

ひったくり危険度予測システムの研究と試作

—ニューラルネットワークを用いて—

2007MI046 平川瑛一 2007MI051 菱田健斗

指導教員：鈴木敦夫

1 はじめに

本研究では、愛知県名古屋市の中心部である中区に焦点を当て、11ある各小学校区（名城小学校区、御園小学校区、栄小学校区、大須小学校区、新栄小学校区、老松小学校区、千早小学校区、松原小学校区、橋小学校区、平和小学校区、正木小学校区）でのひったくり危険度をニューラルネットワークを用いて予測するシステムを試作する。

[1]によると、愛知県におけるひったくりは平成17年には認知件数3000件を超えていた。翌年以降約1500件と半減しているものの、他県と比較し平成21年全国ワースト7位と依然として多いのが現状である。

ひったくり予防策の1つとして各地域を巡回して警戒に当たるパトロールが挙げられ、過去の研究[2]ではそのパトロールに着目し、名古屋市におけるひったくりを未然に防ぐための最適巡回ルート設定が研究されている。しかしパトロールでは巡回できる地域や時間、割り当てることができる車両や警察官の人員数に限界があり、またパトロール巡回地域以外でひったくりが行われる危険性がある。そのため私たちは、警察のひったくり予防策だけではひったくりを減少させるには限界があり、地域住民自身のひったくり危機意識向上こそがひったくりを減らす最も有効な方法であると考えた。また、ひったくりなどの犯罪に対する地域住民の危機意識向上は警察の課題でもある。

そこで、本研究では地域住民のひったくり危機意識向上に焦点を当て研究を行う。

私たちは、地域住民のひったくり危機意識を向上させるためにはいつ、どこで、どのような状況の時にひったくりが発生する危険性が高いかを知らせることが効率のよい方法であると考えた。地域住民がそれぞれの状況に応じたひったくり危険度を予測、把握できるようなシステムを作成することができれば、パトロール巡回ルートだけでなく、地域全体のひったくり減少を実現することができるだろう。

地域住民にとってパトロールなど警察が行う予防策は受動的予防策であり、地域住民が自ら行うひったくり危険度予測は能動的予防策である。ひったくり危険度予測を通じ地域住民が自身でひったくりの予防策を講じるといったように犯罪予防に対し少しでも意識を向けるようになれば、ひったくり以外の犯罪の減少にもつながるのではないだろうか。

2 使用するデータについて

本研究では、過去の研究[2]において愛知県警察より提供された名古屋市のひったくり発生件数が多い6区（千種区、東区、北区、西区、中村区、中区）における2004年～2007年のひったくり発生場所、既遂または未遂、発

生日時、発生場所の区分、被害者の性別、被害者の年齢、被害者の職業、被害者の形態、被害総額、現金被害額、被疑者の形態のひったくり発生状況データから中区のデータを抽出し使用する。ただし、中区におけるひったくり発生状況データは2004年～2006年の3年間分のデータであった。同様に過去の研究[2]において気象庁ホームページから取得された4年間分の天気、気温、降水量、風速のデータを使用する。また、本研究では新たに名古屋市ホームページ[8]より中区の小学校区別人口、性別、年齢のデータを取得した。

これらのデータは、中区のひったくり発生状況データと対応させると共に、各小学校区でのひったくり危険度を予測できるようにデータを整理して使用する。

3 ニューラルネットワーク

3.1 ニューラルネットワークとは

人間の生体神経回路網の情報伝達方式を数理的にモデル化したものをニューラルネットワークと呼ぶ。

生体神経回路網は多数のニューロンで構成され、ニューラルネットワークはこのニューロンに数値伝達を制御するしきい値と出力関数を与え形式的に表し、それらが相互に結合することによって構成される。また、ニューロン間の結合関係上は結合荷重が与えられ、これにより数値のやり取りにある程度の重みが付加される。

また、ニューラルネットワークには主に同一方向にのみ数値伝達を許す階層結合型と、任意のニューロン間の数値伝達を許す相互結合型がある。

さらに、ニューラルネットワークは学習という機能を持つ。人間が何度も同じような間違った行動を繰り返すことで段々と正しい行動をし、未経験の事態にも正しい行動を行えるようになるのと同様に、ニューラルネットワークにも多数のデータを学習し記憶させていくことで未知のデータにも正しい判断が行えるようにすることができる。正しい判断が行えるようにすることは、ある入力値を与えたとき、最終的にこれに対応する正しい出力値（教師信号）を得るような結合加重・しきい値を決めることと等しい。また学習には教師信号ありとなしが存在し、前者の代表的な学習法にBP法がある（3.1は[3][6]参照）

