

平成 22 年度 卒業論文

ニューラルネットワークによる学生の成績予測と  
その学習指導への適用可能性の検討

指導教員

舟橋 健司 准教授

伊藤 宏隆 助教

名古屋工業大学 工学部 情報工学科

平成 19 年度入学 19115012 番

伊藤 暁人

# 目次

第1章	はじめに	1
第2章	本研究で用いる手法の理論	3
2.1	ニューラルネットワーク	3
2.1.1	概要	3
2.1.2	ニューラルネットワークの学習方法	4
2.1.3	成績予測におけるニューラルネットワークの利点	6
2.2	クラスタリング	7
2.2.1	K-means 法	7
第3章	ニューラルネットワークを用いた成績予測	9
3.1	学習に用いる学生データ	9
3.2	学習方法の検討	10
3.2.1	出力方法	11
3.2.2	入力方法	11
3.3	評価実験 (1)	13
3.3.1	leave one out 法による的中率の評価	13
3.3.2	結果及び考察	13
3.4	評価実験 (2)	25
3.4.1	落第候補者が検出可能である最低講義回数の検証	25
3.4.2	結果及び考察	26
第4章	学習指導への適用可能性の検討	30
4.1	ニューラルネットワークから得られる情報	30
4.2	成長可能性の把握	30
4.3	学習指導への適用検討	33
第5章	むすび	40
	謝辞	41
	参考文献	42

## 第1章 はじめに

名古屋工業大学では、双方向型教育支援システムの構築を目的として、2007年4月にICカード出欠管理システムとコースマネージメントシステム(以下CMS)が本格的に導入された[1].

ICカード出席管理システムは本学において考案されたシステムである。学生証はICカード化されており、出席の際、講義室の出入口に設置されているICカードリーダーにICカードを接触させることによって出席情報を蓄積する。

CMSは、情報技術やインターネットを使ったe-Learningを支援するシステムである。本学ではCMSとしてMoodleが採用されており、教材の作成支援、課題の提出管理、小テストの実施、学生を受講管理を行う機能を持っている。この出欠管理システムによって得られた出欠データとCMSで管理されている課題や小テストなどの学習データを統合することで総合的な成績評価が可能となっている。

現在までの学生に対する学習指導の問題点として、学生毎の理解度や学習意欲の把握が困難であることが挙げられる。理解度や意欲の高い学生に相応の学習機会を与えることが難しく、また、理解度の低い学生が発見されるのは学期末の成績算出時であって手遅れとなっていた。そして、将来の成長可能性、落第可能性は知られることがなかったため、学生に本当に必要な指導ができていなかった。

そのような問題に対し、出欠管理システム及びCMSに蓄積されているデータを成績評価のための材料として扱うのではなく、学生の理解度の把握や、学習意欲の向上のための指導にも有効に活用することが提案されている。例えば、過去のデータの傾向を分析することにより学生の成長可能性の把握や成績予測が可能であること、更に落第候補者を早期に発見し教育指導を行うことで、落第者を減少させることが可能であることが挙げられる。過去の関連研究[2][3]においても学生の出欠状況、課題提出状況が学生の成績に影響を与えることが証明されており、またそれらを用いて成績予測が可能であることも証明されている。

しかしながら、過去の実験においては実験者だけが学生毎の理解度や成長可能性、成績予測の結果を把握しており、それらの情報は学生には伝えられていなかった。だが、それらの情報を学生に提供することで、学生自身が現在置かれている状況を把握し学習意欲の向上や、学習に対する姿勢の改善が期待できる。そこで、学生にそれらを効果的に伝えるには、CMSを用いてWeb上で学生が情報を確認することが可能である環境を作ることが有効であると考えられる。過去の実験[3]においてはデータマイニングツールを用いることでデータの分析や成績予測を行ってきた。しかし、データマイニングツールをWeb上に実装するのは困難である。

そこで本研究では、Webで実装可能な成績予測の手法としてニューラルネットワークを適用することを提案する。ニューラルネットワークは、予測、分類、クラスタリングに適応可能

な強力で汎用性の高い分析手法である。人間の脳における神経結合をコンピュータ上でモデル化し、人間が経験から学んでいくようにデータから学習し、その結果を一般化する。本研究ではそのニューラルネットワークの特徴を活かし、過去の学生の学習データと成績のパターンを学習させ、成績未知の学生データを用いて成績予測を行った。成績予測の結果を基に学習指導を行うにあたって、成績予測の結果が信頼できないものであっては学生に合った適切な指導を行うことができない。したがって、ニューラルネットワークによる成績予測の結果がある程度信頼のあるものでなければならない。それに先立ち、与えられた学生のデータをどのようにしてニューラルネットワークに入力すると学習誤差が小さくなるか、高い的中率が得られるかを2つの入力方法と比較して検証した。そして、得られた入力方法によって学習が行われたネットワークの精度を確認するため、ある講義を受講していた2008年、2009年度の学生102人の学生データを用いて評価実験を以下の項目で行った。

- (1) leave one out 法を用いた的中率の評価
- (2) 落第候補者を認識可能な講義回数の検証

評価実験(1)では、予測された成績と実際の成績を比較したところ、確実に学生の成績を的中させることは困難であるが、1ランクの誤差、2ランクの誤差を含めると的中率が上がることから、おおまかな成績予測が可能であることが示された。評価実験(2)では、講義2回目からその時点で得られる学生データを用いて成績予測を行い、単位を取得できなかった学生を何回目の講義から、高い精度で認識できるかを確認した。その結果、授業中盤以前の早い段階で単位を取得できなかった学生を発見することが可能であることが示され、学習したネットワークが落第候補者の早期発見に有効であることが確認できた。以上のことから、ニューラルネットワークでの成績予測がある程度可能なことが証明できた。

その結果を踏まえた上で、ニューラルネットワークから得られた成績予測の結果を基に学習指導が行えるかを検討した。しかし、成績予測結果から得られる情報は予測された学生の成績のみで、その成績が学生の学習状況が改善されて与えられたものなのか、悪くなってきて与えられたものなのかを判断することができず、予測成績をそのまま用いて学習指導を行うことは困難であった。そこで、学生の授業中盤までの予測成績の推移をクラスタリングすることで学生の学習状況が把握可能であるかを確認し、そのクラスタリング結果を基に学習指導が行えるかを検討したところ、クラスタに属する学生の授業中盤以降の出席、課題の提出、課題の評価の傾向を分析することで簡単な学習指導が行えることがわかった。

本論文では、第2章において本研究で用いる手法の理論を述べ、第3章においてニューラルネットワークによる成績予測の有効性を示す。また、第4章においてニューラルネットワークから得られた結果を基に学習指導が可能であるか検討した結果を述べる。第5章にて本研究の結論と今後の課題を述べる。

尚、本研究に用いる学習データには学生の個人情報などプライバシーを侵害するような情報は一切含まれていないものを用いるものとする。

## 第2章 本研究で用いる手法の理論

本研究では成績予測の手段としてニューラルネットワークを提案している。そこで本章では、ニューラルネットワークの概要及び学習アルゴリズムについて述べる。また、成績予測の結果の学習指導への適用可能性を検討するにあたり、ニューラルネットワークから得られた予測結果の傾向を把握する必要があるため、クラスタリングを行う。本研究で用いたクラスタリング手法についての概要も後述する。

### 2.1 ニューラルネットワーク

#### 2.1.1 概要

ニューラルネットワーク [4] は人間の脳をコンピュータ上でモデル化したもので、人間が経験によって脳を学習させていくように、ニューラルネットワークはデータから学習を行う。

その特性を活かしニューラルネットワークは、データマイニングや意志決定の分野において広く利用されている。例として、金融分野における時系列予測、医療診断、価値ある顧客層の特定、クレジットカードの不正利用者の発見、小切手に書かれた数字の識別、エンジンの故障が起こり得る確率の予測など、幅広い産業分野が挙げられる。

ニューラルネットワークを学習させることによってこのような分類や予測を行う際には、一般的に以下の手順で用いられる。

1. 入力と出力の項目を決める。

ニューラルネットワークにより得たい出力に対し、出力に対し影響を及ぼす項目を入力にすることが好ましい。

2. 入力データと出力データを  $-1$  から  $1$  までの範囲に変換する。

ある1つの入力データが他のデータに対しても大きな値であるとき、計算結果に対し支配的になってしまう。それを防ぐため、上記の範囲にデータを変換する。

3. ニューラルネットワークを適切な位相に設定する。

図 2.1 のような入力層、中間層、出力層の階層型ネットワークが一般的である。中間層のユニット数を増やすことにより強力な学習が可能となるが、過学習の危険がある。

4. 学習データでニューラルネットワークを学習させる。

- 教師信号を使い、誤差を最小にする重みデータを選ぶ。  
要求された予測をするための最適な重みの組合せに到達するまで、内部の重みを調整する。
- テスト用データを用いて、ニューラルネットワークの働きを評価する。
- 完成したニューラルネットワークを、未知の入力に対する結果を予測することに適用する。

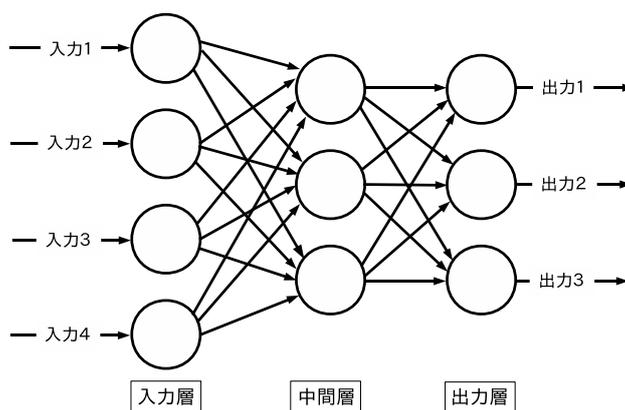


図 2.1: 階層型ネットワーク

完成したニューラルネットワークは、学習データに対してのみ適したモデルとなっている。そのため、最新のモデルとして使用し続けるには、必要に応じて学習データを追加しニューラルネットワークを再学習させる必要がある。

### 2.1.2 ニューラルネットワークの学習方法

ニューラルネットワークの学習とは、求めたい出力値を得るために、連結されたネットワークのユニットに対する重みを最適に設定していくプロセスである。その学習のプロセスの1つであるバックプロパゲーションは次の3つの手順に分けることができる。

- ネットワークに学習データを入力し、既存の重みを使って出力値を計算する。
- 出力値と教師信号との差から誤差を算出する。
- ネットワークを通じて誤差をフィードバックし、誤差が最小になるように重みを調整する。

ネットワークの初期の重みはユニット間の枝に対しそれぞれ乱数で与えられる。その重みを用いて出力値を計算する。入力  $a_k$ , ユニット  $j$  の出力値  $O_{pj}$  は, そのユニットに伸びる枝に与えられた重みを  $w_{kj}$  とすると, 次式で与えられる。

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (2.1)$$

$$O_j = f(-\sum w_{kj} a_k) \quad (2.2)$$

式 (2.1) はシグモイド関数 (sigmoid function) を表す。図 2.2 はユニット  $j$  における出力の様子を表している。

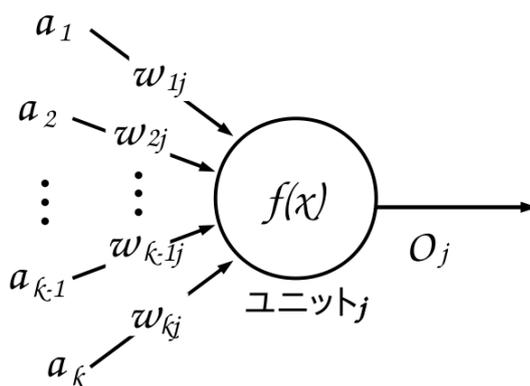


図 2.2: ユニット  $j$  における出力の様子

下位の層から上位の層のユニットへの入力と, そのユニットに伸びる枝に与えられた重みの積の和を, シグモイド関数に与えることで出力を得る。ただし, ユニット  $j$  が入力ユニットである場合には  $O_j$  は入力値となる。

