

ディープラーニングを用いた低 SNR 下での生体信号抽出

In vivo Signal Extraction Under Low SNR by Deep Learning

○小野崎海, 佐藤宏明*, 長田洋*, 恒川佳隆*

○Kaishi Onozaki, Hiroaki Sato*, Hiroshi Osada*, Yoshitaka Tsunekawa*

岩手大学大学院, *岩手大学理工学部

Graduate School of Arts and Sciences, Iwate University,

*Faculty of Science and Engineering, Iwate University

キーワード: 生体信号(In vivo Signal), ディープラーニング(Deep Learning)
長短期記憶(Long Short-Term Memory), 双方向 LSTM(Bidirectional LSTM)

連絡先: 〒020-8551 岩手県盛岡市上田 4-3-5 岩手大学理工学部

佐藤 宏明, Tel: 019-621-6392, E-mail: hsato@iwate-u.ac.jp

1. はじめに

近年, 高齢者期の急速な進行を背景に, 単身世帯や高齢者の一人暮らしが増加している. それに伴い, 孤独死や循環器疾患などによる死亡者の増加が問題となっている. このような突発的な症状に対応するためには長期的な生体情報の計測が必要である. 生体情報の計測方法として, 呼吸サーミスタ方式や, 心電を計測するためのホルスター心電計などがある. これらの方法ではプローブを被験者に取り付けるため, 身体を拘束しなければならず, これは患者にとって身体, 精神的な負担を伴うために長期の計測が困難になるという問題がある[1].

これまで我々は, 無線通信で用いられる送信アンテナ 1 本と受信アンテナ 2 本を使用した SIMO (Single-Input Multiple-Output) 計測システムを用い, 生体信号の観測を遠隔かつ非接触で行ってきた[2].

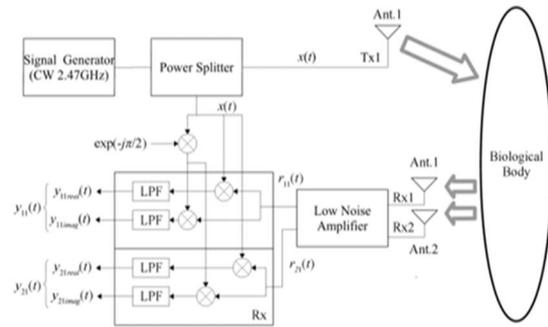


図 1 SIMO 計測システム

本稿では, 深層学習の分野で用いられる, 帰型ニューラルネットワークアーキテクチャの一つである LSTM (Long Short-Term Memory) と Bidirectional LSTM (BiLSTM) を用いた生体信号予測と LSTM の予測精度改善の検討を行う.

2. マイクロ波を用いた生体信号の検出

図 1 に示した, 無線通信で用いられる送信ア

ンテナ 1 本と受信アンテナ 2 本を使用した SIMO 計測システムを用いている。被験者の胸部から呼吸時の生体信号の測定を 30 秒間行った。アンテナと被験者の距離は 50 cm, 床からの高さは 90 cm, 送信信号として 2.47 GHz 帯の連続無変調波 (CW) を使用し, 出力レベルは 6.00 dBm とした受信信号と CW を掛け合わせた出力信号を計測する。送信信号を $x(t) = \cos(\omega t)$ とおき, 受信後の信号を $[r_{11}(t) \ r_{21}(t)]^T$ とすると, 伝搬環境の変化を表す伝搬チャネルは $[h_{11}(t) \ h_{21}(t)]^T$ と表せる。これらを用いて受信信号ベクトル $\mathbf{r}(t)$ は式 (2.1) のように表せる。

$$\mathbf{r}(t) = \begin{bmatrix} r_{11}(t) \\ r_{21}(t) \end{bmatrix} = \begin{bmatrix} h_{11}(t) \\ h_{21}(t) \end{bmatrix} \cos(\omega t) \quad (2.1)$$

受信機 Rx により受信信号と CW が掛け合わされた後, 生じる高調波は受信機内のローパスフィルタによって除去され, 出力信号は式 (2.2) のように表される。

$$\mathbf{y}(t) = \frac{1}{2} \begin{bmatrix} h_{11}(t) \\ h_{21}(t) \end{bmatrix} \quad (2.2)$$