3.2 BP法とは

BP法とは、ある値をニューラルネットワークに入力したとき、この出力値と教師信号との間に誤差が発生した場合にその誤差情報を下層ニューロンに伝達すると共に結合加重・しきい値の修正を繰り返し、誤差が無くなるあるいは最小になるまでこの流れを繰り返す学習法である（[9]参照）

4 ひったくり危険度予測システムの試作

4.1 教師データの作成

本研究では、ニューラルネットワークにおける入力値とそれに対応する教師信号を合わせたデータを教師データと呼ぶ。

教師データは 2.1 で取得したデータの中から気象データとして地域、時間、天気、気温を、個人データとして地域、人口、性別、年齢を抽出し、これらのデータから作成する。また教師データの入力値は、地域を各小学校区の 11 分割、時間を 0~3 時、4~7 時、8~11 時、12~15 時、16~19 時、20~23 時の 6 分割、天気を晴れ、曇、雨・その他の 3 分割、気温を ~9.9、10~19.9、20~29.9、30~ の 4 分割、性別を女性、男性の 2 分割、年齢を ~19 歳、20~29 歳、30~39 歳、40~49 歳、50~59 歳、60~ 歳の 6 分割とし、その分割域に当てはまれば 1、そうでなければ 0 というダミー変数を導入しすべての状況を列挙したのから作成される。すなわち教師データは、気象データに対し $11 \times 6 \times 3 \times 4 = 792$ 通り (個)、個人データに対し $11 \times 2 \times 6 = 132$ 通り (個) となり、その入力値はそれぞれ $11 + 6 + 3 + 4 = 24$ 個、 $11 + 2 + 6 = 19$ 個となる。

次に、教師信号であるひったくり危険度として以下のようにひったくり発生件数と発生確率を設定する。

● ひったくり発生件数

母集団として、気象データに対し過去 3 年間の気象状況を、個人データに対し中区の小学校区別人口を設定する。それぞれこの中から教師データと同じ状況の時間、人口 (例えば個人データに対し「栄小学校区、女性、20~29 歳」の人口) を抽出し、これによりひったくり発生件数を以下のように算出する。

記号の定義

C : 状況の添え字集合

n_c : 母集団内の状況 c の数 ($c \in C$)

x_c : 過去 3 年間の状況 c でのひったくり発生件数 ($c \in C$)

y_c : 状況 c でのひったくり発生件数 ($c \in C$)

モデル化

$$y_c = \frac{x_c}{n_c}$$

● ひったくり発生確率

過去 3 年間の各ひったくり発生状況の潜在的な危険性を考慮し、気象データ、個人データに対し [7] を参考にベイズの定理を拡張しひったくり発生確率を以下のように算出する。ここで言う状況とは、教師データ作成時に分割した各データ 1 つ 1 つ (例えば「0~3 時」や「女性」というデータ) のことを指す。

記号の定義

A : 小学校区の添え字集合

C : 状況の添え字集合

d_c : 状況 c のダミー変数値 (0 or 1) ($c \in C$)

$P(a)$: 小学校区 a でひったくりが発生する確率 ($a \in A$)

$P(c|a)$: 小学校区 a で

状況 c が発生する確率 ($a \in A, c \in C$)

$P(a|d_1, \dots, d_c)$: 状況 c の各ダミー変数値が

d_1, \dots, d_c をとる時

小学校区 a でひったくりが発生する確率
($a \in A, c \in C$)

モデル化

$$P(a|d_1, \dots, d_c) = \frac{P(a) \cdot \prod_{c \in C} [d_c P(c|a) + (1 - d_c)\{1 - P(c|a)\}]}{\sum_{a \in A} P(a) \cdot \prod_{c \in C} [d_c P(c|a) + (1 - d_c)\{1 - P(c|a)\}]}$$

4.2 ニューラルネットワークの構築方法

本研究では、慣性項付き逐次修正法による 3 階層結合型ニューラルネットワークを用いる。

各入力層ニューロンは入力値をそのまま出力し、各中間層、出力層ニューロンはしきい値と出力関数としてシグモイド関数 $f(u) = \frac{1}{1+e^{-u}}$ を持つ。ただし、以下ではしきい値をバイアスと呼び、バイアスは常に 1 を出力するニューロンからある結合加重をもって数値を伝達する役割を持つ。

