

深層学習を用いた動的機器モニタリング信号による予知保全

Predictive Maintenance of Dynamic Equipment Monitoring Signal using Deep Learning

東京大学
東京大学

出町 和之
寺山 怜司

Kazuyuki DEMACHI Member
Satoshi TERAYAMA Non-Member

A time-series data future prediction algorithm using Long-Short Term Memory (LSTM), which is a kind of Regression Neural Network (RNN), has been proposed for the purpose of detecting early abnormality of monitoring signals of dynamic devices. An improvement for applying this algorithm to actual dynamic equipment monitoring signals was proposed, and an anomaly judgment method was also proposed.

Keywords: Deep Learning, Recurrent Neural Network, Predictive maintenance, Condition Based Maintenance

1. はじめに

予知保全とは、機器のモニタリング信号の少し未来を予測し測定値との乖離を評価することで機器不具合の予兆を検知する手法である。

原子力発電所では多数のセンサーによる複数機器のモニタリングが行われているが、多くの場合において線形予測手法に必要な連続的の時系列特徴が失われており、このために未来予測の精度に限界があった。

そこで本研究では、非線形予測手法の1つである回帰型ニューラルネットワーク (Recurrent Neural Network, RNN) の一種である長期短期記憶ユニット (Long-Short Term Memory, LSTM) を用い、過去の時系列データを入力にして未来予測を行う予知保全アルゴリズムを提案した。さらに提案したアルゴリズムを原子力発電所における実際の不具合モニタリング信号へと適用するための改良を行い、時系列データの未来予測手法としての有効性を示すとともに、異常予兆の判定手法も提案した。

を用いて学習を行うが、系列が長くなると重みが掛けられる回数が多くなり、長期の時間依存性は勾配が消失してしまう[3]。これに対して LSTM では、長期依存性を学習するために導入された LSTM ブロックと呼ばれる回路のような仕組みを並べることにより、長期の時間依存性を学習できなくなる問題が解消された。Figure 1 に LSTM のメモリー・ユニット構造を示す。

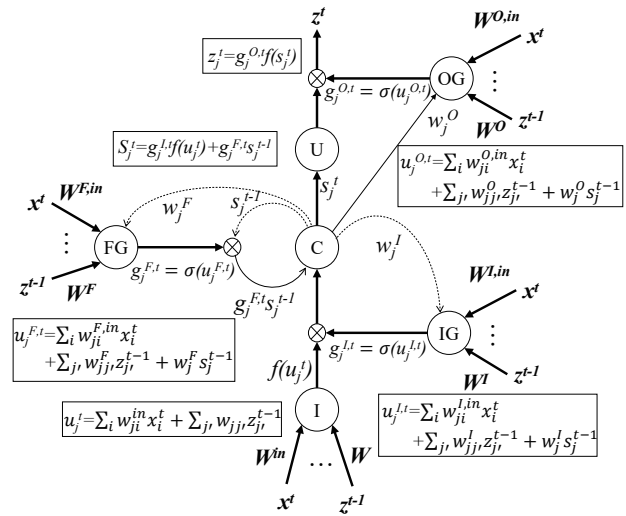


Fig.1 Memory Unit Structure of LSTM

2. 予知保全のための提案アルゴリズム

2.1 長・短期記憶ユニット (LSTM)

LSTM[1]は、時系列性のあるデータを学習できるニューラルネットワークである RNN の一種である。RNN を時間方向に展開すると静的なニューラルネットワークとみることができ、これを誤差逆伝播法[2]

入力ユニット(I)に入力された時刻 t における信号 x^t は、セルを循環して蓄えられつつ、入力ゲート(I)、忘却ゲート(FG)、出力ゲート(O)の演算を受けてメモリーユニット(U)の外へ出力され、最終出力 z^t となる。

メモリーセル(C)ではループを用いて各時刻の(C)の出力を次の時刻の(C)に受け渡す役割をしており、これにより時間方向の情報が保持されている。

また、各ゲートでは x^t と z からゲート値 g を出力し、

連絡先:出町和之、〒113-8654 東京都文京区本郷7-3-1,
東京大学大学院工学系研究科原子力専攻,
E-mail: demachi@n.t.u.tokyo.ac.jp

