

ファジィ多層パーセプトロンによる  
3次元都市データモデル生成システムに関する研究  
3D City Modeler with Fuzzy Multiple Layers Perceptron

小林 佳弘\*、渡辺 俊\*\*  
Yoshihiro KOBAYASHI and Shun WATANABE

A computer aided design (CAD) system that can store the design knowledge of users is proposed. Specifically, a computer system for generating 3D city models from satellite images is formulated, implemented and tested. Techniques from neural networks, fuzzy systems, image processing, pattern recognition, and machine learning constitute the methodological foundation of the system. The flexibility and usability of system are evaluated.

**Keywords** : Computer Aided Design, Soft Computing, Neural networks, Fuzzy Systems, Image Processing, Artificial Intelligence  
CADシステム、ソフトコンピューティング、ニューラルネットワーク、ファジィシステム、画像処理、人工知能、

## 1. はじめに

近年、建築・都市計画におけるコンピュータ利用は急速に発展しており、さまざまな局面においてその利用形態は複雑になってきている。例えば、設計初期段階において設計者を支援するシステム、3次元CADシステムによるエスキース、図面作業の効率化、構造計算、見積もり積算、シミュレーション、ビジュアライゼーション、協調設計などが挙げられる。建築・都市計画という分野は実践的な需要が多いことから、それらのシステムはより多様な要求に、迅速に答えるものが必要とされてきた。その為、エキスパートシステムやオブジェクト指向などにみられるように、出来るだけ多くの機能をシステムに埋め込みさえすれば、よりよいシステムが実現できると思われてきた。結果、数学的に記述できる知識や、百科事典的に事実の集合として記述できる知識をシステムの中で利用できるようにはなったが、人間の概念的に事象を認識・把握するような認知的な知識はこれらのシステムからは排除されてきた。しかし、設計行為とは、すべての人と共有できる知識（数学的、百科事典的知識）と設計者自らの経験等に基づいた知識（人間的知識）によって実現されるものである。よって、今後はユーザの個性や好みに応じて適応していくようなシステムの開発に期待がよせられている<sup>\*)</sup>。

本研究の目的は、デザイン行為における人間的知識（デザイン知識）を蓄積・再利用できるシステムの提案とその実現である。ここ

でいうデザイン知識とは、ユーザに与えられた状況とその状況下においてユーザが選択したシステム機能との関係付けと定義する。本研究では、そのような知識を利用できるシステム実現への第一歩として、航空写真から3次元都市データを自動（半自動）生成できるシステムを開発した。

ケーススタディにおいて、まったく異なる種類の画像と複数の類似した画像を用いた実行例を紹介し、どの程度システムが適応・順応できるかを示す。

## 2. 背景

### 2-1 問題

今日、建築・都市計画分野で利用されるコンピュータシステムは多種多様な目的に対し複雑な作業が可能となったが、まだ多くの問題を含んでいる。例えば、

- システムの複雑化に伴い、インターフェイスも複雑になり、ユーザの学習の負担が大きくなった。
- 以前に行った行為が、類似したケースに適応できずに、何度も同様の作業の繰り返しを求められる。
- 全く異なる状況に対応できるような内部ルールの変更がユーザに許されていない。

などが挙げられる。

\* アリゾナ州立大学建築環境学部 Assistant Prof.・Ph.D.

\*\* 筑波大学社会工学系 助教授・工博

Assistant Prof., College of Architecture and Environmental Design, Arizona State Univ., Ph.D. in Architecture  
Associate Prof., Inst. of Policy and Planning Sciences, Univ. of Tsukuba, Dr. Eng.