ここで、学習において各教師データによる学習を「小域的」学習とする。逐次修正法とは「小域的」学習 1 回ごとに結合加重・バイアスの修正を行う学習法であり、慣性項とは、前回の結合加重・バイアスの修正量に安定化定数を掛け再使用することにより「小域的」学習の振動を抑え、通常の逐次修正法に比べ学習を高速化することができるパラメータである。また、1 回の学習内の各「小域的」学習に使用される教師データは上位のものから順番にすべて別のものを使用し、1 回の学習における「小域的」学習回数はその教師データ数と等しい。

さらに、4.1 で作成した教師データから気象データ、個人データに対しそれぞれ 33 個、11 個をテストデータとして抽出しニューラルネットワークの予測精度判定に使用し、これを省いたものを学習に使用する。また、教師信号としてひったくり発生件数と発生確率を設定し、気象データ、個人データに対しそれぞれ 24 個、19 個の入力値からひったくり発生件数、発生確率を出力する計 4 つのニューラルネットワークを Excel を用い構築する。

中間層ニューロン数は 4.3 において決定し、以下に学習アルゴリズムを示す。また、ここでは最初に誤差情報が到達する中間層ニューロン・出力層ニューロン間結合加重と出力層ニューロンバイアスの修正手順を示す。

記号の定義

H : 中間層ニューロンの添え字集合

O : 出力層ニューロンの添え字集合

C : 学習に使用する教師データの添え字集合

T : 学習回数

$E_c(t)$: 学習 t における教師データ c に対する誤差

($c \in C, t = 1, 2, \dots, T$)

$y_{hc}(t)$: 学習 t における教師データ c に対する

中間層ニューロン h の出力値

($h \in H, c \in C, t = 1, 2, \dots, T$)

$z_{oc}(t)$: 学習 t における教師データ c に対する

出力層ニューロン o の出力値

($o \in O, c \in C, t = 1, 2, \dots, T$)

$k_{oc}(t)$: 学習 t における教師データ c に対する

出力層ニューロン o の教師信号

$$(o \in O, c \in C, t = 1, 2, \dots, T)$$

$w_{ho}(t)$: 学習 t における中間層ニューロン h と

出力層ニューロン o の結合加重

$$(h \in H, o \in O, t = 1, 2, \dots, T)$$

$bw_o(t)$: 学習 t における出力層ニューロン o のバイアス

$$(o \in O, t = 1, 2, \dots, T)$$

$dw_{ho}(t)$: 学習 t における中間層ニューロン h と

出力層ニューロン o の結合加重の修正量

$$(h \in H, o \in O, t = 1, 2, \dots, T)$$

$dbw_o(t)$: 学習 t における出力層ニューロン o の

バイアスの修正量 $(o \in O, t = 1, 2, \dots, T)$

$\delta_{oc}(t)$: 学習 t における教師データ c に対する

出力層ニューロン o から各中間層ニューロン,

出力層ニューロンバイアスへの学習信号

$$(o \in O, c \in C, t = 1, 2, \dots, T)$$

η : 学習定数

α : 安定化定数

学習アルゴリズム

Step.1 結合加重・バイアスと修正量の初期値設定

$t := 1$ とし, 結合荷重・バイアスの初期値として $w_{ho}(t)$, $bw_o(t)$ には $0 \sim 1$ の乱数を, またこれらの修正量の初期値として $dw_{ho}(t) := 0$, $dbw_o(t) := 0$ を設定する.

Step.2 教師データの選択

「小域的」学習に使用する教師データ c を選択する.

Step.3 誤差の計算

教師データ c に対する出力層ニューロン o の出力値 $z_{oc}(t)$ と教師信号 $k_{oc}(t)$ との誤差を以下のように算出する.

$$E_c(t) = \frac{1}{2} \sum_{o \in O} \{k_{oc}(t) - z_{oc}(t)\}^2$$

Step.4 結合加重・バイアスの修正

BP 法による学習は, 最急降下法により $E_c(t)$ を最小にする結合加重・バイアスを求めるということである. よって, 誤差情報を上層ニューロンから下層ニューロンへと伝達し, その情報から得られた学習信号をもとに結合加重・バイアスの修正量 $dw_{ho}(t)$, $dbw_o(t)$ を算出し修正値 $w_{ho}(t)$, $bw_o(t)$ を決定していく.

