

ニューラルネットワークを用いた車両感知器の故障検知

2013SE173 坂本大樹

指導教員：福嶋雅夫

1 はじめに

近年の IT 技術の進歩はめざましく、その中でも人工知能 (AI) が注目されている。人工知能の発展には、深層学習 (ディープラーニング) という、多層のニューラルネットワークを用いた、機械学習の成功が背景にある [2]。ニューラルネットワークの研究は、80 年代にも盛んに行われていたが、90 年代半ばから関心が低下していった。2000 年代の Hinton らの多層ネットワークの学習に関する研究が転機になり、計算機の能力が大きく向上し、再び注目され、人工知能の発展につながった。

車両感知器とは、道路上に設置され、その下を通過する車両を感知するものであり、交通管制システムの中核のセンサーである。交通管制システムは、交通情報の収集や提供だけでなく、都市部を中心に集中する車両の流れをコントロールする交通信号制御を行っている。道路網の混雑状況を迅速かつ的確に把握し、状況に応じた適切な交通信号制御を行うためには、都市部に縦横に広がる道路網に多数の車両感知器を配置する必要がある。わが国の車両感知器総数の約 3 分の 2 を占める超音波式車両感知器は都市部を中心に 13 万基以上設置されており、それらから高精度のデータ収集を行うため、定期的に保守点検業務を行い、機能の保全を行っている。交通管制システムにおける車両感知器の故障判別については、収集したデータの内容と実際の車両走行の状況を比較評価することにより故障かどうかを判断している。しかし、超音波式車両感知器は経年劣化により、実際の車両通過状況と乖離した計測となることもあり、実際の故障判断は必ずしも容易ではない [3]。

本研究では、ニューラルネットワークを用いた超音波式車両感知器の故障判別を試みる。実際のデータを用いた計算実験により、判別可能性の検証を行う。

2 ニューラルネットワークとは

ニューラルネットワークは、人間の脳の神経細胞 (ニューロン) を結合した神経回路網をモデル化した有向グラフで表される。コンピュータに学習能力を持たせることにより様々な問題を解決する方法である。ネットワークの各節点は、処理要素であり、そこでは、他の節点の出力を入力として受け入れ、それにさらに適当な変換を行うことにより、節点の出力を決定し、同様に他の節点に伝える動作を行う。これは、ネットワークの各節点において並列分散に行われる。

3 誤差逆伝播法

ニューラルネットワークには様々な手法があるが、本研究では誤差逆伝播法を取り扱う。図 1 のような 3 層




図 1 3 層ニューラルネットワーク

のネットワークを考える。いま、識別すべき N 個のパターンベクトルを $x^s = (x_1^s, x_2^s, \dots, x_n^s)$ ($s = 1, 2, \dots, N$) とし、そのおのおのに対してネットワークが出すべき望ましい出力 d^s ($s = 1, 2, \dots, N$) が与えられたとする。ネットワークの結合係数を $v = (v_{11}, v_{12}, \dots, v_{mn})$, $w = (w_1, w_2, \dots, w_m)$ としたときの、各パターンベクトル x^s に対する第 2 層の出力を、 $y^s(v) = (y_1^s(v), y_2^s(v), \dots, y_m^s(v))$ 、それを受けて第 3 層 (節点 r) が出すネットワークの最終出力を $z^s(v, w)$ と表す。そのとき、すべての入力パターンに対してネットワークが正しい出力を出すような結合係数の値を定めること、すなわち、結合係数 (v, w) を変数とする、以下のような連立非線形方程式を解くことである。

$$\begin{cases} z^1(v, w) = d^1 \\ z^2(v, w) = d^2 \\ \vdots \\ z^N(v, w) = d^N \end{cases}$$

しかしこの方程式は、変数の数と式の数はいずれも $nm+m$ と N であるので、一般に解を持たない。そこで、入力パターン x^s に対する正しい出力と実際の出力の 2 乗誤差

$$e^s(v, w) = \frac{1}{2}(z^s(v, w) - d^s)^2 \quad (1)$$

の和を最小化する次の問題を考える。

$$\text{目的関数} : E(v, w) \equiv \sum_{s=1}^N e^s(v, w) \rightarrow \text{最小}$$

ネットワークの第 2 層の各節点 i の出力 y_i と、第 3 層の節点 r からの出力 z は 0 と 1 の間の実数と考え、各節点での出力関数としてシグモイド関数

$$G_s(x) = \frac{1}{1 + \exp(-x)}$$

を採用する。そのとき、関数 $z^s(v, w)$ は

$$y_i^s(v) = G_s\left(\sum_{j=1}^n v_{ij}x_j^s\right) \quad (2)$$

$$(i = 1, 2, \dots, m, s = 1, 2, \dots, N)$$

で定義される関数 $y_i^s(v)$ を用いて、

$$z^s(v, w) = G_s \left(\sum_{i=1}^m w_i y_i^s(v) \right) \quad (3)$$

とあらわされる。関数 e^s の各変数に関する偏微分を計算すると、変数 w_i に関する偏微分係数は、式 (1), (3) より、

$$\begin{aligned} \frac{\partial e^s(v, w)}{\partial w_i} &= (z^s(v, w) - d^s) \frac{\partial z^s(v, w)}{\partial w_i} \\ &= (z^s(v, w) - d^s) G'_s \left(\sum_{i=1}^m w_i y_i^s(v) \right) y_i^s(v) \end{aligned}$$