図 2 に受信アンテナから得た 30 秒分の計測信号データ A を示す。

本研究では, LSTM と BiLSTM を用いて計測信号を学習, 予測するだけでなく, 予測精度向上を行う。

3. LSTM と BiLSTM による学習と予測

3.1 パーセプトロン

人間の脳はニューロンという神経細胞が網の目状に繋がって構成されており, このニューロン間での電気信号で物事を認識すると考えられている。ニューラルネットワークはこの構造を模している。図 3 のように入力した値がすぐに出力に伝播する最も単純な形をしたモデルを単純パーセプトロンと呼ぶ。ここで定義した

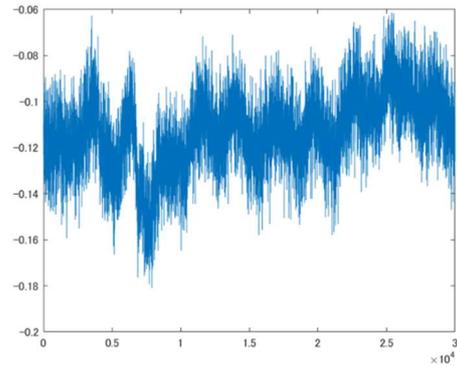


図 2 計測信号データ A

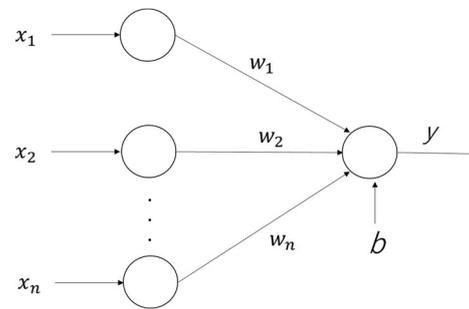


図 3 単純パーセプトロン

\mathbf{x} を入力ベクトル, \mathbf{w} を重みベクトル, b をバイアスと呼ぶ。入力ベクトルと重みベクトルを式 (3.1) のように表す。

$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix}, \quad \mathbf{w} = \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_n \end{bmatrix} \quad (3.1)$$

重みはニューロン間の結合の強さ。バイアスは出力の閾値を指す。入力された値が閾値を超すと情報が出力される。ニューロンの出力は式 (3.2) の形で表される。 f は活性化関数を表す [3]。

$$y = f(\mathbf{w}^T \mathbf{x} - b) \quad (3.2)$$

3.2 多層パーセプトロン

多層パーセプトロンは図 4 のように表される。入力と出力以外の中間のニューロンが繋がっている。ニューロンが層として連なっていると考

えて、入力を受け取る層を入力層、出力をする層を出力層、入力層と出力層の間にある層を隠れ層という。図4での入力ベクトル \mathbf{x} , 重みベクトル \mathbf{w} を次の式(3.3)の形で表される。

$$\mathbf{x} = \begin{bmatrix} x_1 \\ \vdots \\ x_i \\ \vdots \\ x_J \end{bmatrix}, \quad \mathbf{w} = \begin{bmatrix} w_{11} \\ \vdots \\ w_{ji} \\ \vdots \\ w_{J1} \end{bmatrix}, \quad \mathbf{b} = \begin{bmatrix} b_1 \\ \vdots \\ b_{ji} \\ \vdots \\ b_{J1} \end{bmatrix} \quad (3.3)$$

隠れ層における出力を表す式は、入力ベクトル \mathbf{x} , 重みベクトル \mathbf{w} とバイアスベクトル \mathbf{b} に対して次の式(3.4)の形で表される。 f は活性化関数, \mathbf{h} は隠れ層ベクトルである。

$$\mathbf{h} = f(\mathbf{w}^T \mathbf{x} - \mathbf{b}) \quad (3.4)$$

隠れ層-出力層間では、隠れ層ベクトル \mathbf{h} , 重みベクトル \mathbf{v} とバイアスベクトル \mathbf{c} は式(3.5)の形で表される。

$$\mathbf{h} = \begin{bmatrix} h_1 \\ \vdots \\ h_j \\ \vdots \\ h_J \end{bmatrix}, \quad \mathbf{v} = \begin{bmatrix} v_1 \\ \vdots \\ v_{kj} \\ \vdots \\ v_{KJ} \end{bmatrix}, \quad \mathbf{c} = \begin{bmatrix} c_1 \\ \vdots \\ c_{kj} \\ \vdots \\ c_{KJ} \end{bmatrix} \quad (3.5)$$