これらの問題の主な原因は、デザイン知識の蓄積・記述・再利用の方法が確立されていないため、問題解決するための道具としての機能（数学的関数）だけを用意して、どのような機能を個々の問題に当てはめるかはユーザの経験と知識に委ねているためである。

## 2-2 動機

コンピュータによる人間的な認識能力の実現は、人工知能研究の大きな課題のひとつである。現在、多くの人工知能研究者の間でニューラルネットワーク、ファジィシステム、遺伝的アルゴリズムなどの技術の統合によって問題解決をするような研究開発が行われている。特に画像理解、言語・音声理解の分野の研究がさかんに行われているが、未だ人間と同レベルの能力を持つまでには至っていない。本研究の延長線上にある最終的な目標は、そのような人工知能技術を利用した上で、建築・都市計画といった分野の設計者が、自らのデザイン知識をコンピュータ上で実現可能にすることである。

第1ステップとして、航空写真を使った3次元都市データの生成システムの構築を試みた。ここでは従来の画像認識の研究のような状況下においても最適に行動するシステムを構築するのではなく、ユーザの主観によって与えられた状況とその状況下においてユーザが選択した数学的関数との関連が柔軟に変化するシステムの構築を意図する。

その理由としては、画像から建物データを生成するためにユーザが選択した関数との関連を知識と見立てた上で、システムが異なる状況下にも、また類似したケースにも柔軟に適応でき、しかもそこで蓄積されたルールが再利用できれば、人間的知識を蓄積・記述・再利用することのできるシステムの開発に貢献できると考えたからである。

また現在、建築・都市計画の分野においては3次元都市データの役割は非常に大きく、多くの研究分野で高速かつ目的にあった詳細度で3次元データを生成してくれるようなシステムを必要としているが、現状は市販の3次元ソフトによって航空写真から建物をひとつひとつ手作業で生成するに留まっている。もしここで紹介するような新たな3次元都市データの生成システムが実現すれば、このような手作業での時間と労力を費やす必要がなくなる。

具体的には、航空写真から建物の領域を抽出した後、抽出された領域を整形し、高さ情報を与えることによって3次元のオブジェクト群（3次元都市データ）を発生させる。特にニューラルネットワークの学習機能を用いることによって、ユーザが各自で抽出・整形のルールを変更できるような柔軟性の実現を試みた。

## 2-3 関連分野

本システムの実現には、主に2つの研究分野が深く関わっている。

ひとつはコンピュータの画像理解による航空衛星写真からの人工物検出という研究分野である。この分野においてはコンピュータの処理能力が発展した1980年代頃からさかんに研究開発がはじまった。当初は基本的な2値画像処理に幾何分析を用いた研究が多かった<sup>文2-5)</sup>。後に影やエッジコーナーから建物領域の形状解析の手法<sup>文6-8)</sup>などが提案され、最近では巨大なデータベースとエキスパートシステムを用いて建物の3次元構造を解析する方法<sup>文9-10)</sup>が研究開発されてきている。

もう一つの関連分野としては、人工知能研究によるニューラルネットワークとファジィシステムを融合利用したソフトコンピューティング<sup>文18)</sup>が挙げられる。これはニューラルネットワークの学習機能と、ファジィシステムの柔軟なルール表現の両方を適用することによって互いの欠点を補うために開発された。文献11)によると、主に1)ニューラルネットの枠組みにファジィを組み込んだもの<sup>文12)</sup>、2)ファジィ論理式にしたがってニューラルネットワークをデザインするもの<sup>文13)</sup>、3)ニューロンの性質そのものを変化させるもの<sup>文14)</sup>、4)ネットワークにおける誤差・不安定値にファジィ測度を用いるもの<sup>文15)</sup>、5)自立したファジィニューロンをモデル化するもの<sup>文16)</sup>、といった5つのタイプに分類される。

本研究では、基本的な画像理解の技術である、画素の分類・2値画像処理と、上で述べた1)のタイプに分類されるソフトコンピューティングのモデルのひとつであるファジィ多層パーセプトロン<sup>文12)</sup>を統合することによって、システムの実装を試みた。

## 3. 方法論

### 3-1 ファジィ多層パーセプトロン

ファジィ多層パーセプトロンは S. Pal 等によって開発されたソフトコンピューティングモデルのひとつである。これは階層型ニューラルネットワークの構造をもち、入出力にグレード（ファジィメンバーシップ値）を用いることによって、ニューラルネットワークにおける難問のひとつである「何を学習しているか」をファジィ If-then ルールとして検出できる。また学習には収束を早めるためにモーメント項を考慮したバックプロパゲーションを用いている。