また, 出力ユニット  $j$  の教師信号 (目標出力) を  $t_j, O_j$  を用いて, 二乗誤差  $E$  は次式で与えられる。

$$E = \frac{1}{2} \sum_j (t_j - O_j)^2 \quad (2.3)$$

この二乗誤差を減らすよう重みを調整する。3層の階層型ニューラルネットワークでは, 中間ユニット  $i$  から出力ユニット  $j$  への枝の重み  $w_{ji}(n+1)$  は次式で与えられる。

$$w_{ji}(n+1) = \eta \delta_j O_i \quad (2.4)$$

ただし,  $\eta$  は学習係数を表す。また,  $\delta_j$  は出力ユニット  $j$  の誤差信号である。

$$\delta_j = (t_j - O_j) O_j (1 - O_j) \quad (2.5)$$

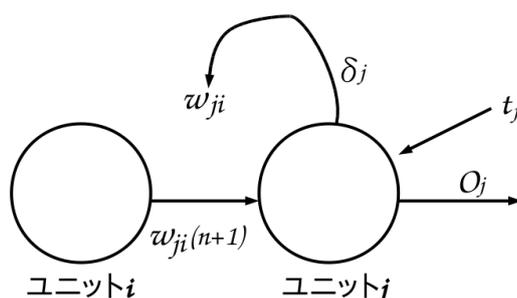


図 2.3: ユニット i における重みの更新の様子

図 2.3 は中間ユニット  $i$  の重みの更新の様子を表している。

更に全体の誤差をより減らすために入力層の重みを調整する。入力ユニット  $j$ , 中間ユニット  $i$  とし, 中間層から出力層への重みの更新と同様に, 式 (2.4) を用いる。ただし,  $\delta$  を次式のようにする。

$$\delta_j = O_j(1 - O_j)\sum \delta_k w_{kj} \quad (2.6)$$

ここで,  $\delta_k$  は中間ユニット  $j$  の出力ユニット  $k$  からの誤差信号,  $w_{kj}$  は中間ユニット  $j$  から出力ユニット  $k$  の枝に付加された重みである。

出力ユニットから得られた出力値と, そのパターンに応じた教師信号から誤差信号を求め, 元の重みと学習信号との積を求めることで新たな重みを算出する。

これらの操作を学習データの各パターン, 各ユニットに対して繰り返し行うことで, 徐々に重みを最適値に近づかせていく。

指定学習回数, もしくは平均二乗誤差  $\frac{E_p}{n(p)}$  が指定した値よりも小さくなるまで繰り返すことでネットワークに学習データのパターンを認識させる。ただし,  $p$  は入力パターンとする。

### 2.1.3 成績予測におけるニューラルネットワークの利点

本研究では成績予測のツールとしてニューラルネットワークを用いることを提案している。その利点は以下の通りである。

- Web 上での実装が可能
- パターン学習に優れている

学生に成績予測の結果を提示, それを基に学習指導を行うにあたって, Web アプリケーションとしての実装が望まれる。Web 上で実装することにより, 学生への公開が容易になる。また, 学生がいつでもどこでも自分の学習状況を把握することができる。こういった要素が学生への学習指導の実施のしやすさや, 学生の学習意欲の向上につながると期待することができる。

ニューラルネットワークは様々なソフトウェアに組み込まれて使用されている。ニューラルネットワークを用いた広告配信システム [5], 楽曲レコメンドシステム [6] は Web 上で利用されている。ニューラルネットワークの学習シミュレーションが可能な Web サイトも存在する。このことから、成績予測のツールとしてニューラルネットワークを利用することが可能であることがわかる。

また、ネットワークの学習は学生データが新たに得られた時 (全講義終了及び成績評価後) にのみ行えば良いので完成したネットワークから得られた重みデータだけで成績予測が行える。それゆえ複雑な計算も必要がないので、安定した Web 上での稼働が期待できる。

一般的に、大学の講義は教員ごとに成績評価の基準が異なっている。出席を重視する教員もいれば、課題の提出を重視する教員もいる。試験の結果のみを見て、普通の講義への取り組みは評価に考慮しない教員もいるだろう。そういった評価基準により成績が変動する場合がある。しかし、ニューラルネットワークの学習においては評価基準に応じて学習データに手を加える必要はない。評価基準による成績の変動をパターンとして認識するためである。すなわち、成績予測を行う講義が出席重視であったとしても、学習データに出席を重視した結果の成績が与えられており、ニューラルネットワークはそれをパターンとして学習するため、評価基準を考慮し、学習データに重みづけをする必要はないということである。

ただし、成績に影響しないような学習データの要素は学習の負担を軽減するため入力要素から外すべきである。

## 2.2 クラスタリング

クラスタリングアルゴリズムは、トップダウン型とボトムアップ型の2つに分類することができる。トップダウン型は、1つのデータの集合を2つに分割し、分割されたデータの集合をさらに2つに分割する。それを再帰的に繰り返すことでデータをクラスタ化する。それに対しボトムアップ型は、最初データ1つ1つをクラスタとし、類似度の高いクラスタ同士を1つのクラスタに併合していく。そして、クラスタ数が既定数になるまでその操作を繰り返すことでクラスタリングを行う。本研究ではクラスタリング手法として K-means 法 [7][8] を採用した。

### 2.2.1 K-means 法

K-means 法はボトムアップ型の代表的な手法である。実装が容易なこと、アルゴリズムがシンプルなことから広く用いられている。

K-means 法は次の手順で行われる。

1. 初期値としてクラスタ数  $k$  を与え、 $k$  個のシード  $p^i (i = 1, 2, \dots, k)$  を生成する。
2. 各データ  $x^j (j = 1, 2, \dots, n)$  に対し、最も近いシード  $p^i$  を求める、データ  $x^j$  をクラスタ  $C_i$  に入れる。
3. 各クラスタ  $C_i$  の重心を求め、その重心を新たなシード  $p^i$  とする。

4. 上記手順においてシード  $p^i$  が移動していた場合, 手順2へ戻る. 移動していなかった場合, クラスタリングを終了する.

K-means 法では最終的なクラスタ数を自分で与える必要があるため, 手順1でクラスタ数を決定する. また, 手順1において生成するシード点はランダムな値とする. 手順2におけるデータ  $x^j$  とシード  $p^i$  の距離  $d(x^j, p^i)$  はユークリッド距離 (式 2.7) によって与えられる.

$$d(x^j, p^i) = \sqrt{(x_1 - p_1)^2 + (x_2 - p_2)^2 + \cdots + (x_l - p_l)^2} \quad (2.7)$$

ただし,  $x^j = (x_1, x_2, \dots, x_l)$ ,  $p^i = (p_1, p_2, \dots, p_l)$  である. 手順3によりシードが更新された場合, あるデータの最も近いシードが移動することがある. その移動によって, 手順2の操作でそのデータの所属するクラスタが更新される. この更新を繰り返されると, やがてシードが移動しなくなり, それに伴いデータの更新もなくなる. その時点の結果をクラスタリング結果とする. しかし, K-means 法によって得られたクラスタリング結果は局所最適解であり, ランダムに生成したシードの初期値によりその結果が異なる場合があることに注意しなければならない.

## 第3章 ニューラルネットワークを用いた成績予測

ニューラルネットワークに過去の学生データを学習させることにより、成績未知の学生の成績を予測する。それにより落第候補者を早期に発見したり、成績に応じた修学指導が可能となることが期待できる。そのためには成績予測の結果がある程度妥当である必要がある。

そこで本章において、ニューラルネットワークを用いて成績予測が可能か評価実験を行った結果について述べる。

### 3.1 学習に用いる学生データ

ニューラルネットワークには正しいパターンを認識させなければならない。そこで、成績予測に用いるデータは、成績の評価基準が年ごとに差異のない、同一教員の同一講義のものを使用する。以下がその学生データである。

2008年度: 人数 64人 (成績 S:18人, A:16人, B:13人, C:9人, D:0人, X:8人)  
2009年度: 人数 38人 (成績 S:19人, A:9人, B:2人, C:5人, D:0人, X:3人)

成績は6段階で与えられており、最優良成績をSとし、以下A,B,C,D,Xの順で与えられている。この中でDは低成績による不合格、Xは講義の放棄による失格を表している。単位取得成績はS,A,B,Cで、D,Xは単位取得不可成績である。講義は講義回数15回、課題出題回数10回(講義2,4,5,6,7,9,10,11回終了後に加え、最終課題2題)で、それぞれの講義回に対する出欠席、課題出題回に対する課題の提出状況(提出・未提出)のデータが与えられている。

講義の出席データに関して、講義に出席した場合には1、欠席した場合には0の2値が設定されている。

課題の提出データに関しては、課題を提出期限内に提出した場合には1、未提出である場合には0の2値が与えられている。

それに加え課題提出値が与えられている。課題提出値とは課題提出の早さを表し、課題提出受付開始時を1とし、課題提出締め切り時を0としている。つまり、課題の提出が早ければ早いほど提出値は高くなる。ただし、未提出の場合には-1とした。一般的に、この提出値が高いほど、成績が良くなる傾向があるということが過去の実験の結果[3]によって証明されている。そのため今回予測の一つの指標としてこの値を用いることが有効であると考えられる。

### 3.2 学習方法の検討

図 3.1 に本研究で用いるニューラルネットワークの概要を示す。

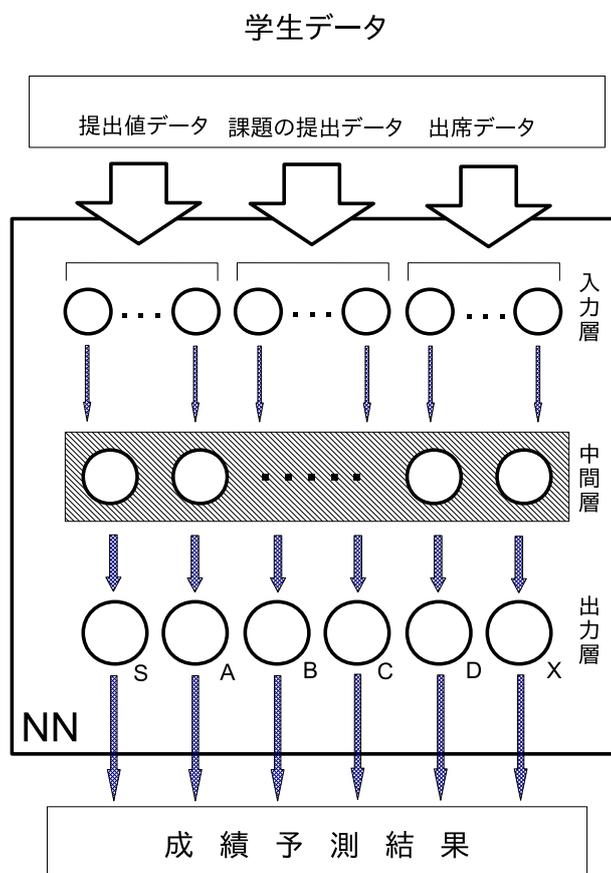


図 3.1: ニューラルネットワーク概要

### 3.2.1 出力方法

教師信号は学生の成績データを用いる。6段階で与えられている成績データを6つの出力ユニットに割り振る。教師信号に対応した出力ユニットの値を1とし、その他の出力ユニットの値を0とすることでニューラルネットワークを学習させる。

学習したニューラルネットワークに入力を与えると、6つの出力ユニットが入力に応じて発火する。これが成績予測結果である。図3.2に成績予測結果の出力例を示す。

```
4(成績:B)
B:0.9999929991983151
X:0.05349541053367842
A:0.028107364809262205
D:2.586187662762269E-4
C:6.585381220206958E-7
S:1.9484783622451263E-10
```

図 3.2: 成績予測結果の出力例

出力ユニットの値が1に近いほど出力ユニットに対応した成績になることが期待でき、値が0に近いほど対応した成績になることは期待できないということを表している。

### 3.2.2 入力方法

入力信号として、学生データの出席データ、課題の提出データ、提出値の3種類を用いる。これらを用いて入力するにあたり、以下の2つの入力方法が考えられる。

- (1) 出席データ、課題の提出データ、提出値をそれぞれ合計し、正規化して入力。(3入力)
- (2) 出席データ、課題の提出データ、提出値1つ1つに入力ユニットを割り当て入力。(講義回数 + 課題出題数×2入力)

(1)の入力方法は、予測タイミングにおいて得られる出席データの合計、課題の提出データの合計、提出値の合計をそれぞれ入力ユニットに入力する。入力ユニットの数が講義回数に因らず3個で固定されているので学習速度に優れている。

(2)の入力方法は予測タイミングにおいて得られる学生データを1つずつ入力ユニットに割り当てて入力する。例えば講義10回目の時点で成績予測を行う場合、得られる学生データは出席データ10個、課題の提出データが7個、提出値データが7個で、これらをそれぞれに入力ユニットを割り当てるので計24個の入力ユニットが必要となる。学習速度は(1)に劣るが、各講義ごとの学生データをネットワークに学習させているので学生データを一括して学習させている(1)に比べ、学生の連続出席などのパターンを詳細に学習することができる点で優れている。

これら2つの入力方法による学習誤差, 的中率を比較し, 精度の高い方法を実験に用いる. なお,(1)の入力方法では学習データの正規化を行い, 入力信号  $INPUT$  は式 (3.1) で与えられるものとする.

$$INPUT = (DATA - minDATA)/(maxDATA - minDATA) \quad (3.1)$$

ただし,  $DATA$  は各学習データ,  $minDATA$  は学習データにおける最小値,  $maxDATA$  は最大値である. 学習データの出席データにおける最大値は 15, 最小値は 0, 課題の提出データにおける最大値は 10, 最小値は 0, 提出値における最大値は 10, 最小値は -10 である.

