した予測モデルと異なる季節における予測精度に課題が残っているため、今後課題解決に向けて取り組む必要がある。

5 今後の展望

今後の展望としては、作成した予測モデルの精度をフィールドテストにて検証する。さらに、予測モデルが季節の変化に伴う外気温の変化に対応できるような予測モデルの改良に取り組むことで、運転支援システムに必要なデータ数削減を実現して、早期に社会実装するための手法について検証を行う。

参考案件

1) 経済産業省 2023年版ものづくり白書（ものづくり基盤技術振興基本法第8条に基づく年次報告）2023/6/2 pp.51-57 https://www.meti.go.jp/report/whitepaper/mono/2023/pdf/all.pdf
2) 熊谷秀樹, 基礎からの自動制御と実装テクニック, pp125-127,2011.
3) S. Hochreiter and J. Schmidhuber. “Long short-term memory.” Neural computation 9.8 (1997): 1735-1780.
4) Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner. Gradient-based learning applied to document recognition. Proceedings of the IEEE, 86 (11):2278–2323, 1998.

筆者紹介

HAMABE Takuma
浜辺　拓真
2015年入社
開発部
開発3課