隠れ層-出力層間の出力を表す式は、重みベクトル \mathbf{v} とバイアスベクトル \mathbf{c} に対して式(3.6)の形で表される。 g は活性化関数, \mathbf{y} は出力ベクトルである[4]。

$$\mathbf{y} = g(\mathbf{v}^T \mathbf{h} - \mathbf{c}) \quad (3.6)$$

多層パーセプトロンは画像認識の分野で用いられており有効と認められているが、本研究で用いる胸部変位データには適していない。人の胸部変位は1次元の時間変化関数(時系列データ)である。図4の多層パーセプトロンは多次元入力, 多次元出力のデータを扱うのに向いている。そこで、時系列データを扱うことに適しているとされる LSTM を用いることにより規則性を学習し、そのデータの未来を予測する。

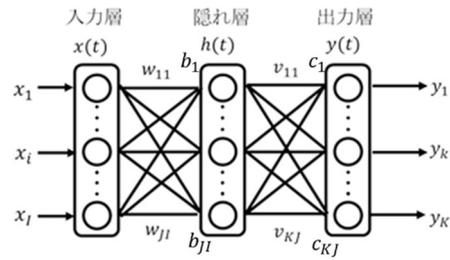


図4 多層パーセプトロン

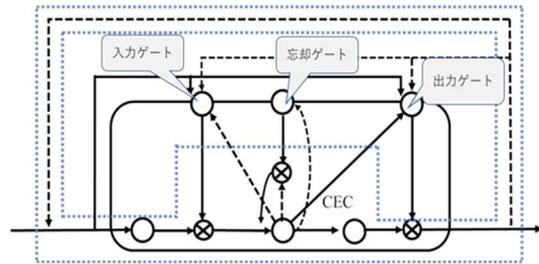


図5 LSTM ブロック

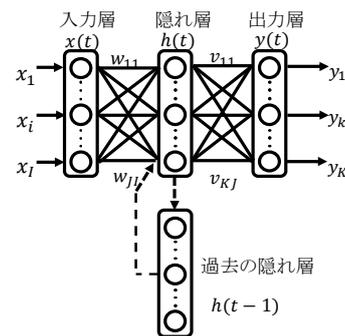


図6 過去の隠れ層を加えたモデル

3.3 LSTM

通常モデルでは扱えない時系列データを扱う為に LSTM を用いる。図4のニューロン (○) の代わりに図5に示す LSTM ブロックを配置する。

LSTM ブロックの主な役割は、過去の情報をニューラルネットワーク内に保持すること、過去の情報を必要なタイミングで取得、置換することである。LSTM ブロックは構造として CEC(Constant Error Carousel), 入力ゲート, 忘却ゲートが繋がって出来て

いる。図 5 内の青い線で囲われている部分が CEC にあたる。CEC で入力された値を必要になるまで保持している。

入力ゲート，出力ゲートは過去の情報が必要になったタイミングでのみゲートを開けて信号を伝播する。それ以外はゲートを閉じておき過去の情報を保持する。

忘却ゲートは，入力となる時系列データ内でパターンが劇的に変化する場合に過去の情報を記憶しておく必要が無くなる為，そのタイミングで CEC に保持しておいた情報を忘れるという命令を出す。

CEC と各ゲートは覗き穴結合で繋がり，CEC に保持された情報を伝えている。この時伝える状態は入力，忘却ゲートには過去の状態を，出力ゲートには現在の状態を伝えている。

これらの構造により，LSTM は過去の情報をニューラルネットワーク内に保持すること，過去の情報を必要なタイミングで取得，置換することの 2 つを実現している[5]。

LSTM ブロックを用いる事で，多層パーセプトロンにおける隠れ層の他に「過去の隠れ層」をつくる事が出来る。図 6 に過去の隠れ層を加えたモデルを示す。全体の構成は「入力層-隠れ層-出力層」だが，時刻 t における入力 $x(t)$ に加えて時刻 $t-1$ における隠れ層の値 $h(t-1)$ を保持しておき，それも時刻 t における隠れ層に伝える点が通常のモデルと異なる。時刻 t の状態を $t-1$ の状態として保持しフィードバックさせる為，過去の隠れ層の値 $h(t-1)$ の中には過去の決定された状態が全て反映されている。