また,(2)においては学習データは  $\{0, 1\}$  もしくは  $-1$  及び  $[0, 1]$  で与えられているので正規化は行わないものとする.

そして, それぞれの入力方法に対し学習は授業中盤 (講義 8 回迄), 授業終盤 (講義 11 回迄), 授業終了後 (講義 15 回迄) のタイミングで 20000 回行い, 学習係数  $\eta$  は 0.1 とした. それぞれのネットワークの構造は表 3.1 の通りである.

表 3.1: 入力方法比較におけるネットワークの構造

	入力ユニット (出席-課題提出-提出値)	中間ユニット	出力ユニット
方法 (1)	3(1-1-1)	10	6
方法 (2)* 中盤	18(8-5-5)	40	6
方法 (2)* 終盤	27(11-8-8)	60	6
方法 (2)* 終了後	35(15-10-10)	70	6

このような条件の下, ネットワークの学習を行ったところ表 3.2 のような結果になった.

表 3.2: 入力方法 (1) と入力方法 (2) における誤差と的中率

	授業中盤		授業終盤		授業終了後	
	的中率 (%)	誤差	的中率 (%)	誤差	的中率 (%)	誤差
方法 (1)	66.6	0.2513	65.6	0.2366	62.7	0.2341
方法 (2)	88.2	0.0796	91.1	0.0662	91.1	0.0441

2つの方法を比較してみると,(2)の入力方法がより誤差も収束しており, 的中率も高いことが確認でき, 成績予測において有効な入力方法と言える. また, 学生データを1つずつ入力ユニットに割り当てる(2)の方法を用いることでの中率が上がったことから, 学生の学習パターンが最終成績に影響していることが考えられる.

なお, 学習データの中には, 出席, 課題の提出, 提出値のパターンがほぼ同様であるが, その後の授業への出欠や, 提出課題の評価及び授業の終盤に出題する最終課題の評価によって, 最

終成績が別々になってしまっている学生が存在する。これらはネットワークの学習に入力として用いることができないため、厳密な成績予測を行うことができない。その点を考慮すると表 3.2 の結果が、本実験で用いる学生データによる成績予測の的中率の最大値であると考えられる。

### 3.3 評価実験 (1)

#### 3.3.1 leave one out 法による的中率の評価

成績予測は授業中盤 (講義 8 回迄), 授業終盤 (講義 11 回迄), 授業終了後 (講義 15 回迄) の 3 つのタイミングにおいて行った。本実験において成績予測結果の評価方法として leave one out 法を採用した。

leave one out 法は以下の手順によって行われる。

1. 学習データから 1 つデータを取り除く。
2. 取り除いたデータを除く学習データを用いてニューラルネットワークを学習させる。
3. 学習したニューラルネットワークに取り除いた学習データを入力し、結果を評価する。
4. 1~3 の手順を全ての学習データに対し繰り返し行う。

本実験ではこの手法を学習データ 102 人分に対して 20000 回学習を行い、成績に対応した出力ユニットで 1 番大きく発火しているものと実際の成績 (実成績) とを比較して評価を行う。

学習させるニューラルネットワークの入力層, 中間層, 出力層のユニットの個数は予測タイミングによって変更する。

授業中盤 入力 (出席-課題提出-提出値):18 個 (8-5-5) 中間:40 個 出力:6 個

授業終盤 入力 (出席-課題提出-提出値):27 個 (11-8-8) 中間:60 個 出力:6 個

授業終了後 入力 (出席-課題提出-提出値):35 個 (15-10-10) 中間:70 個 出力:6 個

それぞれのネットワークの学習係数  $\eta$  は 0.1 とした。

#### 3.3.2 結果及び考察

表 3.3 に授業中盤における学生のデータを学習させて得られた予測結果, 表 3.4 に授業終盤における予測結果, 表 3.5 に授業終了後における予測結果を示す。

各表の項目は以下の事項を表している。

番号 leave one out 法により取り除かれた学生の番号。

実成績 取り除かれた学生の実際の成績。

予測成績 取り除かれた学生に対して予測された成績.

誤差 その学習における最終誤差.

的中率 (%) 学習されたネットワークに番号以外の学生のデータを入力した際の予測的中率.

S,A,B,C,X (%) 成績ごとの的中率.

表 3.3: 授業中盤における評価実験結果

番号	実成績	予測成績	誤差	的中率	S	A	B	C	X
1	C	C	0.0771	90.1	97.3	84.0	80.0	84.6	100.0
2	C	C	0.0829	88.1	97.3	80.0	80.0	76.9	100.0
3	C	C	0.0832	88.1	97.3	84.0	80.0	69.2	100.0
4	B	B	0.0781	89.1	94.6	84.0	85.7	78.6	100.0
5	B	B	0.0752	89.1	97.3	84.0	78.6	78.6	100.0
6	C	A	0.0788	90.1	97.3	84.0	86.7	76.9	100.0
7	B	B	0.0871	88.1	97.3	84.0	78.6	71.4	100.0
8	A	B	0.0797	89.1	97.3	79.2	86.7	78.6	100.0
9	A	A	0.0786	89.1	94.6	83.3	86.7	78.6	100.0
10	A	C	0.0830	88.1	94.6	79.2	86.7	78.6	100.0
11	A	S	0.0819	88.1	97.3	83.3	80.0	71.4	100.0
12	B	S	0.0718	91.1	97.3	84.0	92.9	78.6	100.0
13	X	X	0.0847	89.1	97.3	84.0	86.7	71.4	100.0
14	B	B	0.0880	87.1	97.3	84.0	64.3	78.6	100.0
15	X	X	0.0769	91.1	94.6	88.0	93.3	78.6	100.0
16	S	S	0.0767	90.1	94.4	84.0	86.7	85.7	100.0
17	B	C	0.0706	91.1	97.3	84.0	85.7	85.7	100.0
18	A	S	0.0769	89.1	97.3	83.3	80.0	78.6	100.0
19	A	S	0.0728	91.1	100.0	83.3	86.7	78.6	100.0
20	S	S	0.0892	86.1	97.2	84.0	66.7	71.4	100.0
21	B	S	0.0791	89.1	97.3	84.0	78.6	78.6	100.0
22	S	B	0.0816	89.1	97.2	80.0	93.3	71.4	100.0
23	A	C	0.0786	89.1	97.3	83.3	86.7	71.4	100.0
24	A	A	0.0808	90.1	97.3	83.3	86.7	78.6	100.0
25	A	S	0.0686	91.1	97.3	83.3	86.7	85.7	100.0
26	A	S	0.0756	89.1	97.3	87.5	80.0	71.4	100.0
27	B	B	0.0760	90.1	97.3	84.0	85.7	78.6	100.0
28	C	C	0.0804	89.1	97.3	84.0	80.0	76.9	100.0
29	X	X	0.0773	89.1	97.3	84.0	80.0	78.6	100.0
30	C	S	0.0774	89.1	97.3	84.0	80.0	76.9	100.0
31	A	C	0.0826	88.1	97.3	83.3	80.0	71.4	100.0

32	X	X	0.0813	88.1	97.3	80.0	80.0	78.6	100.0
33	B	S	0.0612	92.1	97.3	84.0	92.9	85.7	100.0
34	A	A	0.0832	88.1	97.3	83.3	80.0	71.4	100.0
35	C	A	0.0739	89.1	97.3	84.0	80.0	76.9	100.0
36	S	S	0.0789	89.1	97.2	80.0	86.7	78.6	100.0
37	S	A	0.0882	88.1	97.2	80.0	80.0	78.6	100.0
38	B	S	0.0829	89.1	97.3	84.0	85.7	71.4	100.0
39	X	X	0.0759	90.1	97.3	84.0	80.0	85.7	100.0
40	A	S	0.0768	90.1	97.3	83.3	86.7	78.6	100.0
41	X	X	0.0759	90.1	97.3	84.0	86.7	78.6	100.0
42	X	X	0.0831	88.1	100.0	76.0	80.0	78.6	100.0
43	B	S	0.0742	90.1	97.3	84.0	85.7	78.6	100.0
44	S	B	0.0725	90.1	94.4	84.0	93.3	78.6	100.0
45	B	S	0.0747	90.1	97.3	84.0	85.7	78.6	100.0
46	A	C	0.0762	90.1	97.3	83.3	86.7	78.6	100.0
47	S	S	0.0822	89.1	97.2	80.0	86.7	78.6	100.0
48	B	A	0.0831	89.1	97.3	84.0	85.7	71.4	100.0
49	S	S	0.0724	90.1	97.2	84.0	86.7	78.6	100.0
50	S	S	0.0738	91.1	97.2	84.0	86.7	85.7	100.0
51	S	B	0.0812	89.1	97.2	84.0	80.0	78.6	100.0
52	S	S	0.0832	88.1	97.2	84.0	73.3	78.6	100.0
53	S	S	0.0866	87.1	97.2	80.0	80.0	71.4	100.0
54	S	S	0.0710	91.1	97.2	84.0	86.7	85.7	100.0
55	C	S	0.0754	89.1	97.3	84.0	80.0	76.9	100.0
56	S	S	0.0889	87.1	97.2	80.0	80.0	71.4	100.0
57	A	S	0.0784	89.1	97.3	83.3	80.0	78.6	100.0
58	S	S	0.0784	89.1	94.4	84.0	86.7	78.6	100.0
59	S	A	0.0708	91.1	100.0	84.0	80.0	85.7	100.0
60	A	A	0.0800	89.1	97.3	79.2	80.0	85.7	100.0
61	X	X	0.0890	87.1	97.3	80.0	80.0	71.4	100.0
62	C	S	0.0799	89.1	97.3	84.0	80.0	76.9	100.0
63	S	S	0.0803	89.1	97.2	84.0	80.0	78.6	100.0
64	S	B	0.0813	89.1	97.2	84.0	86.7	71.4	100.0
65	S	S	0.0795	89.1	97.2	84.0	80.0	78.6	100.0
66	X	X	0.0811	89.1	97.3	84.0	80.0	78.6	100.0
67	S	A	0.0702	91.1	97.2	88.0	80.0	85.7	100.0
68	C	C	0.0855	88.1	97.3	84.0	80.0	69.2	100.0
69	C	A	0.0730	90.1	97.3	84.0	86.7	76.9	100.0
70	C	A	0.0733	90.1	97.3	84.0	80.0	84.6	100.0
71	S	S	0.0803	88.1	97.2	84.0	73.3	78.6	100.0