### 3-2 ファジィ多層パーセプトロンの入力

ファジィ多層パーセプトロンにおける入力は、考慮される各々の属性値を3つのメンバーシップ {LOW, MID, HIGH} によって表現し、これを入力層に伝達する。4つの属性が与えられたときには、12の入力値をもつことになる。例えば、j番目の属性値  $F_j$  が与えられた時、その入力値は、

$$F_j = \{u_{low}(F_j), u_{mid}(F_j), u_{high}(F_j)\} \text{-----} (1)$$

として記述される。 $u_x(F)$  は入力値  $F$  に対する  $X$  属性のグレードであり、 $\pi$  関数を用いて計算される。 $\pi$  関数とは

$$\pi(r:c,\lambda) = \begin{cases} 2(1-\|r-c\|/\lambda)^2, & \text{for } \lambda/2 \leq \|r-c\| \leq \lambda \\ 1-2(\|r-c\|/\lambda)^2, & \text{for } 0 \leq \|r-c\| \leq \lambda/2 \\ 0, & \text{otherwise} \end{cases} \text{-----} (2)$$

のように定義されており、 $r$  は元の入力属性値、 $c$  は平均値、 $\lambda$  は領域幅を示す。上で述べた LOW, MID, HIGH それぞれのグレードを算出するための  $c$ ,  $\lambda$  は以下のように規定する。

$c_{mid}(F_j)$	＝すべてのサンプルに対する属性 $j$ の平均値
$c_{high}(F_j)$	＝属性 $j$ における $c_{mid}(F_j)$ 以上のサンプルの平均
$c_{low}(F_j)$	＝属性 $j$ における $c_{mid}(F_j)$ 以下のサンプルの平均
$F_j_{max}$	＝属性 $j$ の最大値
$F_j_{min}$	＝属性 $j$ の最小値

$$\lambda_{low}(F_j) = 2(c_{mid}(F_j) - c_{low}(F_j))$$

$$\lambda_{high}(F_j) = 2(c_{high}(F_j) - c_{mid}(F_j))$$

$$\lambda_{mid}(F_j) = \frac{\lambda_{low}(F_j) * (F_{j_{max}} - c_{mid}(F_j)) + \lambda_{high}(F_j) * (c_{mid}(F_j) - F_{j_{min}})}{F_{j_{max}} - F_{j_{min}}}$$

### 3-3 ファジィ多層パーセプトロンの出力

ファジィ多層パーセプトロンの出力は、用意された全てのクラス群へのグレードの集合として表現される。各々のグレードは、クラスの平均ベクトルへの距離によって算出される。そのベクトルの次元は入力に用いる属性の数と等しい。はじめにあるクラス  $k$  に分類されると期待されるサンプルのそれぞれの属性  $j$  の平均値と標準偏差を求める。求められた属性次元のベクトルをそれぞれ  $Mkj, Vkj$  とする。それらを用いて以下に定義されるサンプル  $i$  に対する荷重距離  $Zik$  を計算する。この荷重距離を用いて、 $i$  番目のサンプル  $Fi$  におけるクラス  $k$  に対するグレード  $u_k(Fi)$  を計算する。

$$Zik = \sqrt{\sum_{j=1}^n ((Fij - Mkj) / Vkj)^2} \quad (3)$$

$$u_k(Fi) = 1 / (1 + Zik / f_d)^{f_e} \quad (4)$$

上式における  $f_d, f_e$  はファジィ次元項、ファジィ対数項とよばれ、ファジィネスを決定するために用いられる。本プロジェクトにおいては、文献 11) に基づき、それぞれを  $f_d = 5, f_e = 1$  の定数とした。

ニューラルネットワークの学習の際に用いる期待される出力（教師信号）は、求められたグレードのなかで、ひとつのクラスのグレードのみを採用し、その他のクラスに対するグレードは 0.0 とした。例えば、分類されるクラスが 3 つある場合、上式から算出された入力  $Fi$  に対する出力が、(0.04, 0.75, 0.50) で、このサンプルがクラス 2 に分類されることが期待されるとすると、その教師信号は (0.0, 0.75, 0.00) である。