やってきた信号にゲート値 g' を掛け合わせて出力する。ゲート値は $0 \leq g' \leq 1$ の範囲を取り、1 に近づけば信号はほとんど減衰しないが、0 に近いと忘却の役割を果たす。

これらセルとゲートの働きにより、データの時間方向変化の特徴を捉え、入力された信号が近い未来に取るであろう値を予測することが可能となる。

2.2 LSTM モデルの改良

本研究では未来予測の精度向上のため、本研究では下記の4つの LSTM モデルの改善を行った。

(1) 規格化

学習を進めていくうえで、重みの更新が重要になってくるが、単位や特徴量の異なるデータを一緒に学習させると、重みの更新が適切に行われない可能性がある。そこで、入力データが一定の範囲になるように、(1)式のようにデータの最小値を 0、最大値を 1 とする規格化を行った。ここで x_k は時刻 j におけるセンサー k の出力、 x_{ka} はセンサー k の全時刻における出力を表す。

$$y_{kj} = \frac{x_{kj} - \min(x_{ka})}{\max(x_{ka}) - \min(x_{ka})} \quad (1)$$

(2) ノイズ除去

学習データに含まれるノイズは学習プロセスに無駄な負荷をかけ、学習のスムーズな進行を妨害する。そこで、LPF(Low Pass Filter) をかけることでデータのノイズを軽減した。今回は LPF の中でも簡単な、平均を取る手法を用い、50 ステップ分の平均を取った。

$$\begin{cases} y_{kj} = \frac{\sum_{i=0}^{j-1} x_{k(j-i)}}{j-1} & (50 > j) \\ y_{kj} = \frac{\sum_{i=0}^{50-1} x_{k(j-i)}}{50} & (50 \leq j) \end{cases} \quad (2)$$

(3) 学習データ拡張

過学習を避けて学習のロバスト性を高めるため、元の学習データにランダム変動を付加することで疑似的な学習データを作成し、データ数を拡張した。ここで、ノイズ付与率を v とし、 $1-v$ から $1+v$ の範囲を動き、一様分布に従うランダムな数値を $\text{rand } i \in [1-v, 1+v]$ とすると、ノイズ付加後のデータセットは次式で算出される。今回はデータ数を 100 倍に拡張した。

$$y_{kj} = \text{rand} \times x_{kj}, \quad \text{rand} \in [1-v, 1+v] \quad (3)$$

(4) 正則化

勾配降下法により学習が進むと、誤差関数は減少し学習データに即したモデルが構築される。しかし、そのモデルが必ずしも未学習データに即しているとは限らず、時にはフィッティング制度が悪く過学習が起きることもある。これを避けるため、誤差関数に重みの 2 乗を加えたものを学習のコスト関数として重みに対する制約をつける L2 正則化[4]を適用した。コスト関数を $J(t)$ 、誤差関数を $E(t)$ 、出力時の重みを $v(t)$ 、荷重減衰係数を λ とすると(4)式となる。この $J(t)$ が最小化されるように学習を進めた。

$$J(t) = E(t) + \lambda v(t)^2 \quad (4)$$

2.3 異常判定手法の提案

学習後の LSTM モデルにより予測された値と測定値の乖離のうち、学習に使用した 1000 ステップ分における乖離を学習誤差、学習に使用した直後の 500 ステップ分における誤差を予測誤差とし、その両方を総称して平常時誤差とした。その平常時誤差の平均二乗誤差(MSE)の最大値の 3 倍を異常判定閾値とし、MSE がこの閾値を 2 ステップ連続で超えた時刻を異常判定時刻とした。(Figure 2)




Fig.2 Abnormality Judgment Threshold and Time

2.4 解析対象データ

今回は、2006年6月15日午前8時39分に発生した中部電力浜岡原子力発電所5号機における低圧タービンB第12段羽根脱落事象を対象とした。

事象発生前の6月1日0時0分～6月15日8時30分のセンサー信号を10分おきに記録した2069ステップのうち、1～1000ステップを学習データ、1001～2069ステップを未学習データとして使用した。用いたデータは、タービン軸受振動センサーの全10基である。