72	A	A	0.0864	87.1	97.3	79.2	80.0	71.4	100.0
73	A	A	0.0733	90.1	97.3	83.3	80.0	85.7	100.0
74	X	X	0.0827	88.1	97.3	80.0	80.0	78.6	100.0
75	C	C	0.0884	87.1	97.3	84.0	66.7	76.9	100.0
76	B	S	0.0884	87.1	97.3	80.0	78.6	71.4	100.0
77	A	A	0.0900	88.1	97.3	79.2	86.7	71.4	100.0
78	S	B	0.0752	91.1	97.2	84.0	86.7	85.7	100.0
79	A	A	0.0851	88.1	97.3	83.3	80.0	71.4	100.0
80	X	A	0.0755	90.1	97.3	84.0	80.0	85.7	100.0
81	A	A	0.0780	89.1	97.3	79.2	80.0	85.7	100.0
82	S	S	0.0780	89.1	97.2	84.0	86.7	71.4	100.0
83	S	S	0.0768	90.1	97.2	84.0	80.0	85.7	100.0
84	S	S	0.0808	88.1	97.2	84.0	73.3	78.6	100.0
85	S	A	0.0749	90.1	97.2	84.0	86.7	78.6	100.0
86	S	S	0.0710	90.1	97.2	84.0	80.0	85.7	100.0
87	S	A	0.0794	90.1	97.2	84.0	86.7	78.6	100.0
88	S	S	0.0813	90.1	97.2	84.0	86.7	78.6	100.0
89	S	S	0.0746	90.1	97.2	84.0	86.7	78.6	100.0
90	A	B	0.0638	92.1	97.3	87.5	86.7	85.7	100.0
91	S	S	0.0772	90.1	94.4	84.0	86.7	85.7	100.0
92	S	B	0.0737	90.1	97.2	80.0	86.7	85.7	100.0
93	A	S	0.0830	88.1	97.3	83.3	80.0	71.4	100.0
94	S	B	0.0743	90.1	97.2	84.0	86.7	78.6	100.0
95	S	S	0.0892	88.1	97.2	80.0	80.0	78.6	100.0
96	S	S	0.0907	88.1	97.2	80.0	86.7	71.4	100.0
97	S	S	0.0840	90.1	97.2	84.0	86.7	78.6	100.0
98	C	S	0.0709	90.1	97.3	84.0	86.7	76.9	100.0
99	S	B	0.0775	89.1	94.4	84.0	86.7	78.6	100.0
100	B	S	0.0841	89.1	97.3	84.0	85.7	71.4	100.0
101	A	B	0.0775	89.1	97.3	83.3	80.0	78.6	100.0
102	A	A	0.0767	89.1	97.3	83.3	73.3	85.7	100.0

表 3.4: 授業終盤における評価実験結果

番号	実成績	予測成績	誤差	的中率	S	A	B	C	X
1	C	C	0.0567	91.1	97.3	84.0	93.3	76.9	100.0
2	C	S	0.0658	91.1	97.3	84.0	86.7	84.6	100.0
3	C	A	0.0569	92.1	97.3	84.0	100.0	76.9	100.0
4	B	C	0.0527	93.1	97.3	84.0	100.0	85.7	100.0
5	B	S	0.0527	93.1	97.3	88.0	100.0	78.6	100.0

6	C	B	0.0539	93.1	97.3	84.0	93.3	92.3	100.0
7	B	A	0.0565	92.1	97.3	88.0	92.9	78.6	100.0
8	A	S	0.0716	90.1	97.3	83.3	86.7	78.6	100.0
9	A	B	0.0607	91.1	97.3	79.2	100.0	78.6	100.0
10	A	C	0.0516	93.1	97.3	83.3	100.0	85.7	100.0
11	A	S	0.0537	92.1	97.3	87.5	93.3	78.6	100.0
12	B	S	0.0598	92.1	97.3	84.0	100.0	78.6	100.0
13	X	X	0.0607	91.1	97.3	76.0	93.3	92.9	100.0
14	B	A	0.0499	94.1	97.3	88.0	100.0	85.7	100.0
15	X	X	0.0541	92.1	97.3	88.0	93.3	78.6	100.0
16	S	S	0.0584	91.1	100.0	76.0	86.7	92.9	100.0
17	B	B	0.0612	92.1	97.3	84.0	100.0	78.6	100.0
18	A	S	0.0592	92.1	97.3	83.3	93.3	85.7	100.0
19	A	S	0.0541	92.1	100.0	79.2	100.0	78.6	100.0
20	S	S	0.0605	92.1	97.2	84.0	100.0	78.6	100.0
21	B	S	0.0547	93.1	97.3	88.0	100.0	78.6	100.0
22	S	S	0.0622	92.1	97.2	84.0	100.0	78.6	100.0
23	A	C	0.0756	88.1	100.0	75.0	73.3	85.7	100.0
24	A	A	0.0599	92.1	97.3	83.3	93.3	85.7	100.0
25	A	S	0.0533	93.1	100.0	79.2	100.0	85.7	100.0
26	A	S	0.0524	93.1	97.3	87.5	100.0	78.6	100.0
27	B	A	0.0589	92.1	97.3	84.0	100.0	78.6	100.0
28	C	A	0.0784	88.1	97.3	72.0	86.7	84.6	100.0
29	X	X	0.0613	91.1	97.3	84.0	93.3	78.6	100.0
30	C	S	0.0661	90.1	97.3	80.0	86.7	84.6	100.0
31	A	C	0.0592	92.1	97.3	87.5	93.3	78.6	100.0
32	X	X	0.0550	93.1	97.3	84.0	100.0	85.7	100.0
33	B	S	0.0618	91.1	97.3	84.0	92.9	78.6	100.0
34	A	C	0.0530	93.1	97.3	83.3	93.3	92.9	100.0
35	C	A	0.0570	92.1	97.3	88.0	93.3	76.9	100.0
36	S	S	0.0632	91.1	97.2	84.0	80.0	92.9	100.0
37	S	A	0.0620	92.1	97.2	88.0	93.3	78.6	100.0
38	B	A	0.0576	92.1	97.3	84.0	92.9	85.7	100.0
39	X	X	0.0685	90.1	97.3	80.0	93.3	78.6	100.0
40	A	S	0.0608	92.1	97.3	79.2	93.3	92.9	100.0
41	X	X	0.0638	90.1	97.3	80.0	93.3	78.6	100.0
42	X	X	0.0473	94.1	97.3	88.0	100.0	85.7	100.0
43	B	S	0.0577	92.1	97.3	84.0	92.9	85.7	100.0
44	S	C	0.0656	90.1	94.4	84.0	86.7	85.7	100.0
45	B	S	0.0676	91.1	97.3	84.0	92.9	78.6	100.0

46	A	S	0.0626	92.1	97.3	83.3	100.0	78.6	100.0
47	S	S	0.0888	88.1	97.2	84.0	73.3	78.6	100.0
48	B	C	0.0517	93.1	97.3	88.0	100.0	78.6	100.0
49	S	S	0.0700	90.1	97.2	80.0	93.3	78.6	100.0
50	S	S	0.0656	91.1	97.2	84.0	93.3	78.6	100.0
51	S	B	0.0730	90.1	97.2	80.0	93.3	78.6	100.0
52	S	S	0.0567	92.1	97.2	84.0	100.0	78.6	100.0
53	S	S	0.0707	90.1	97.2	76.0	93.3	85.7	100.0
54	S	S	0.0640	91.1	97.2	84.0	86.7	85.7	100.0
55	C	S	0.0524	93.1	97.3	88.0	93.3	84.6	100.0
56	S	B	0.0699	89.1	94.4	80.0	93.3	78.6	100.0
57	A	S	0.0582	92.1	97.3	83.3	93.3	85.7	100.0
58	S	S	0.0763	89.1	97.2	84.0	80.0	78.6	100.0
59	S	A	0.0411	95.0	100.0	84.0	100.0	92.9	100.0
60	A	S	0.0875	87.1	97.3	75.0	80.0	78.6	100.0
61	X	X	0.0641	91.1	97.3	80.0	93.3	85.7	100.0
62	C	S	0.0569	92.1	97.3	84.0	93.3	84.6	100.0
63	S	S	0.0572	92.1	97.2	84.0	93.3	85.7	100.0
64	S	B	0.0707	88.1	100.0	64.0	93.3	85.7	100.0
65	S	A	0.0678	91.1	97.2	84.0	93.3	78.6	100.0
66	X	X	0.0724	89.1	97.3	76.0	93.3	78.6	100.0
67	S	S	0.0477	94.1	97.2	88.0	100.0	85.7	100.0
68	C	C	0.0609	92.1	97.3	84.0	100.0	76.9	100.0
69	C	C	0.0600	92.1	97.3	84.0	100.0	76.9	100.0
70	C	B	0.0561	92.1	97.3	84.0	100.0	76.9	100.0
71	S	S	0.0946	85.1	100.0	64.0	73.3	85.7	100.0
72	A	A	0.0602	92.1	97.3	83.3	100.0	78.6	100.0
73	A	A	0.0713	89.1	97.3	79.2	86.7	78.6	100.0
74	X	X	0.0578	92.1	97.3	84.0	93.3	85.7	100.0
75	C	B	0.0692	89.1	100.0	76.0	86.7	76.9	100.0
76	B	S	0.0537	93.1	97.3	88.0	100.0	78.6	100.0
77	A	A	0.0561	92.1	97.3	83.3	93.3	85.7	100.0
78	S	A	0.0762	89.1	97.2	72.0	100.0	78.6	100.0
79	A	A	0.0570	92.1	97.3	83.3	100.0	78.6	100.0
80	X	S	0.0607	92.1	97.3	84.0	100.0	78.6	100.0
81	A	S	0.0599	92.1	97.3	83.3	100.0	78.6	100.0
82	S	S	0.0481	94.1	97.2	88.0	93.3	92.9	100.0
83	S	S	0.0619	92.1	97.2	88.0	93.3	78.6	100.0
84	S	S	0.0471	94.1	97.2	88.0	100.0	85.7	100.0
85	S	S	0.0461	94.1	97.2	88.0	100.0	85.7	100.0

86	S	S	0.0657	90.1	97.2	76.0	100.0	78.6	100.0
87	S	A	0.0558	92.1	97.2	84.0	100.0	78.6	100.0
88	S	S	0.0507	93.1	97.2	88.0	100.0	78.6	100.0
89	S	S	0.0528	93.1	97.2	84.0	100.0	85.7	100.0
90	A	S	0.0581	91.1	97.3	87.5	86.7	78.6	100.0
91	S	S	0.0608	92.1	97.2	84.0	100.0	78.6	100.0
92	S	S	0.0709	90.1	97.2	76.0	100.0	78.6	100.0
93	A	S	0.0507	93.1	97.3	83.3	100.0	85.7	100.0
94	S	B	0.0672	91.1	97.2	84.0	93.3	78.6	100.0
95	S	S	0.0549	92.1	97.2	84.0	100.0	78.6	100.0
96	S	S	0.0563	93.1	97.2	88.0	100.0	78.6	100.0
97	S	A	0.0708	90.1	97.2	84.0	86.7	78.6	100.0
98	C	S	0.0652	91.1	97.3	80.0	100.0	76.9	100.0
99	S	B	0.0782	89.1	97.2	72.0	93.3	85.7	100.0
100	B	S	0.0728	90.1	97.3	84.0	85.7	78.6	100.0
101	A	S	0.0598	91.1	100.0	75.0	93.3	85.7	100.0
102	A	A	0.0776	89.1	97.3	83.3	80.0	78.6	100.0

表 3.5: 授業終了後における評価実験結果

番号	実成績	予測成績	誤差	的中率	S	A	B	C	X
1	C	A	0.0397	92.1	100.0	80.0	93.3	84.6	100.0
2	C	B	0.0199	96.0	100.0	96.0	93.3	84.6	100.0
3	C	A	0.0446	91.1	100.0	80.0	86.7	84.6	100.0
4	B	B	0.0248	95.0	100.0	96.0	85.7	85.7	100.0
5	B	B	0.0397	92.1	100.0	84.0	85.7	85.7	100.0
6	C	C	0.0446	91.1	100.0	80.0	86.7	84.6	100.0
7	B	A	0.0199	96.0	100.0	100.0	85.7	85.7	100.0
8	A	S	0.0397	92.1	100.0	83.3	86.7	85.7	100.0
9	A	C	0.0397	92.1	100.0	83.3	86.7	85.7	100.0
10	A	S	0.0446	91.1	100.0	79.2	86.7	85.7	100.0
11	A	A	0.0446	91.1	100.0	79.2	86.7	85.7	100.0
12	B	S	0.0446	91.1	100.0	80.0	85.7	85.7	100.0
13	X	X	0.0446	91.1	100.0	80.0	86.7	85.7	100.0
14	B	B	0.0446	91.1	100.0	80.0	85.7	85.7	100.0
15	X	X	0.0348	93.1	100.0	84.0	93.3	85.7	100.0
16	S	S	0.0446	91.1	100.0	80.0	86.7	85.7	100.0
17	B	A	0.0446	91.1	100.0	80.0	85.7	85.7	100.0
18	A	S	0.0397	92.1	100.0	83.3	86.7	85.7	100.0
19	A	S	0.0446	91.1	100.0	79.2	86.7	85.7	100.0