3.4 BiLSTM

BiLSTM は，順方向の LSTM と逆方向の

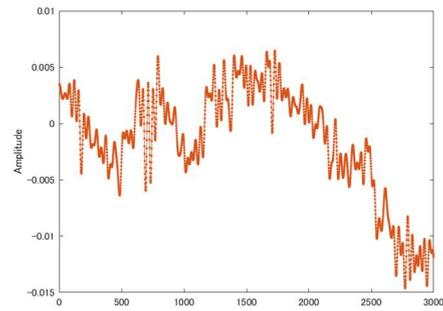


図 7 LSTM 処理後の
予測波形

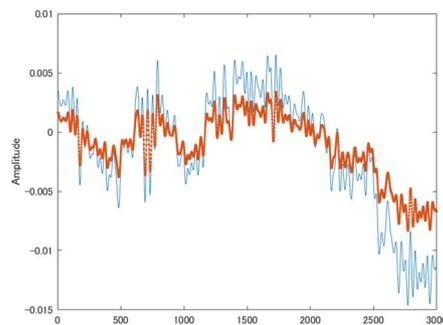


図 8 BiLSTM 処理後の
予測波形

LSTM を持った構造をしている[6]。BiLSTM はデータを予測する時に，予測したい信号を x_n とすると， $x_0 \sim x_{n-1}$ と $x_{END} \sim x_{n+1}$ を用いて予測を行うといった特徴がある。これにより同じデータの量を学習に用いた場合 LSTM よりも多くのデータ量を扱うことが可能である。しかし，多くのデータ量を扱うため LSTM よりも処理に時間がかかってしまう。

3.5 学習結果

図 2 の 30 秒間の計測信号を学習データとテストデータに分割し検証を行う。1 kHz でサンプリングした全 30000 サンプルの最初から 9 割を学習データに，残りをテストデータとした。分割した学習データとテストデータを使い，LSTM と BiLSTM を用いて

処理を行う。この時、学習率を 0.005 とし、隠れ層を 200 で学習を行った。図 7 に LSTM によるデータの予測、図 8 に BiLSTM によるデータの予測を示す。図 7, 8 の青い線がテストデータ、オレンジ線が予測データを表している。BiLSTM の予測は LSTM よりも精度が悪くなった。これは、学習データの外れ値等を多く学習してしまったためだと考えられる。しかし、BiLSTM のテストデータと予測した値は異なるが同じ形を描くことはできている。これより BiLSTM でも時系列データの予測に用いることが可能であると考える。

次に少ない学習データで良い予測精度の結果を得ることが出来れば、扱えるデータ量が増えて得られる情報も増えると考えた。計測波形の学習データに用いる時間の割合を 9 割から 1 割ずつ減らしていき、1 割になるまで変更し、LSTM と BiLSTM を用いて学習と検証を行った。図 9 にこの概要を示す。テストデータと予測した波形のずれを式 (3.4) の形で表される RMSE (Root Mean Square Error, 二乗平均平方根誤差) を用いて表現する。 n がデータ数、 y_i が予測した値、 f_i が実際の正しい値を示す。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - y_i)^2} \quad (3.4)$$

学習データとテストデータの比率を変更して行った結果を図 10 に示す。図 10 より、LSTM は学習データの割合が少ないと予測精度が大幅に低くなってしまいが、BiLSTM は学習データの割合に大きく依存しないことが確認できた。

4. LSTM の予測精度改善

3.5 の実験より、少ない学習データでも

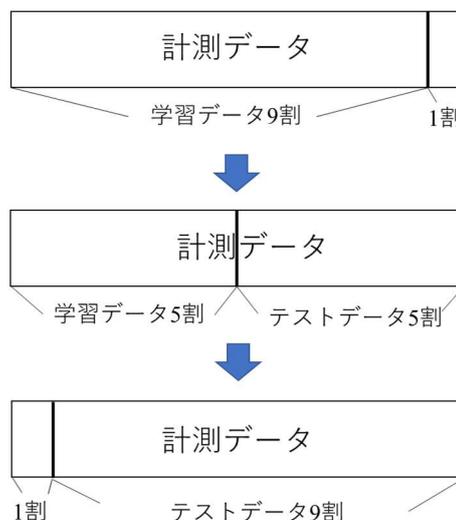


図 9 学習データ割合変更の概要

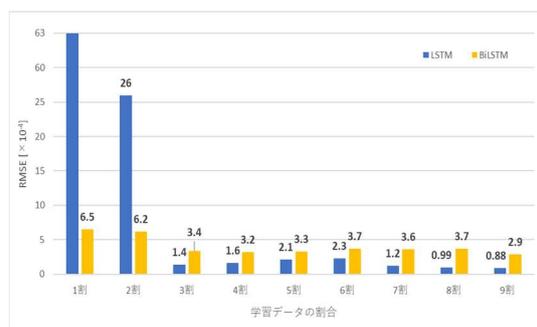


図 10 学習データとテストデータの割合を変更して行った結果

予測を行うことが可能なのは確認できた。ここからは、LSTM の RMSE が 1.0×10^{-4} に近づけられるように検討を行う。LSTM の予測精度向上のため 2 つの実験を行った。