3. 異常検知結果と考察

3.1 LSTMによる予測誤差

10基のタービン軸受振動センサーの測定データと改良無しの LSTM による予測データとの MSE を示したものが Figure 3 である。横軸は予測開始からのステップ数 (step/10min.)、縦軸は MSE (mm^2) を表す。緑線は MSE の最大値の 3 倍とした異常判定閾値であるが、異常が顕著となる 1,900 ステップ以降にも MSE が閾値を超えることが無い。

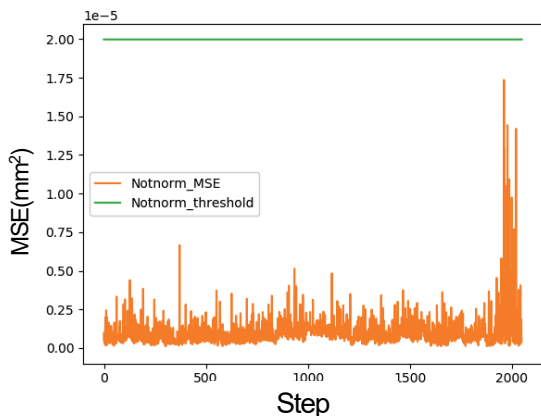


Fig.3 Mean squared error of predicted value of time-series data of turbine vibration sensors by LSTM

3.2 規格化およびノイズ除去による早期検知化

Figure 4 に、測定データを規格化し、さらに LPF によりノイズ除去をした後に LSTM に学習させた場合の予測データの MSE を示す。Figure 3 に比べて値が 2 桁小さくなっており、揺動成分も小さく抑えられていることが分かる。閾値を MSE の最大値の 3 倍に取った場合、タービン翼脱落の 84 ステップ前 (839 分前) で異常を検知することができる。

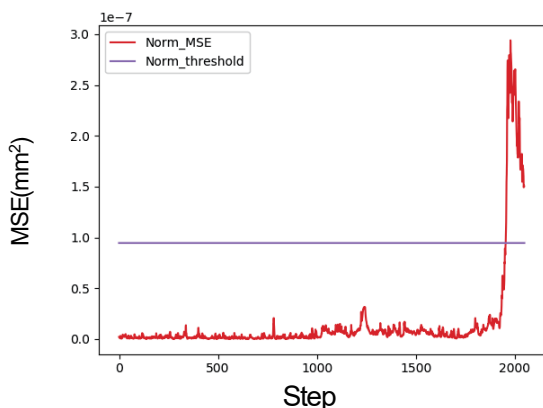


Fig.4 Mean squared error of predicted value of normalized and noise-removed time-series data of turbine vibration sensors by LSTM

3.3 データ拡張後による早期検知化

続けて、ノイズ付与による学習データの拡張を追加した場合の予測値の MSE を、3.2 節の予測値の MSE と比較した結果を Figure 5 に示す。1,000~1,900 ステップにおける揺動の最大値には変化が無いが、異常が顕著になる 1,900 ステップ以降の MSE が大きくなり、異常に対する感度が上がった様子が見られる。

さらに、MSE 最大値の 3 倍とした閾値との交差点を拡大した図を Figure 6 に示す。タービン翼脱落の 96 ステップ前 (959 分前) で異常を検知することができており、3.2 節の場合に比べて 12 ステップ (120 分) の早期検知ができた。

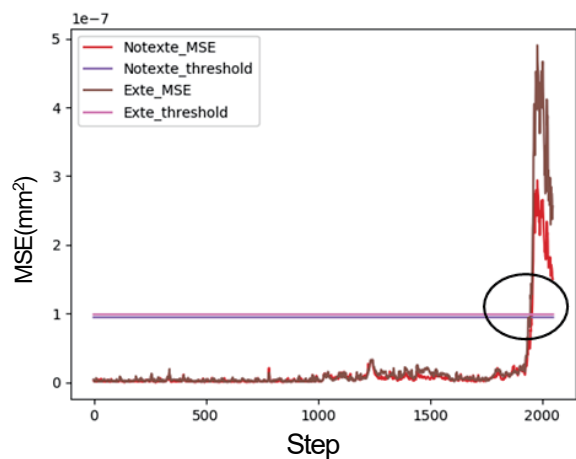


Fig.5 Mean squared error of predicted value of normalized, noise-removed and extended time-series data of turbine vibration sensors by LSTM