20	S	S	0.0150	97.0	100.0	96.0	93.3	92.9	100.0
21	B	S	0.0347	93.1	100.0	88.0	85.7	85.7	100.0
22	S	S	0.0298	94.1	100.0	88.0	93.3	85.7	100.0
23	A	B	0.0348	93.1	100.0	87.5	86.7	85.7	100.0
24	A	B	0.0347	93.1	100.0	87.5	86.7	85.7	100.0
25	A	S	0.0356	93.1	100.0	79.2	86.7	100.0	100.0
26	A	A	0.0398	92.1	100.0	83.3	86.7	85.7	100.0
27	B	C	0.0199	96.0	100.0	96.0	92.9	85.7	100.0
28	C	A	0.0397	92.1	100.0	84.0	86.7	84.6	100.0
29	X	X	0.0347	93.1	100.0	84.0	93.3	85.7	100.0
30	C	A	0.0446	91.1	100.0	80.0	86.7	84.6	100.0
31	A	A	0.0447	91.1	100.0	79.2	86.7	85.7	100.0
32	X	X	0.0446	91.1	100.0	80.0	86.7	85.7	100.0
33	B	B	0.0397	92.1	100.0	84.0	85.7	85.7	100.0
34	A	A	0.0446	91.1	100.0	79.2	86.7	85.7	100.0
35	C	C	0.0397	92.1	100.0	84.0	86.7	84.6	100.0
36	S	S	0.0446	91.1	100.0	80.0	86.7	85.7	100.0
37	S	C	0.0397	92.1	100.0	84.0	86.7	85.7	100.0
38	B	S	0.0446	91.1	100.0	80.0	85.7	85.7	100.0
39	X	X	0.0397	92.1	100.0	84.0	86.7	85.7	100.0
40	A	S	0.0446	91.1	100.0	79.2	86.7	85.7	100.0
41	X	X	0.0446	91.1	100.0	80.0	86.7	85.7	100.0
42	X	X	0.0349	93.1	100.0	80.0	86.7	100.0	100.0
43	B	S	0.0446	92.1	100.0	80.0	92.9	85.7	100.0
44	S	S	0.0397	92.1	100.0	84.0	86.7	85.7	100.0
45	B	B	0.0447	91.1	100.0	80.0	85.7	85.7	100.0
46	A	S	0.0446	91.1	100.0	79.2	86.7	85.7	100.0
47	S	S	0.0446	91.1	100.0	80.0	86.7	85.7	100.0
48	B	S	0.0397	92.1	100.0	80.0	92.9	85.7	100.0
49	S	S	0.0446	91.1	100.0	80.0	86.7	85.7	100.0
50	S	S	0.0398	92.1	100.0	84.0	86.7	85.7	100.0
51	S	S	0.0446	91.1	100.0	80.0	86.7	85.7	100.0
52	S	S	0.0199	96.0	100.0	96.0	93.3	85.7	100.0
53	S	B	0.0446	91.1	100.0	80.0	86.7	85.7	100.0
54	S	S	0.0446	91.1	100.0	80.0	86.7	85.7	100.0
55	C	S	0.0348	93.1	100.0	84.0	86.7	92.3	100.0
56	S	S	0.0446	91.1	100.0	80.0	86.7	85.7	100.0
57	A	A	0.0249	95.0	100.0	91.7	86.7	92.9	100.0
58	S	S	0.0446	91.1	100.0	80.0	86.7	85.7	100.0
59	S	A	0.0248	95.0	100.0	96.0	86.7	85.7	100.0

60	A	S	0.0299	94.1	100.0	91.7	86.7	85.7	100.0
61	X	X	0.0446	91.1	100.0	80.0	86.7	85.7	100.0
62	C	S	0.0199	96.0	100.0	96.0	86.7	92.3	100.0
63	S	S	0.0446	91.1	100.0	80.0	86.7	85.7	100.0
64	S	S	0.0299	94.1	100.0	84.0	86.7	100.0	100.0
65	S	A	0.0248	95.0	100.0	96.0	86.7	85.7	100.0
66	X	X	0.0446	91.1	100.0	80.0	86.7	85.7	100.0
67	S	C	0.0446	91.1	100.0	80.0	86.7	85.7	100.0
68	C	C	0.0446	91.1	100.0	80.0	86.7	84.6	100.0
69	C	C	0.0446	91.1	100.0	80.0	86.7	84.6	100.0
70	C	B	0.0397	92.1	100.0	84.0	86.7	84.6	100.0
71	S	S	0.0397	92.1	100.0	84.0	86.7	85.7	100.0
72	A	A	0.0446	91.1	100.0	79.2	86.7	85.7	100.0
73	A	A	0.0446	91.1	100.0	79.2	86.7	85.7	100.0
74	X	X	0.0347	93.1	100.0	84.0	93.3	85.7	100.0
75	C	C	0.0446	91.1	100.0	80.0	86.7	84.6	100.0
76	B	B	0.0446	91.1	100.0	80.0	85.7	85.7	100.0
77	A	A	0.0446	91.1	100.0	79.2	86.7	85.7	100.0
78	S	B	0.0248	95.0	100.0	96.0	86.7	85.7	100.0
79	A	A	0.0249	95.0	100.0	95.8	86.7	85.7	100.0
80	X	X	0.0446	91.1	100.0	80.0	86.7	85.7	100.0
81	A	S	0.0397	92.1	100.0	83.3	86.7	85.7	100.0
82	S	S	0.0446	91.1	100.0	80.0	86.7	85.7	100.0
83	S	S	0.0397	92.1	100.0	84.0	86.7	85.7	100.0
84	S	S	0.0446	91.1	100.0	80.0	86.7	85.7	100.0
85	S	A	0.0446	91.1	100.0	80.0	86.7	85.7	100.0
86	S	S	0.0447	91.1	100.0	80.0	86.7	85.7	100.0
87	S	A	0.0248	95.0	100.0	96.0	86.7	85.7	100.0
88	S	S	0.0447	91.1	100.0	80.0	86.7	85.7	100.0
89	S	S	0.0397	92.1	100.0	84.0	86.7	85.7	100.0
90	A	S	0.0397	92.1	100.0	83.3	86.7	85.7	100.0
91	S	X	0.0446	91.1	100.0	80.0	86.7	85.7	100.0
92	S	S	0.0398	92.1	100.0	80.0	93.3	85.7	100.0
93	A	A	0.0446	91.1	100.0	79.2	86.7	85.7	100.0
94	S	S	0.0446	91.1	100.0	80.0	86.7	85.7	100.0
95	S	S	0.0446	91.1	100.0	80.0	86.7	85.7	100.0
96	S	S	0.0150	97.0	100.0	100.0	93.3	85.7	100.0
97	S	S	0.0397	92.1	100.0	80.0	93.3	85.7	100.0
98	C	A	0.0299	94.1	100.0	92.0	86.7	84.6	100.0
99	S	S	0.0446	91.1	100.0	80.0	86.7	85.7	100.0

100	B	A	0.0397	92.1	100.0	80.0	92.9	85.7	100.0
101	A	B	0.0248	95.0	100.0	95.8	86.7	85.7	100.0
102	A	A	0.0100	98.0	100.0	100.0	86.7	100.0	100.0

これらの結果から, 予測した成績と実際の成績との関係を表 3.6, 表 3.7, 表 3.8 にまとめる.

表 3.6: 授業中盤での予測結果

		実成績					
		S	A	B	C	D	X
予測成績	S	21	8	8	4	0	0
	A	8	10	2	4	0	1
	B	8	3	4	1	0	0
	C	0	4	1	6	0	0
	D	0	0	0	0	0	0
	X	0	0	0	0	0	10

表 3.7: 授業終盤での予測結果

		実成績					
		S	A	B	C	D	X
予測成績	S	25	14	8	5	0	1
	A	6	6	4	3	0	0
	B	5	1	1	3	0	0
	C	1	4	2	3	0	0
	D	0	0	0	0	0	0
	X	0	0	0	0	0	10

表 3.8: 授業終了後での予測結果

		実成績					
		S	A	B	C	D	X
予測成績	S	29	10	5	2	0	0
	A	4	11	3	5	0	0
	B	2	3	6	2	0	0
	C	2	1	1	5	0	0
	D	0	0	0	0	0	0
	X	0	0	0	0	0	11

表における行は予測成績を、列は実成績を表している。例えば、表 3.6 において (S,A) の学生は 8 人いる。これは予測成績が S であったが、実際の成績が A であったことを表す。つまり表の対角成分が的中している人数を表す。また、対角成分の上側を見ることにより実際の成績よりも成績が高く予測されていること、下側を見ることにより実際の成績よりも予測成績が低く予測されていることを確認することができる。

これらの結果から、正確に成績を的中させた割合、1 ランク違いを含めた中の割合、2 ランク違いを含めた中の割合を求めた。表 3.9 にその結果を示す。

表 3.9: 実成績に対する的中率

予測時点	授業中盤	授業終盤	授業終了後
正確に的中 (%)	53.9	43.1	60.7
含む 1 ランク違い (%)	70.5	73.5	83.3
含む 2 ランク違い (%)	94.1	93.1	96.0

学生の成績を正確に的中させることができたのは、授業中盤においては約 54 %、終盤で約 43 %、終了後で約 61 %と、半分程度となってしまっている。1 ランク違いを含めた割合を見てみると、授業中盤において 70 % を超え、終了後では 80 % を超える結果となっており、2 ランク違いを含めた割合においてはほぼ 95 % の学生が範囲内に含まれていることから、成績予測の結果は大きく外れていないと言える。

次に各成績ごとの実際の成績に対する的中率 (各成績の的中数 / 各成績の学生数) を確認し、表 3.10 に示す。

表 3.10: 成績ごとの実成績に対する的中率

予測時点	授業中盤					
成績	S	A	B	C	D	X
正確に的中 (%)	56.7	40.0	26.6	42.8	0	90.9
含む1ランク違い (%)	78.3	84.0	46.6	42.8	0	90.9
含む2ランク違い (%)	100.0	100.0	100.0	71.4	0	90.9
予測時点	授業終盤					
成績	S	A	B	C	D	X
正確に的中 (%)	67.5	24.0	6.6	21.4	0	90.9
1ランク違い (%)	83.7	84.0	46.6	42.8	0	90.9
2ランク違い (%)	97.2	100.0	100.0	64.2	0	90.9
予測時点	授業終了後					
成績	S	A	B	C	D	X
正確に的中 (%)	78.3	44.0	40.0	35.7	0	100.0
1ランク違い (%)	89.1	96.0	66.6	50.0	0	100.0
2ランク違い (%)	94.5	100.0	100.0	85.7	0	100.0

正確に的中している成績に着目したとき、最優秀成績であるSはほぼ60%以上、失格であるXは90%以上と、高い精度で予測できていることが確認できる。しかしながら、成績Aに関しては授業中盤と終了後では50%を切り、終盤に至っては20%に近い。また成績Bにおいては中盤では30%程度で、終盤で10%を切るという低い的中率であるが、終了後は40%に上がっている。成績Cについても同様、中盤、終了後で約40%程度であるが終盤では低めの20%となってしまう。授業終盤における全体の的中率が他の2つの予測タイミングより下がってしまったのは、成績A,B,Cの的中率が低いためである。

1ランク違いを含めた中の割合に着目すると、正確に的中した割合と比較すると全てのタイミングにおいて成績A,B,Cの的中率が大きく上がっている。的中率の低かった授業終盤における成績予測の結果は、1ランク違いの誤りが多かったことがわかる。2ランク違いを含めた的中率では成績S,A,Bに関してはほぼ100%になっている。

以上より、成績ごとの的中率を確認しても成績予測の結果は大きく外れていないことがわかる。よって、ニューラルネットワークに過去の学生のデータを学習させることで、おおまかに成績予測が可能であると言える。