1 つ目は、学習不足が起きていると考え学習回数を 250 から 50 ずつ増やして 500 まで行った。学習データの割合は 90%, 80%, 20%, 10% の 4 つで行った。結果を図 11 に示す。図 11 より、学習データの割合が多いときは予測精度改善が行えているが少ないときは予測精度改善ができていない。外れ値等の悪い影響を再度学習したり、不良ノードとい

われる情報提供をしないノードをさらに学習に使ったために予測精度の改善を行えなかったと考えられる。

2つ目は、過学習対策で用いられるドロップアウトを組み込んで実験を行った。ドロップアウトとは、学習時に一定の割合のニューロンを不活性化させながら学習を行う手法のことである。過学習に有効な方法として知られている。学習データの割合は学習不足の時と同じ条件で行った。結果を図12に示す。図12より学習データの割合が多いときは予測精度の改善ができていないが、少ない場合は予測精度の改善を行うことができている。学習不足の時と同様に、外れ値や不良ノードはドロップアウトを組み込むことで無視することができ、予測精度向上につながったと考える。

他の信号でも同様な結果を得られるかを確認するために図13、図14を用意した。データB、データCを用いて行った、学習回数増加の結果を図15、図16に示す。図15と図16から、学習データの割合が多い場合に有効であると確認できる。図11の結果と同様な傾向であるといえる。

次に、LSTMにドロップアウトを組み込み、実験を行った。その結果を図17、図18に示す。図17と図18から、学習データの割合が少ない場合にドロップアウトが有効であることが確認できる。こちらも図12の結果と同様な傾向である。

これら2つのから、学習データの割合が多い場合は学習回数を増やしてあげることさらなる精度改善につながり、学習データの割合が少ない場合はドロップアウトを用いることで予測精度の大幅な改善を行うことが確認できた。

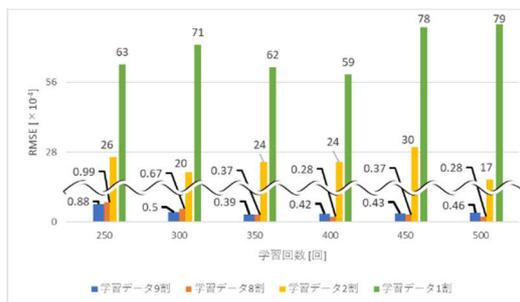


図11 学習回数を増やして行った場合

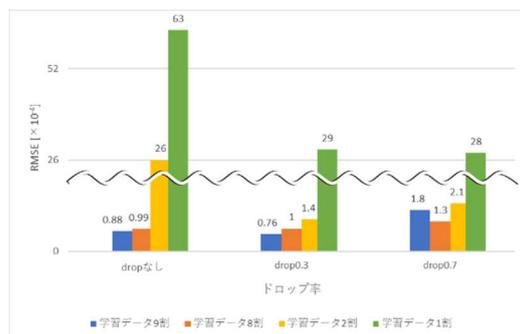


図12 LSTMにドロップアウトを組み込んで行った場合

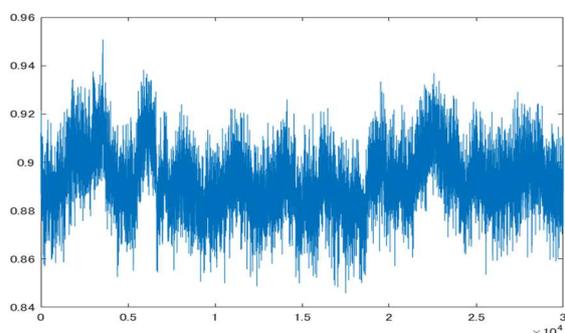


図13 データB

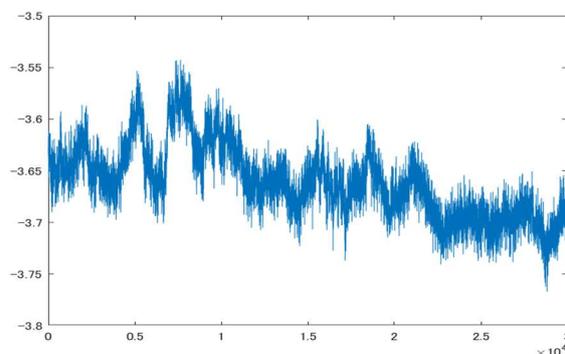


図14 データC

5. まとめ

本稿では, SIMO 計測システムの計測信号にディープラーニングのアルゴリズムを適用した. アルゴリズムは, 時系列データに有効な LSTM と BiLSTM を用いた. LSTM ではテストデータと同じものを予測できたが, BiLSTM ではテストデータと同じ予測を行うことができなかった. しかし, テストデータと同じ形のものを予測はできていたので時系列データに用いることは可能ではないかと考える.