一方、学習後にニューラルネットワークが出力するものに関しては、最大のグレードをもつクラスに分類されるとした。(図 1)

### 3-4 ニューラルネットワークの荷重の更新

入力層から伝達されるニューロン間に関しては、最も基本的なシグモイド関数  $f(x) = 1 / (1 + \exp(-x))$  を採用し、ニューラルネットワ

ークの学習には、モーメント項を考慮したバックプロパゲーション

$$\Delta w_{ji}^h(t) = -\varepsilon \frac{\partial E}{\partial w_{ji}^h} + \alpha \Delta w_{ji}^h(t-1) \quad (5)$$

を用いた。上式において  $\Delta w_{ji}^h(t)$  は、階層  $h$  における  $i$  番目のニュー

ロンと階層  $h-1$  における  $j$  番目のニューロン間の荷重  $w_{ji}^h$  の  $t$  回

目の学習における増減値を示す。 $E$  は出力層から伝達されてきた値と入力層から伝達されたニューロンの出力値との最小二乗誤差である。

$\varepsilon$  は正数の学習率、 $\alpha$  は [0, 1] のモーメント変数と呼ばれ、それぞれ実数の集合として用意されたものを使用する。本研究では、

学習率 = {2, 1, 0.5, 0.3, 0.1, 0.05, 0.01, 0.005, 0.001}

モーメント変数 = {0.9, 0.5, 0.5, 0.5, 0.5, 0.5, 0.5, 0.5, 0.5}

とした。それぞれの値は、すべてのサンプルの学習終了時（1 エポック）に、平均二乗誤差 (Mse) とクロスエントロピー (Ce) が算出され、もしどちらか一方がある閾値よりも小さい時に、次の値へと更新される。今回は閾値として 0.0001 を採用した。更新が行えなくなった時（最後の項が更新された時）に、学習の終了とした。

$$Mse = \left( \sum_{F \in \text{SampleSet}} \sum_{j=1}^l (d_j - y_j^H)^2 \right) / (l * \text{SampleNumber}) \quad (6)$$

$$Ce = \frac{\left( \sum_{F \in \text{SampleSet}} \sum_{j=1}^l (-d_j * \ln(y_j^H) - (1 - d_j) * \ln(1 - y_j^H)) \right)}{(\ln(2) * l * \text{SampleNumber})} \quad (7)$$

上式で、 $d_j$  は出力層 (H) における  $j$  番目 (クラス  $j$ ) の期待される値であり、 $y_j^H$  は入力層から伝達されてきた値である。また、 $l$

は出力層のクラスの総数、 $\text{SampleNumber}$  は学習に用いたサンプルの総数を示す。

### 3-5 ファジィルール生成

ファジィ多層パーセプトロンによるファジィルールの検出は、ニューラルネットワークにおける荷重最大のパスを各々のサンプルに対して探すことである。つまり結果に大きな影響をあたえるような関係をニューラルネットワークの荷重行列から探し出すことと同値である。荷重最大パスの強度が十分な時のみ、ひとつのサンプルに対してひとつのファジィ If-then ルールが、システムの学習したル




図 1 ファジィ多層パーセプトロンの入出力

ールとして検出される。この荷重最大パスにおいて、入力層に連結された属性群から If 節を、出力層から then 節を導き出す。

まず、出力層における j 番目のニューロンの確信値を

$$bel_j^H = y_j^H - \sum_{i \neq j} y_i^H \quad (8)$$

から求め、これが 0 以上だった場合、この j 番目のニューロンに連結しているひとつ手前の層の出力値が 0.5 以上のニューロンの中で最大の荷重を持つものをそのニューロンの最大荷重  $wet_{i,k}$  とする。

$$y_i^h > 0.5, \wedge wet_{i,k} = \max[wet_{j,h+1} + w_{ij}^h] \quad (9)$$

このプロセスを入力層まで行い、最後に

$$\sum_i wet_{i,0} > 2 \sum_{i \neq i} wet_{i,0} \quad (10)$$

を満たす全ての入力層のニューロン i を求める。ここで求められたニューロンが、生成されるファジィ If-then ルールの If 節を形成し、はじめに求めた確信値とそのニューロンによって Then 節を形成する。確信値が [0.8-1.0] の場合、ファジィ修飾語は「かなり」になり、[0.6-0.8] では「およそ」、[0.4-0.6] は「少なくとも」、[0.1-0.4] は「あまり～ではない」、[0-0.1] では「認識できない」とした。