次に、単位取得成績(S,A,B,C)であるか、単位取得不可成績(D,X)の2点について着目する。単位取得成績の予測に関して、授業中盤、授業終盤においては100%的中している。授業終了後については1人だけ成績Xとしてしまい誤った予測を出力している。単位取得不可成績の予測に関しては授業中盤、終盤において90%的中している。授業終了後においては100%的中させることができていた。

このことから、単位が取得可能か、不可能かに関する判定は高い精度で予測することができると考えられる。しかし、成績Xになるであろう学生は、落第候補者を早期発見したいと

いう要求を満たすために、できる限り100%予測したい。そこで、授業中盤、授業終盤において実成績Xの学生で的中させることのできなかった学生に着目する。

表3.3,表3.4より,80番の学生がその学生に該当する。その学生は講義7回目までは比較的講義に出席し,出席した講義に与えられた課題は提出を行うという平均的な学習状況であった。しかし講義8回目以降は講義に出席しなくなり,課題の提出も行わなくなり,その結果成績Xになってしまうという,途中で講義放棄をしてしまった学生であった。一方,その他の実成績Xの学生は授業中盤より前に講義を放棄してしまっていた。leave one out法により学習されたネットワークには中盤以降に講義を放棄した学生のパターンは学習されていなく,結果的にその学生の認識率が低くなってしまっており,予測ができなかったと言える。

表3.3,表3.4の成績Xの項目を確認するとわかるように,的中率はすべて100%となっている。80番の学生のパターンがネットワークに学習されていることで的中させることが可能となっている。

以上のことから,中盤以降講義を放棄した学生と同等のパターンを学習させることにより予測を的中させることが可能となることが確認できた。同様に成績を予測したい学生と同じようなパターンを学習させることで,その学生の成績を高い精度で予測することが可能であると考えられる。

しかし,あらかじめネットワークに成績を予測したい学生のパターンをすべて学習させておくことは困難である。学習させるデータ数を増やし,様々なパターンを学習させておくことにより更に成績予測の精度を高められることが期待できる。

## 3.4 評価実験(2)

### 3.4.1 落第候補者が検出可能である最低講義回数の検証

評価実験(1)において,授業中盤から比較的早い段階で成績予測が可能であることを示した。しかしながら,落第候補者はできるだけ早く発見し,該当者には早期に修学指導を行いたい。そこで,講義2回目から講義15回までの学習データを用いて,leave one out法を実成績Xの学生11人に対し行い,何回目の講義から信頼できる精度で実成績Xの学生11人を的中させることができるか確認した。

実験を行うに際し,ニューラルネットワークの構造は講義回別に表3.11の値を用いる。

表 3.11: 評価実験 (2) におけるネットワークの構造

講義回	入力ユニット数 (出欠-課題提出-提出値)	中間ユニット数	出力ユニット数
2	4(2-1-1)	10	6
3	5(3-1-1)	10	6
4	8(4-2-2)	20	6
5	11(5-3-3)	30	6
6	14(6-4-4)	30	6
7	17(7-5-5)	40	6
8	18(8-5-5)	40	6
9	21(9-6-6)	40	6
10	24(10-7-7)	50	6
11	27(11-8-8)	60	6
12	28(12-8-8)	60	6
13	29(13-8-8)	60	6
14	30(14-8-8)	60	6
15	35(15-10-10)	70	6

それぞれのニューラルネットワークの学習係数  $\eta$  は 0.1 とする.

### 3.4.2 結果及び考察

leave one out 法により得られた結果を表 3.12 に示す. 各項目は番号は成績 X であった学生の番号, 予測成績はニューラルネットワークにより予測された成績, 誤差はその学習での最終誤差, 的中率は取り除いた番号以外の学生のデータをネットワークに入力した際の的中率を示している.

表 3.12: 各講義回ごとの結果

講義 2 回				講義 3 回			
番号	予測成績	誤差	的中率	番号	予測成績	誤差	的中率
13	X	0.2786	56.4	13	X	0.2739	57.4
15	X	0.2796	55.4	15	X	0.2747	57.4
29	X	0.2730	55.4	29	X	0.2578	60.4
32	X	0.2765	56.4	32	S	0.2703	58.4
39	X	0.2729	57.4	39	X	0.2583	60.4
41	X	0.2800	56.4	41	X	0.2781	56.4
42	B	0.2929	53.5	42	A	0.2604	60.4
61	B	0.2700	57.4	61	X	0.2624	59.4
66	X	0.2799	56.4	66	B	0.2566	60.4

74	X	0.2798	56.4	74	X	0.2577	60.4
80	B	0.2741	57.4	80	B	0.2564	59.4
講義 4 回				講義 5 回			
番号	予測成績	誤差	的中率	番号	予測成績	誤差	的中率
13	X	0.1821	73.3	13	X	0.1432	80.2
15	X	0.1828	73.3	15	X	0.1379	78.2
29	X	0.1776	73.3	29	X	0.1355	79.2
32	S	0.1759	74.3	32	X	0.1361	79.2
39	X	0.1824	74.3	39	X	0.1404	78.2
41	X	0.1774	74.3	41	X	0.1402	78.2
42	X	0.1860	73.3	42	A	0.1381	79.2
61	X	0.1772	74.3	61	X	0.1371	78.2
66	X	0.1821	73.3	66	X	0.1522	76.2
74	X	0.1801	74.3	74	X	0.1411	78.2
80	B	0.1763	74.3	80	A	0.1399	79.2
講義 6 回				講義 7 回			
番号	予測成績	誤差	的中率	番号	予測成績	誤差	的中率
13	X	0.1158	83.2	13	X	0.0981	85.1
15	X	0.1227	81.2	15	X	0.0941	85.1
29	X	0.1341	80.2	29	X	0.0902	87.1
32	X	0.1241	81.2	32	X	0.0976	85.1
39	X	0.1296	81.2	39	X	0.0874	87.1
41	X	0.1256	82.2	41	X	0.0953	86.1
42	X	0.1152	82.2	42	X	0.0963	85.1
61	X	0.1309	82.2	61	X	0.0949	85.1
66	X	0.1293	82.2	66	X	0.0872	86.1
74	X	0.1259	82.2	74	X	0.0890	87.1
80	S	0.1228	83.2	80	S	0.0921	85.1
講義 8 回				講義 9 回			
番号	予測成績	誤差	的中率	番号	予測成績	誤差	的中率
13	X	0.0847	89.1	13	X	0.0662	90.1
15	X	0.0769	91.1	15	X	0.0676	90.1
29	X	0.0773	89.1	29	X	0.0615	92.1
32	X	0.0813	88.1	32	X	0.0663	91.1
39	X	0.0759	90.1	39	X	0.0685	91.1
41	X	0.0759	90.1	41	X	0.0654	91.1
42	X	0.0831	88.1	42	X	0.0661	91.1
61	X	0.0890	87.1	61	X	0.0652	91.1
66	X	0.0811	89.1	66	X	0.0593	92.1
74	X	0.0827	88.1	74	X	0.0686	91.1

80	A	0.0755	90.1	80	S	0.0661	91.1
講義 10 回				講義 11 回			
番号	予測成績	誤差	的中率	番号	予測成績	誤差	的中率
13	X	0.0579	92.1	13	X	0.0607	91.1
15	X	0.0537	92.1	15	X	0.0541	92.1
29	X	0.0544	93.1	29	X	0.0613	91.1
32	X	0.0609	92.1	32	X	0.0550	93.1
39	X	0.0579	92.1	39	X	0.0685	90.1
41	X	0.0521	93.1	41	X	0.0638	90.1
42	X	0.0516	93.1	42	X	0.0473	94.1
61	X	0.0473	94.1	61	X	0.0641	91.1
66	X	0.0517	93.1	66	X	0.0724	89.1
74	X	0.0510	93.1	74	X	0.0578	92.1
80	S	0.0570	92.1	80	S	0.0607	92.1
講義 12 回				講義 13 回			
番号	予測成績	誤差	的中率	番号	予測成績	誤差	的中率
13	X	0.0516	93.1	13	X	0.0644	90.1
15	X	0.0646	90.1	15	X	0.0654	90.1
29	X	0.0629	90.1	29	X	0.0651	90.1
32	X	0.0691	92.1	32	X	0.0558	92.1
39	X	0.0701	90.1	39	X	0.0533	92.1
41	X	0.0610	92.1	41	X	0.0668	90.1
42	X	0.0736	88.1	42	X	0.0654	90.1
61	X	0.0777	87.1	61	X	0.0678	91.1
66	X	0.0629	91.1	66	X	0.0647	90.1
74	X	0.0666	91.1	74	X	0.0608	91.1
80	S	0.0556	92.1	80	A	0.0626	91.1
講義 14 回				講義 15 回			
番号	予測成績	誤差	的中率	番号	予測成績	誤差	的中率
13	X	0.0679	90.1	13	X	0.0446	91.1
15	X	0.0681	90.1	15	X	0.0348	93.1
29	X	0.0614	91.1	29	X	0.0347	93.1
32	X	0.0610	91.1	32	X	0.0446	91.1
39	X	0.0608	91.1	39	X	0.0397	92.1
41	X	0.0526	93.1	41	X	0.0446	91.1
42	X	0.0530	93.1	42	X	0.0349	93.1
61	X	0.0629	91.1	61	X	0.0446	91.1
66	X	0.0481	94.1	66	X	0.0446	91.1
74	X	0.0529	93.1	74	X	0.0347	93.1
80	A	0.0545	92.1	80	X	0.0446	91.1

また, 最終成績 X の学生の的中率をグラフにし, 図 3.3 に示した.

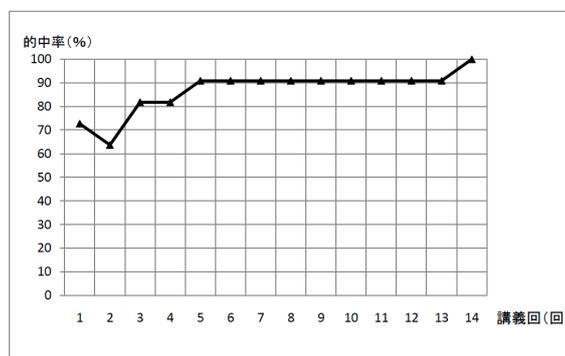


図 3.3: 講義回数ごとの最終成績 X の学生の的中率

講義 2 回目に 70 % と, 高い的中率が得られているが, まだ出欠データ 2 つ, 課題提出データ, 提出値データがそれぞれ 1 つと, データ数が少ないので信頼性が高いとは言えない. 少しデータが増えた 3 回目以降は, 的中率が上がってきている. 4, 5 回目で 80 % を超え, 6 回目には 90 % に到達した. 6 回目以降は最高値の 90 % を維持している.

最後まで的中させることができなかったのは, 3.3.2 項にて挙げられた学生である.

このことから, 落第候補者は 4, 5 回目から概ね発見可能であることが期待でき, 6 回目からはかなり信頼できる精度で認識できると考えられる.