次に学習データの量を変更して予測を行った. BiLSTM の予測精度は学習データ量に大きく依存しないのに対して, LSTM の予測精度は学習データ量に大きく影響されることを確認した. この結果は, BiLSTM の特徴である多くのデータ量を扱えるということによるものと思われる.

LSTM の予測精度改善を行うため, 学習不足対策である学習回数増加と, 過学習対策であるドロップアウトの追加を試した. 学習データの割合が多い場合には学習不足対策が有効であり, 学習データの割合が少ない場合には過学習対策が有効であることが確認できた.

今後は, 学習データの割合が少ない場合の予測精度改善を行う. ドロップアウト以外の過学習対策の手法を LSTM に組み込んでいき予測精度向上を目指す.

6. 参考文献

- [1] 中野広, “人体計測の現状と今後の問題 -非接触人体自動計測装置の開発について-”, 1982 年, 計測と制御 Vol.21 No. 6

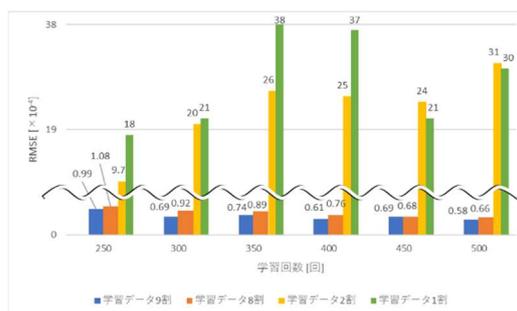


図 15 データ B を用いて学習回数を増やして行った場合

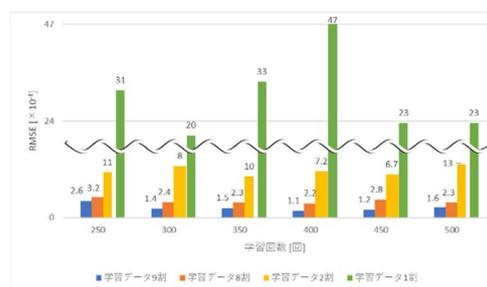


図 16 データ C を用いて学習回数を増やして行った場合

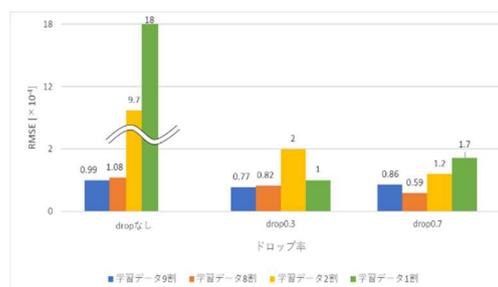


図 17 LSTM にドロップアウトを加えてデータ B を用いた場合

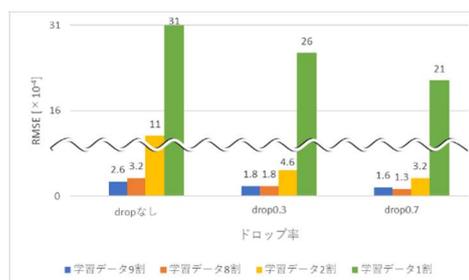


図 18 LSTM にドロップアウトを加えてデータ C を用いた場合

- [2] 大塚皓喜 他, “マイクロ波計測システムへ
適応処理を用いた心拍検出”,2017 年
電子情報通信学会ソサエティ大会,B-20-
9, (2017)
- [3] 巢籠悠輔,“詳解ディープラーニング”,マイ
ナビ出版,2019, p.p.80- 82
- [4] 巢籠悠輔,“詳解ディープラーニング”,マイ
ナビ出版,2019, p.p.119- 124
- [5] 巢籠悠輔,“詳解ディープラーニング”,マイ
ナビ出版,2019, p.228
- [6] 巢籠悠輔,“詳解ディープラーニング”,マイ
ナビ出版,2019, p.p.251- 255