例えば、図 2 の場合、求められるルールは「もし F1 が中くらいでかつ F2 が大きいならば、およそ class3 に分類される」となる。




図 2 ルール生成の例題

## 4 システム

### 4-1 システムの概要

このシステムを用いて 3 次元都市データを生成するには 2 つのステージを経由する。それらは画像を画素の属性群によって分類するステージ（画素分類ステージ）と、分類された領域を形の属性群によって分類するステージ（領域整形ステージ）である。（図 3）

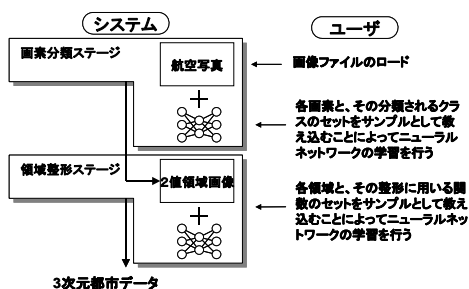


図 3 システムの概要

各々のステージにおいて、別々のニューラルネットワークを必要とし、それらの学習の精度をあげるために 2 つの学習プロセスを必要とする（訓練プロセスと修正プロセス）。訓練プロセスとはニューラルネットワークが何も学習していない段階で、入力とその入力に対して期待される出力をひとつのセットとしてシステムに教え込ませるプロセスである。修正プロセスとは、ある程度学習したニューラルネットワークをよりユーザの期待するものへと修正していくプロセスである。（図 4）

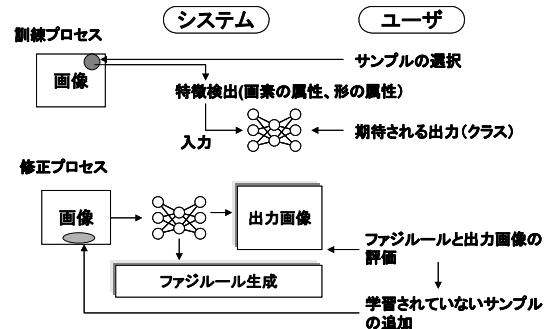


図 4 ニューラルネットワークの学習プロセス

本システムは Java 言語によってプログラムされている。サポートする画像としては、jpg と gif フォーマットの画像である。生成された 3 次元都市データは dxf ファイルとして保存される。

### 4-2 シナリオ

基本的なシステム利用の流れを紹介する。

まず、画素分類ステージにおいてユーザは採用した画像の中からひとつひとつ画素を選択し、その画素が分類されるべきクラスを指定する。ある程度サンプルを獲得した後で、それらのサンプル群からファジィ多層パーセプトロンへの入出力を計算し、学習させる。これが訓練プロセスである。

次に、この学習されたニューラルネットワークを用いて全ての画素に対しての分類が行われる。その結果があまりにもユーザの期待するものからかけ離れていた場合は、分類された結果の画像とニューラルネットワークから検出されるファジィ If-then ルールを調べる。そして、まだ学習されていないルール、あるいは間違っして学習されているルールを修正するために、それらを補うようなサンプルを加え直す。これが修正プロセスであり、これを繰り返すことによって十分に学習されたニューラルネットワークを作り出すのである。これらのプロセスはユーザの主観的な判断に委ねられている。

この画素分類ステージにおいて、いずれかのクラスに分類された全ての画素の中から、利用したいクラスの画素のみを抽出し、8 近傍において同じクラスに属しているものを連結することによって、領域群を生成させる。ここで生成された領域群は、小さなノイズや不自然な形のものを含んでおり、それらをユーザが期待するような形に整形する必要がある。それを第 2 の領域整形ステージで行う。

領域整形ステージでは、ユーザは生成された領域群の中からひとつひとつ領域を選択し、その領域に対してどういった整形関数を採用するかを指定する。そして訓練プロセスと修正プロセスに従いニューラルネットワークを十分学習させる。