## 第4章 学習指導への適用可能性の検討

第3章においてニューラルネットワークを用いて成績予測が可能であることを示した。しかし、本研究の目的はニューラルネットワークによる成績予測の結果を用いて、学生に適切な学習指導を行うことである。

本章では、成績予測で得られた結果を用いて行うことができる学習指導方法を提案する。ただし、学習指導はある程度成績予測の結果が信頼できる、授業中盤（講義8回目）の時点で行うものとする。

### 4.1 ニューラルネットワークから得られる情報

ニューラルネットワークは入力に対し、常に最良の結果を出力する。しかし、その出力に至るまでのプロセスは使用者には明らかにならずブラックボックス化している。それゆえ成績予測において成績Bが出力されたとしても、学習状況が向上してきたのBなのか、学習状況が低下してきたのBなのかを判断することができない。それまでの状況によって、その後の学習指導も変わってくる。ニューラルネットワークから得られた「成績B」という情報だけでは、前者のような学生に学習状況を維持するような指導はできず、後者のような学生に学習状況を改善するような指導もできない。ニューラルネットワークから得られた結果をそのまま学習指導に用いるのではなく、それらを応用して学習指導を行うことが有効であると考えられる。

### 4.2 成長可能性の把握

ニューラルネットワークから得られる出力値は、その成績になることを表すのではなく、その成績になることが濃厚であることを表すので、出力値自体を使用することは困難である。

そこで、8回までの成績予測の結果の推移に着目する。授業中盤においてある程度成績予測が可能であることから、最終成績の良い学生は授業序盤から中盤にかけて良い成績が予測され、最終成績の悪い学生は授業序盤は予測成績が良かったものの、授業中盤に至るまでに予測成績が徐々に悪くなっていくといった傾向が見られることが考えられる。他にも様々な傾向が存在すると考えられるため、講義8回までの成績予測結果を基にクラスタリングを行い、成績予測の結果の推移が類似している学生を分類し、傾向を調査した。ここで用いる成績予測の結果は、講義2回目から8回目の学習データに対しそれぞれ leave one out 法を適用し、ネットワークを20000回学習して得られたものを用いる。ネットワークの構造、及びパラメータは3.4.1項に記述してあるものと同様とする。

クラスタリングを行うに際し、予測成績を全て数値化する必要があり、各成績に対し単純に数値を割り当てた。ここでは  $S = 6, A = 5, B = 4, C = 3, D = 2, X = 1$  とした。

クラスタリングを行うツールとして、Weka[10] を使用し、クラスタリング手法は K-means 法を採用した。K-means 法ではあらかじめ自分で最終的なクラスタ数を決定する。そこでクラスタ数は、様々な傾向を認識したいという要求から 10 個とした。

クラスタリングの結果、10 個のクラスタにはそれぞれ以下のような傾向が見られた。

クラスタ 1 常に S と予測されている。

クラスタ 2 ほぼ S と予測され、稀に A が予測されている。

クラスタ 3 5,6 回目までは S と予測されていたが、7 回目以降は A, B と予測されている。

クラスタ 4 平均して A と予測されている。

クラスタ 5 7 回目までは平均して S, A が予測されていたが、8 回目に B, C と予測されている。

クラスタ 6 2,3,7,8 回目は S と予測されていたが、4,5,6 回目では B, C と予測されている。

クラスタ 7 4 回目までは S と予測されていたが、5 回目以降は B, C と予測されている。

クラスタ 8 2,3 回目までは S と予測されていたが、それ以降は B, C と予測されている。

クラスタ 9 2 回目までは X と予測されたが、中盤に至るまでに徐々に予測成績が上がっている。

クラスタ 10 X が 4 回以上予測されている。

クラスタごとに、各講義回の成績予測値の平均値を算出し、グラフ (図 4.1) で表すとその傾向が更に確認しやすくなる。

また、各クラスタに存在する学生の最終成績の内訳は表 4.1 のようになる。

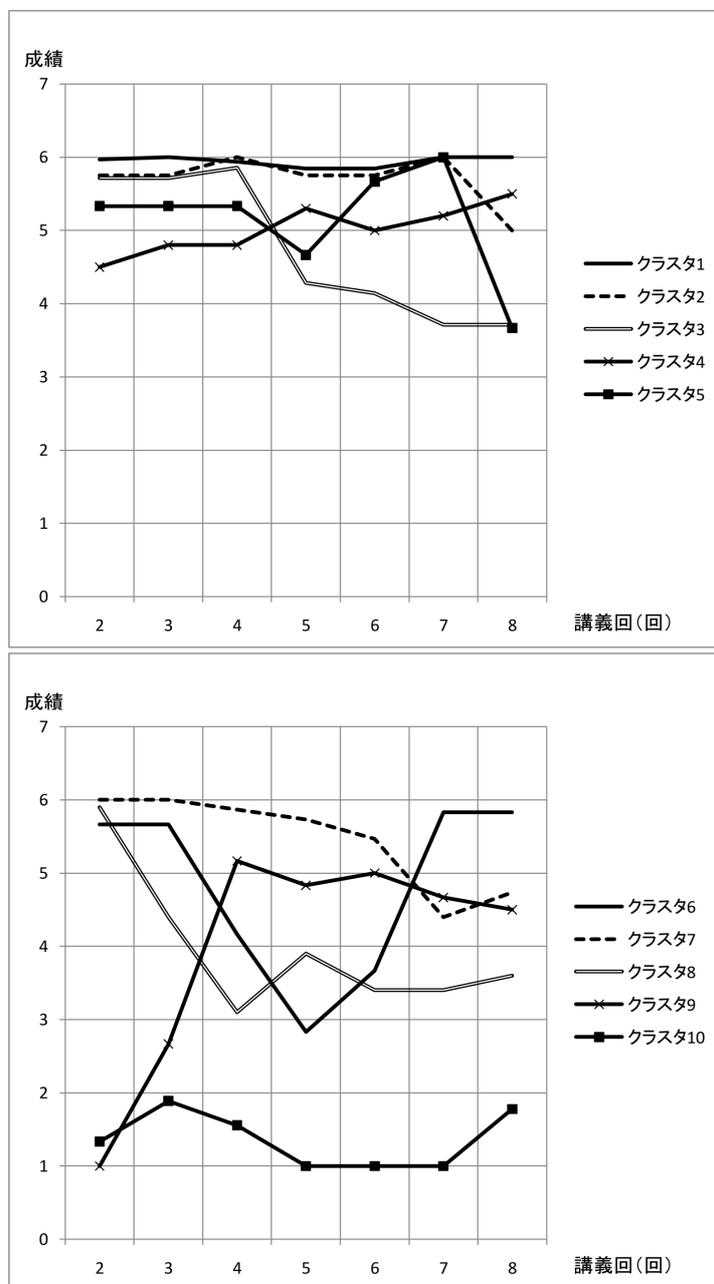


図 4.1: クラスタごとの比較

表 4.1: クラスタ毎の最終成績内訳

クラスタ番号	S	A	B	C	D	X	計
1	19	6	4	3	0	0	32
2	1	3	0	0	0	0	4
3	4	3	0	0	0	0	7
4	4	2	3	0	0	1	10
5	1	1	1	0	0	0	3
6	1	1	2	2	0	0	6
7	3	6	3	3	0	0	15
8	2	2	0	5	0	1	10
9	2	1	2	1	0	0	6
10	0	0	0	0	0	0	9

図 4.1 と照らし合わせると、予測成績の点数が高いクラスタほど最終成績が高い学生の割合が多くなり、点数が低いクラスタほど最終成績が低い学生の割合が多くなる傾向が見られる。

すなわち、前者のクラスタに属する学生の学習に対する姿勢は比較的良好であり、後者のクラスタに属する学生の学習に対する姿勢はあまり良くなかったということが考えられる。

よって、このクラスタ化された成績予測の推移のパターンに対し、履修途中の学生の成績予測の結果を数値化し、マッチングさせることで自分の成績推移による学習状況を把握することができ、マッチングされたクラスタの最終成績の内訳を知ることによって、学生の成長可能性を把握することが可能になることが期待できる。

### 4.3 学習指導への適用検討

講義 2 回から 8 回までの成績予測の結果をクラスタリングすることによって得られた 10 個のクラスタから、そのクラスタに合った学習指導を行いたい。そこで、クラスタごとに講義 9 回から 15 回までの学生の講義への出席状況、課題の提出状況、加えて最終課題 (2 題) の評価が最終成績に影響を与えているかを確認する。それら 3 つの要素が最終成績と関係を持つ場合、そのクラスタ内で最終成績の良い学生がどのような推移で良い最終成績になったのか、最終成績の悪い学生がどのような推移で悪い最終成績になってしまったのか、その理由を把握することが可能であり、学習指導も可能になると考えられる。

次に各クラスタに属する学生の講義 2 回目から 8 回目までの成績予測の結果を数値化したデータ、講義 9 回から 15 回目までの出席回数、課題の提出回数、最終課題の評価 (2 題分)、最終成績を表 4.2(クラスタ 1) ~ 表 4.11(クラスタ 10) にまとめる。なお、成績予測の結果は  $S = 6, A = 5, B = 4, C = 3, D = 2, X = 1$  と数値化する。また、講義 9 回目から 15 回目までの課題の提出回数は最終課題 2 題を含め 5 回である。最終課題の評価は、(非常に良い)、(良い)、(普通)、×(悪い) で与えられており、最終課題が未提出である学生は評価は与えられておらず、- と表記している。



表 4.2 より、クラスタ 1 の学生は成績予測の結果が優秀で、講義 9 回目以降も出席率が良く課題も欠かさず提出しているため、半分以上の学生の最終成績が S になっていることが確認できる。講義 9 回目以降やや出席回数が減ってしまっている学生は少し成績が悪くなっている。しかし、最終成績 B,C の学生を確認すると、このクラスタにおいては最終課題の評価が大きく影響していると考えられる。

上記より、クラスタ 1 の学生に行えるであろう学習指導は、このままの学習姿勢を保つことと、課題の質を上げることが挙げられる。

表 4.3: クラスタ 2 の学生の学習状況及び課題の評価

2回	3回	4回	5回	6回	7回	8回	出席	提出	課題 1	課題 2	最終成績
6	6	6	6	6	6	5	4	5			A
6	6	6	6	6	6	5	7	5			A
5	5	6	5	5	6	5	6	5			A
6	6	6	6	6	6	5	6	5			S

表 4.3 から確認できるように、クラスタ 2 の学生は最終成績が S,A のみである。9 回目以降の授業への取り組みは全体として大きな変化はなく、S,A の決め手となっているのは最終課題の評価ということが確認できる。しかし、出席回数が 4 回の学生は、最終課題の評価が優秀であるのにも関わらず成績が A となっている。

このことから、クラスタ 2 の学生に行えるであろう学習指導は、課題の質を高めることで更なるステップアップが可能であることと課題だけでなく、普段の授業に対する姿勢を改善することが挙げられる。

表 4.4: クラスタ 3 の学生の学習状況及び課題の評価

2回	3回	4回	5回	6回	7回	8回	出席	提出	課題 1	課題 2	最終成績
6	6	5	4	4	3	3	7	5			A
6	6	6	6	3	3	3	4	5			A
6	6	6	4	4	4	4	7	5			A
6	6	6	4	4	4	4	7	5			S
6	6	6	4	4	4	4	7	5			S
6	6	6	4	6	4	4	7	5			S
4	4	6	4	4	4	4	7	5			S

表 4.4 より、クラスタ 3 の学生の成績推移の傾向として、4 回目から予測成績が下がってきていることが挙げられる。4 回目から 8 回目にかけての授業への姿勢があまり良くなかったと推測できる。しかし、9 回目以降の出席回数、課題提出回数は優秀で、最終課題の評価も高いことから授業への姿勢が改善されたと考えられる。その結果、このクラスタには最終成績 S,A の学生しか存在しない。改善されなかった場合を想定すると、学生の最終成績が大きく下が

るようなパターンも考えられることに注意したい。

以上を踏まえてクラスタ3の学生に行えるであろう学習指導は、講義への出席といった、学習姿勢の改善を行うと良いと考えられる。

表 4.5: クラスタ4の学生の学習状況及び課題の評価

2回	3回	4回	5回	6回	7回	8回	出席	提出	課題1	課題2	最終成績
5	5	5	5	5	5	6	6	5			A
5	5	5	5	5	5	5	6	5			A
4	4	4	5	6	4	4	7	5			B
5	5	5	6	6	6	6	7	5			B
6	3	5	6	3	6	6	5	5			B
3	6	5	5	5	5	5	7	5			S
5	5	5	5	5	5	6	6	5			S
3	6	5	5	5	5	5	6	5			S
5	5	5	6	5	6	6	6	5			S
4	4	4	5	5	5	6	0	0	—	—	X

表 4.5 より、クラスタ4の学生は成績予測の推移が成績 A 付近で、最終成績に S, B の割合が高くなっていることがわかる。成績 B となっている学生は出席、課題の提出はしっかりと行っているが最終課題の評価が低い、もしくは最終課題の評価はほどほどであるが出席回数が若干少ないという状況である。足りないどちらかを補うことにより成績アップが望めるだろう。しかし、出席回数、課題の提出回数に大きな差がないことから、課題の質の向上が成績アップの近道とも言える。

このクラスタには途中で授業を放棄してしまった学生もいることに注意したい。

表 4.6: クラスタ5の学生の学習状況及び課題の評価

2回	3回	4回	5回	6回	7回	8回	出席	提出	課題1	課題2	最終成績
5	5	5	3	6	6	4	7	5			A
6	6	6	6	6	6	3	7	5			B
5	5	5	5	5	6	4	7	5			S

表 4.6 より、クラスタ5の学生は講義8回目において大きく予測成績が下がってしまっているが、9回目以降の講義では出席、課題の提出をくまなく行っていることが確認できる。それらの回数に差がないことから、課題の評価によって大きく成績が変化するクラスタだと言える。課題の質の向上と共に、講義8回目において予測成績が下がってしまったままにならないよう、9回目以降の講義への出席を促したい。

表 4.7: クラスタ 6 の学生の学習状況及び課題の評価

2回	3回	4回	5回	6回	7回	8回	出席	提出	課題1	課題2	最終成績
4	4	4	1	5	6	6	7	5			A
6	6	3	3	3	6	6	6	5			B
6	6	6	3	4	6	6	7	5			B
6	6	3	3	3	5	5	6	5			C
6	6	6	4	4	6	6	7	5			C
6	6	3	3	3	6	6	7	5			S

表 4.7 より, クラスタ 6 の学生は講義 4,5,6 回において予測成績が 1 度大きく下がり, 7 回目以降に再び上がっていることがわかる. 上がって以降は授業に対する姿勢は優秀である. にもかかわらず, 最終課題の評価が低いことにより成績 B, C の学生の割合が多くなってしまっている. 課題の質の向上を促すことでこのクラスタの学生の成績を向上させることができるだろう.