最急降下法で $E_c(t)$ の勾配を求め, エネルギー減少方向を考慮したとき結合加重・バイアスの修正量は学習定数を掛け以下ようになる.

$$-\eta \frac{\partial E_c(t)}{\partial w_{ho}(t)} = \eta \{k_{oc}(t) - z_{oc}(t)\} z_{oc}(t) \{1 - z_{oc}(t)\} y_{hc}(t)$$

ここで, 出力層ニューロンからの学習信号を以下のように設定する.

$$\delta_{oc}(t) = \{k_{oc}(t) - z_{oc}(t)\} z_{oc}(t) \{1 - z_{oc}(t)\}$$

よって以上より, 学習の高速化を図るために慣性項を付加すると, 結合荷重・バイアスの修正量と修正値は以下ようになる.

$$dw_{ho}(t) := \eta \delta_{oc}(t) y_{hc}(t) + \alpha dw_{ho}(t)$$

$$dbw_o(t) := \eta \delta_{oc}(t) + \alpha dbw_o(t)$$

$$w_{ho}(t) := w_{ho}(t) + dw_{ho}(t)$$

$$bw_o(t) := bw_o(t) + dbw_o(t)$$

未学習の教師データがあるならば Step.2 へ移行する.
全ての教師データが学習済みならば Step.5 へ移行する.

Step.5 ニューラルネットワークの学習終了判定

学習の終了は, あらかじめ与えられた学習回数と誤差の収束を以て判定される. 誤差の収束は, Step.4 により確定した結合加重・バイアスから算出される以下の誤差を基準とする.

$$\sum_{c \in C} E_c(t)$$

$t \neq T$ ならば結合荷重・バイアスの修正量と修正値を以下のようにし, $t := t + 1$ とし Step.2 へ移行する.

$$dw_{ho}(t+1) := dw_{ho}(t)$$

$$dbw_o(t+1) := dbw_o(t)$$

$$w_{ho}(t+1) := w_{ho}(t)$$

$$bw_o(t+1) := bw_o(t)$$

$t = T$ ならばすべての結合荷重・バイアスと学習の最終誤差が確定する.

なお, 入力層ニューロン・中間層ニューロン間結合荷重と中間層ニューロンバイアスの修正は同様の手順で行う. (4.2 は [4][5][6][9] 参照)

4.3 ニューラルネットワークの予測精度判定

ニューラルネットワークの予測精度には中間層ニューロン数や学習回数が大きく関係する. 中間層ニューロン数が少なすぎると入力値の特徴がうまく反映されず, 逆に多すぎると学習に時間がかかり, 余計なノイズまで学習してしまう. また学習回数に関しては, あまり多く取ってしまうと学習に使用する教師データの特徴にとらわれすぎて未知のデータに対する融通が利かなくなる過学習が起こり, ニューラルネットワークの汎用性が失われてしまう ([3] 参照)

そこで, 4.2 で抽出したテストデータをニューラルネットワークに入力し, 出力値と実際値との誤差をもとに予測精度を判定し, 最適な中間層ニューロン数と学習回数を試行錯誤的に探索し選定する. 判定は, 学習終了時の最終誤差から以下のように算出される学習に使用した教師データ 1 つずつの誤差の換算値を基準とする.

$$\sqrt{\sum_{c \in C} E_c(T) / N \times 2}$$

記号の定義は 4.2 を参照, N は学習に使用した教師データ数とする. テストデータに対する誤差がこの基準値未満なら正解, 以上なら不正解とし, テストデータ中いくつか正解できるかを調べる. すべての学習において学習定数 $\eta = 0.9$, 安定化定数 $\alpha = 0.6$ とした.

その結果, 中間層ニューロン数と学習回数を増やすほど, 最終誤差は小さくなるが過学習を起こしやすいこと

がわかった．なお，結合荷重・バイアスの初期値は乱数を使用するため結果に違いが発生するが，どの学習においても同じような結果となる．

表 1 は，選定された中間層ニューロン数，学習回数とその時のある学習における最終誤差，正解率を示したものである．

表 1 予測精度

	気象データ		個人データ	
	発生件数	発生確率	発生件数	発生確率
中間層ニューロン数	5	9	8	7
学習回数	1500	1700	300	100
最終誤差	0.099499	0.257865	0.01081	0.127934
正解率	30/33	25/33	9/11	9/11