となる。ここで、 G'_s はシグモイド関数の導関数であり、

$$G'_s(x) = G_s(x)(1 - G_s(x))$$

で与えられる。さらに変数 v_{ij} に関する偏微分係数は、式 (1), (2), (3) より、

$$\frac{\partial e^s(v, w)}{\partial v_{ij}} = (z^s(v, w) - d^s) G'_s \left(\sum_{i=1}^m w_i y_i^s(v) \right) w_i G'_s \left(\sum_{j=1}^n v_{ij} x_j^s \right) x_j^s$$

と表すことができる。第 3 層で観測された誤差に関する情報を、入力信号の流れとは逆向きに伝達することにより、 $\partial e^s(v, w)/\partial w_i$ は第 2 層の節点 i において、 $\partial e^s(v, w)/\partial v_{ij}$ ($i = 1, 2, \dots, m$) は第 1 層の節点 j において、それぞれ計算することが可能になる。この原理に基づいて誤差関数の偏微分係数を計算することを誤差逆伝播法という [1]。

4 計算実験

4.1 車両感知器データについて

もとの車両感知器のデータは 155 次元のベクトルであり、扱いにくいいため、正常データは特徴的なデータであるとし、ひとつの正常な車両感知器情報の交通量および占有時間を平均値および標準偏差を用いて中心化と正規化を行い、分散共分散行列による固有値分解を行い、その係数行列を導出する。故障データを含めたすべてのデータに対してその係数行列によるデータ変換を実施し、次元の縮約を行っている。その結果、本実験で用いるデータでは、占有時間が 11 次元、交通量が 11 次元の計 22 次元となっている。

4.2 実験

車両感知器のデータとして、学習用データと検証用データを用いる。学習用データをニューラルネットワークに学習させ、その後、検証用データを用いて、ニューラルネットワークがどの程度学習できているかを検証する。学習用データとして、22 次元の実数ベクトルであらわされたパターンベクトルが 40 個ある。そのうち 28 個は故障データ、残りの 12 個は正常データである。検証用データも同

様に 22 次元のパターンベクトルであり、その数は 16 個である。結合係数 v, w の初期値は乱数を用いて設定する。また、故障の状態を 0、正常の状態を 1 として表す。学習には誤差逆伝播法を用いる。学習が進行するにつれ、ネットワークからの出力が、故障データと正常データのそれぞれに対して 0 または 1 に近づいていけばよい。40 個のデータを入力し学習させることを、学習回数を 1 回とカウントする。1 回学習をし、それぞれの望ましい出力の数値に近づいていれば学習を終了し、いなければ学習を繰り返す。

300 回の学習を行った後、 $x < 0.2$ の値をとる出力 x を 0、それ以外の値のときを 1 とみなし、学習データ内で検証を行うと、表 1 に示すように 97.5 % という高い正答率が得られた。つぎに、この学習後のネットワークを使用し、検証用データに対して検証を行う。検証結果を表 2 に示す。16 個のデータに対して 93.75 % という高い正答率を得た。

表 1 学習結果

データ	正答数/データ数
故障データ	27/28
正常データ	12/12
正答率	97.5 %

表 2 検証結果

データ	正答数/データ数
故障データ	5/6
正常データ	10/10
正答率	93.75 %

5 おわりに

車両感知器のデータに対して、ニューラルネットワークにより、正答率 93.75 % という結果が得られた。また、それぞれの状態で分けて見ると、正常データでは正答率 100 %、故障データでは正答率 83 % という良好な結果が得られた。この結果により、ニューラルネットワークによる故障検知は有効であることが確認できた。様々なデータに対して数値実験を行い、故障検知の精度をさらに高めることが今後の課題である。

参考文献

- [1] 茨木俊秀, 福島雅夫, 『最適化の手法』, 共立出版, 1994
- [2] 岡谷貴之, 『深層学習』 講談社, 2015
- [3] 岩岡 浩一郎, 弘津雄三, 『集約車両感知器情報による故障検出手法の検討』, 電気学会論文誌 D, 第 137 巻, 第 4 号, 2017 (掲載予定)