表 4.8: クラスタ 7 の学生の学習状況及び課題の評価

2回	3回	4回	5回	6回	7回	8回	出席	提出	課題1	課題2	最終成績
6	6	5	5	5	4	5	7	5			A
6	6	6	6	4	5	5	5	5			A
6	6	5	5	5	4	5	7	5			A
6	6	6	6	6	3	5	3	5			A
6	6	6	6	5	5	5	5	5			A
6	6	6	5	6	4	4	6	5			A
6	6	6	6	6	5	5	7	5			B
6	6	6	6	5	5	4	4	5			B
6	6	6	6	6	5	5	6	5			B
6	6	6	6	6	5	4	4	5			C
6	6	6	6	5	5	5	5	5	×		C
6	6	6	6	6	5	4	4	5			C
6	6	6	6	6	4	4	7	5			S
6	6	6	6	6	3	6	7	5			S
6	6	6	5	5	4	5	7	5			S

表 4.8 において, クラスタ 7 の講義 8 回までの成績推移の特徴として講義の回を重ねるごとに少しずつ成績予測の結果が下がっていることが挙げられる. そこで授業に対する姿勢を改善したか, もしくはそのままの状態を維持したかがそのまま最終成績に反映されている. 特に成績 B, C の学生は出席回数が少ない傾向にある. 最終課題の評価が優秀な成績 C の学生も存在することから, 課題の質はもちろんとして, このクラスタにおいては授業に対する姿

勢の改善するよう指導することが有効であると考えられる。

表 4.9: クラスタ 8 の学生の学習状況及び課題の評価

2回	3回	4回	5回	6回	7回	8回	出席	提出	課題1	課題2	最終成績
6	3	3	6	6	3	3	6	5			A
6	6	3	3	3	4	3	7	5			A
6	6	3	3	3	3	3	3	5			C
6	6	3	6	3	5	4	5	5			C
6	3	3	3	3	3	3	4	5			C
6	3	3	3	5	3	3	4	5			C
6	3	3	3	3	4	4	5	4			C
6	6	3	3	3	4	4	7	5			S
6	3	4	4	4	4	4	7	5			S
5	5	3	5	1	1	5	0	0	—	—	X

表 4.9 より、クラスタ 8 は授業序盤以降、成績予測値が低いことが確認できる。授業中盤までの学習状況は良くなかったと言える。このクラスタは 9 回目以降の学生の出席回数の違いが顕著で、出席回数が多い学生は最終成績が S, A になり、出席回数が少ない学生は最終成績が C となっている。このクラスタに関しては最終課題の評価がとても良いのにも関わらず最終成績 C となっている学生の割合が多い。このことから、このクラスタにおいては出席回数が大きく成績に影響することがわかるので、それに関して学習指導を行うことが有効である。また、成績 C の学生が多いクラスタであるため、落第候補者の早期発見の観点から注意が必要である。

表 4.10: クラスタ9の学生の学習状況及び課題の評価

2回	3回	4回	5回	6回	7回	8回	出席	提出	課題1	課題2	最終成績
1	4	5	4	6	5	5	5	5			A
1	1	4	3	4	4	3	4	5			B
1	1	6	6	6	6	3	1	5			B
1	5	5	5	3	3	6	7	5			C
1	1	5	5	5	4	4	7	5			S
1	4	6	6	6	6	6	7	5			S

表 4.10 において、クラスタ9の学生は授業序盤では予測成績の結果が悪かったが、中盤にかけて予測が良くなっている学生が集まっている。出席回数、課題の提出回数が多く、最終課題の評価が良好である学生の最終成績がSになり、出席回数が下がるにつれ、課題の評価が悪くなるにつれ成績も下がっていくといった平均的な傾向を持つクラスタである。逆に言えば、何か1つが欠けるとそれが成績の低下につながるのだからそれなりの努力が必要なクラスタでもあると言える。学生にはそれに沿うような学習指導が行われると効果的であると考えられる。

表 4.11: クラスタ10の学生の学習状況及び課題の評価

2回	3回	4回	5回	6回	7回	8回	出席	提出	課題1	課題2	最終成績
1	1	1	1	1	1	1	0	0	-	-	X
1	1	1	1	1	1	1	0	0	-	-	X
1	1	1	1	1	1	1	0	0	-	-	X
1	6	6	1	1	1	1	0	0	-	-	X
1	1	1	1	1	1	1	2	0	-	-	X
1	1	1	1	1	1	1	0	0	-	-	X
4	1	1	1	1	1	1	0	0	-	-	X
1	4	1	1	1	1	1	0	0	-	-	X
1	1	1	1	1	1	1	0	0	-	-	X

表 4.11 はクラスタ10の学生について示している。クラスタ10の学生は途中で講義を放棄してしまった学生である。そのため、授業中盤以降の講義への出席、課題の提出はされていなく、最終課題の提出もされていない。3.4.1 項において示されたように、落第候補者を早い段階で予測することができるので授業中盤以前のタイミングにおいて学習指導を行うことができれば、学習状況の改善が行えるだろう。

以上のことから、ニューラルネットワークから得られた成績予測の結果を基にクラスタリングを行うことで、生成された各クラスタにおいて授業への出席、課題の提出、課題の質の3点について学習指導が行えるという期待を持つことができた。

今後は成績未知の学生に対しニューラルネットワークを用いて成績予測をし、予測結果をクラスタにマッチングさせることで、検討した学習指導が適切なものであるかを検証したい。

## 第5章 むすび

本研究では、ニューラルネットワークに過去の学生の出席データ、課題の提出データを学習させることで成績予測を行い、評価実験を行うことで、成績予測の手段としての有効性を検証した。結果として、授業中盤の時点で、学習データとして用いた学生 102 人の約半数の学生の成績を正確に的中させることができた。1 ランク違いを含めた的中率は 70 %、2 ランク違いを含めた的中率は 90 % を超え、成績予測の結果は大きく外れていなかったことから、大まかな成績予測が可能であると言える。正確に的中させることのできた学生のうち、単位を取得できない成績 (成績 X) の学生の的中率は 90 % を超えており、落第候補者を高い精度で発見することができる。更に、そのような学生は講義 4 回目以降の早い段階で検出することが可能であることが示された。これにより、落第候補者の早期発見が可能になることを期待することができる。

そして、成績予測の結果の推移をクラスタリングすることで、学生の学習の傾向をある程度把握することができ、それを基に学生に対し簡単な学習指導を行うことが可能であるという方向性を見出した。

本研究において、ニューラルネットワークが成績予測の手段において有効であることが示されたが、各検証を行うにあたって使用した学生のデータはある 1 つの講義で得られたデータのみである。ニューラルネットワークがパターン学習において、強力な力を発揮するという特性を持つことを考慮すれば、他の講義においてもニューラルネットワークによる成績予測が十分可能であることが考えられる。しかし、その有効性を更に確実なものとするために、今後はその他の講義においても実験を行い、成績予測に適用できるのかを検証していきたい。

また、評価実験において、ネットワークに学習させるパターンが不足していて検出できていない学生が存在していた。3.3.2 項においても述べたように、学習させるデータ数を増やし、更に学習させるパターンを増やすことでの的中率を上げることが可能であると考えられる。本研究での実験では学習させることのできた学生データは 2008 年度、2009 年度の 2 年分であったが、今後は 2010 年度の学生データを得ることができるので、それをを用いての実験を検討している。

ニューラルネットワークを用いることによって、成績予測やその結果を用いた学習指導は Web 上で実施できることが期待できる。しかし、ニューラルネットワークから得られた結果をそのまま発信することは情報を押しつける形になり、学生の学習意欲の低下につながり、指導が逆効果になってしまうことが考えられる。そのような点を考慮した場合に、学生にどのように適切な情報を伝達するかを検討していくことが今後の課題として挙げられる。

先述した検証すべき点に対しては実験を行い、課題となっている点に対して改善を施していくことにより、将来的には優秀な学生に対しては更に学力を伸ばすことができるような、落第候補者に対しては適切なケアが行えるような環境を構築していきたい。

## 謝辞

本研究を進めるにあたり、日頃から多大な御尽力を頂き、御指導を賜りました名古屋工業大学 舟橋健司 准教授、伊藤宏隆 助教、山本大介 助教に深く感謝申し上げます。

また、本研究の実験のためのデータの提供元である、出欠システム及びコースマネジメントシステムの開発に尽力されました、名古屋工業大学情報基盤センター長 松尾啓志 教授、内匠逸 教授、情報基盤センター教職員の皆様に心から感謝いたします。

そして、本研究に対し御討論、御強力いただきました中村研究室の皆様ならびに中部大学岩堀研究室の皆様に深く感謝いたします。

最後に、舟橋研究室のゼミにおいて舟橋研究室諸氏に多大な助言をいただきました。この場でお礼申し上げます。

## 参考文献

- [1] 伊藤宏隆, 舟橋健司, 中野智文, 内匠逸, 松尾啓志, 大貫徹, “名古屋工業大学における Moodle の構築と運用”, メディア教育研究,4,2, pp.15-21, 2008.
- [2] 堀江匠, 舟橋健司, 伊藤宏隆, “データマイニングによる学生の修学傾向分析とその修学指導への適用有効性の検証”, 平成 20 年度名古屋工業大学卒業研究論文, 2008.
- [3] 伊藤宏隆, 舟橋健司, 内匠逸, 松尾啓志, “IC カード出欠データと CMS 学習データを用いたデータマイニング”, メディア教育研究,4,2, pp.15-21, 2008.
- [4] マイケル J.A. ベリー, ゴードン S. リノフ, “データマイニングの手法 営業, マーケティング, CRM のための顧客分析 (第 2 訂版)”, 海文堂, pp.161-212, 2008-2.
- [5] 堀田創, 野澤貴, 萩原将文, “ニューラルネットワークを用いた位置情報に基づくインターネット広告配信システム”, 知能と情報 (日本知能情報ファジィ学会誌) 20,3, pp.347-356,1970.
- [6] SBI ネットシステムズ株式会社 「M-NEXTe」  
[http://sbins.co.jp/pdf/press/2007/press\\_20070709.pdf](http://sbins.co.jp/pdf/press/2007/press_20070709.pdf)
- [7] 加藤直樹, 羽室行信, 矢田勝俊, “データマイニングとその応用”, 朝倉書店,4,2, pp.138-142,2010-3.
- [8] 元田浩, 津本周作, 山口高平, 沼尾正行, “データマイニングの基礎”, オーム社, pp.78-82, 2006-1.
- [9] 伊藤宏隆, 舟橋健司, 山本大介, 内匠逸, 松尾啓志, 斎藤彰一, “過去の学習データに基づく成績予測による教育指導の実践”, 私立大学情報教育協会論文誌 ICT 活用教育方法研究, Vol13, No.1, pp41-45, 2010.11
- [10] Weka  
<http://www.cs.waikato.ac.nz/ml/weka/>