これより，ダミー変数による情報の欠損があるにもかかわらず，高い予測精度を示した．

ここで，ニューラルネットワークと同様に多数のデータからそれに対応するデータを予測することができる重回帰分析を行い，ニューラルネットワークの学習時と同様の教師データを使用したとき，その入力値で教師信号をどの程度説明できるか分析を行う．分析に使用する教師データの入力値を説明変数，教師信号を目的変数としたとき，分析結果 R^2 (自由度調整済み決定係数) を表 2 に示す．

表 2 R^2

気象データ		個人データ	
発生件数	発生確率	発生件数	発生確率
0.04491	0.07069	0.4399	0.4281

これより， R^2 が低くなるためこれらの教師データは重回帰分析には適さないことがわかる．また，ニューラルネットワークでは学習済みのデータだけでなく未学習のデータに対しても高い精度で予測することができるため，重回帰分析を用いるよりも高い予測精度と汎用性を持つシステムを試作することができ，ニューラルネットワークを用いる必要性を再確認することができた．

4.4 ひたたくり危険度予測システム GUI の実現

4.1～4.3 において，ひたたくり危険度予測システムに用いるニューラルネットワークの構築方法を決定した．これにもとづいて，ニューラルネットワークの学習，構築から予測を行うひたたくり危険度予測システム GUI を図 1 のように Excel 上のマウス操作のみで利用できるよう実現した．使用 방법은以下のようにになっている．

- 1) 初期化ボタンを押す
- 2) 学区，気象データ，個人データの各枠の中において当てはまる状況を選択し，ボックスにチェックを入れる
- 3) 下の 4 つの枠の中から知りたい情報を選び，学習ボタンを押して計算が終わるまで待つ
- 4) 予測ボタンを押す

なお，図 1 は名城小学校区，0～3 時，晴れ，～9.9℃，女性，30～39 歳という状況時の出力画面である．この状

況では，気象データに対して約 0.06 件のひたたくりが約 30% の確率で，また個人データに対して約 0.02 件のひたたくりが約 12% の確率で発生するという予測結果となっている．

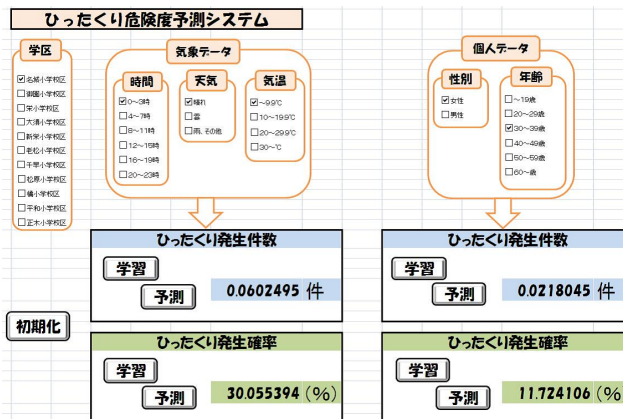


図 1 ひたたくり危険度予測システム GUI

5 おわりに

本研究では，子供やお年寄りでも簡単にマウス操作のみで利用することができるようなシステムを試作することができた．しかし，より細かい地域や状況でのひたたくり危険度予測を可能にする必要性があると感じた．これを実現するためにはさらに多くのデータが必要となり，それらのデータは警察や地方自治体の方々の協力なくして手に入れることはできない．よって，今後は警察や地方自治体の方々と関係を更に密にして様々な尺度でひたたくり危険度予測を行ってもよいと考える．

参考文献

- [1] 愛知県警察ホームページ
<http://www.pref.aichi.jp/police/>
- [2] 青木ひと美，高木大輔：名古屋市におけるパトロールの最適巡回路，南山大学数理情報学部数理科学科卒業論文，2008
- [3] Bahman Kermanshahi：ニューラルネットワークの設計と応用，昭晃堂，東京，1999.
- [4] 平野廣美：C でつくるニューラルネットワーク，パーソナルメディア，東京，1991.
- [5] 階層型神経回路網の基本プログラム
<http://www.eva.ie.u-ryukyu.ac.jp/~tnal/Job/NN/basic/>
- [6] 小杉幸夫：神経回路システム — 基礎と応用 —，コロナ社，東京，1995.
- [7] 松原望：入門ベイズ統計 — 意思決定の理論と発展 —，東京図書，東京，2008.
- [8] 名古屋市公式ウェブサイト
<http://www.city.nagoya.jp/>
- [9] 臼井支朗，岩田彰，久間和生，浅川和雄 編著：基礎と実践 ニューラルネットワーク，コロナ社，東京，1995.