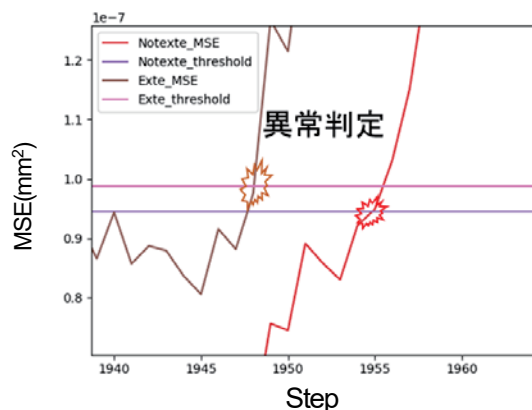


Fig.6 Enlarged view of the intersection of the threshold line with the mean squared error of predicted value of normalized, noise-removed and extended time-series data of turbine vibration sensors by LSTM

3.4 正則化による早期検知化

さらに、学習時の誤差関数に重みの 2 乗を加えたものを学習のコスト関数として重みに対する制約をつける L2 正則化を追加した場合の予測値の MSE を、3.2 節の予測

値のMSEと比較した結果をFigure.7に示す。異常が顕著になる1,900ステップ以降の異常に対する感度がさらに強くなっていることが分かる。




Fig.7 Mean squared error of predicted value of normalized, noise-removed, extended and regularized time-series data of turbine vibration sensors by LSTM

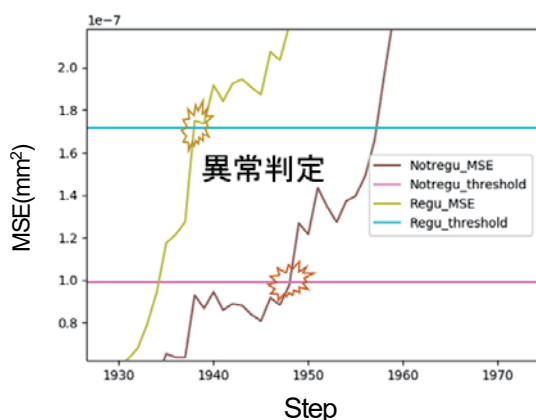


Fig.8 Enlarged view of the intersection of the threshold line with the mean squared error of predicted value of normalized, noise-removed, extended and regularized time-series data of turbine vibration sensors by LSTM

3.5 LSTMの改良による早期検知効果の比較

4つのLSTMの改良による、タービン翼脱落前の異常検知時間の比較をTable 1に示す。異常検知にLSTMを用い、さらにこれら4つの改良を行うことで、17時間以上前の段階でタービン翼脱落の検知が可能であることが示された。

Table 1 Comparison of anomaly detection time before turbine blade dropout

| | 異常検知時刻 (発生何分前) |
|-----------|---------------------|
| 規格化&ノイズ除去 | 6/14 17:40 (839分前) |
| データ拡張 | 6/14 16:40 (959分前) |
| 正則化 | 6/14 14:50 (1069分前) |

4. 結論

動的機器モニタリング信号からのLSTMによる早期異常検知手法を開発した。規格化、ノイズ除去、データ拡張、正則化の改良を行うことにより、事象発生よりも前の十分に早い時点の異常の検知が可能であることが示された。

参考文献

- [1] Hochreiter, Schmidhuber, "Long Short-Term Memory", Neural Computation, Vol.9, No.8, pp1735-1780(1997).
- [2] Zipser, Andersen, "A back-propagation programmed network that simulate response properties of a subset of posterior parietal neurons", Nature331, pp679-684,(1988)
- [3] Bengio, Simard, Fransconi, "Learning Long-Term Dependencies with Gradient Descent is Difficult", IEEE, Transactions on Neural Network, Vol.5, No.2, (1994).
- [4] Tibshirani R, "The lasso method for variable selection in the cox model", Statistics in Medicine, Vol.16, No.4, (1998).

謝辞

本研究において、タービン軸受振動センサーのモニタリングデータをご提供頂きました中部電力(株)殿に、心より感謝を申し上げます。