次に、この学習されたニューラルネットワークは各々の領域に適用されるべき整形関数を導きだし、システムはその関数を使って2次元の整形された領域群を作りだす。これに高さ情報を与えることによって3次元の都市データが生成される。

上記2つのステージで学習されたニューラルネットワークは常にシステム内に保存される。これを用いることによって、類似した航空写真からは3次元都市データを自動生成させることが可能となる。もし類似した画像の中に学習していない状況がある場合は、修正プロセスによって、再び足りないルールを学習させる。ここで学習されたニューラルネットワークの荷重行列はテキストとして保存され、再度利用することも可能である。

## 5. ケーススタディ

今回は、サンプルの変化に伴うシステムの適応順応性を比較できるように、ニューラルネットワークの入出力の変数を同じものに設定した。

画素分類ステージにおいて入力として採用した画素の属性は、256段階の赤 (R)、緑 (G)、青 (B)、強度 (Gray) とし、5つのクラス (建物、道路、緑、グラウンド、影) に分類を試みた。

領域整形ステージにおいて入力して採用した属性は、横方向の最大画素数 (幅)、縦方向の最大画素数 (長さ)、領域の画素数 (面積)、幅を長さでわった比率 (比率) である。領域の整形には、その領域を消去する関数、幅と長さから長方形を生成する関数、領域の外郭から多角形を生成する関数の3つを用意した。

共にニューラルネットワークの構造は、10のニューロンから成るひとつの隠れ層をもつように設定した。

### 5-1 ドローイングのケース

はじめに、画像レタッチソフトによって描かれた簡単なドローイングを用いた事例を紹介する。

使用した画像は300x300画素である。画素分類ステージのニューラルネットワークの学習には30のサンプルを使用し、領域整形ステージの学習には、22のサンプルを使用した。

各段階で生成された画像を図5に示した。図5-a)は採用した元のドローイングである。学習後、サンプルの中でニューラルネットワークが正しい分類をした割合 (正当率) は100%で、生成されたファジィ If-then ルールの数は16であった。図5-b)は画素分類ステージにおいて学習されたニューラルネットワークを用いて、画像内の全ての画素を分類したときの結果である。図5-c)は得られた画素分類画像の中で「建物」と認識された画素のみを抽出した画像である。図5-d)は領域整形ステージにおいて学習されたニューラルネットワークを用いて、全ての領域に整形関数を適用した結果である。サンプルの中でニューラルネットワークが正しい関数を適応した割合 (正当率) は95.45%で、14のファジィ If-then ルールが生成された。図5-e)はd)の画像を基に生成された3次元都市データである。

### 5-2 航空写真のケース

次に、実際の航空写真を用いた例を示す。ここで使用した画像は市販のロスアンジェルス近郊の航空写真<sup>17)</sup> (図6-a)で、そのサ

イズは400x400画素である。サンプル数は画素分類ステージにおいては1000、領域整形ステージにおいては100とした。画素分類においては、学習後の正当率は81.05%、生成されたファジィルールは86、領域整形においては、正当率76.04%、生成されたルールは43であった。各々の段階での結果は図6に示されている。

### 5-3 類似した航空写真のケース

上で用いた航空写真と類似した画像として、2つの異なった地点の航空写真を適用した。図7は、修正プロセスを必要とせず、ケース5-2で学習したニューラルネットワークをそのまま使用した結果が示してある。一方、図8は、修正プロセスが必要であった例である。ケース5-2で学習したニューラルネットワークをそのまま使用した場合、入力画像 (図8-a)における右下のアパート群は建物とは認識されずグラウンドとして誤認された。(このアパート群の屋根はオレンジ色であるが、事前に学習したサンプルの中でオレンジ色の建物がなかったためである。)したがって、その屋根の部分を建物と (設定) する新たな20のサンプルを学習に加えた。その結果が図8-c)である。

## 6. 考察

まず、5-1に用いたような単純な色調の画像に対しては、ほぼ期待どおりの結果を得ることができた。

実際の航空写真を用いた5-2、3の場合は、色情報だけからでは正確には建物と分類できないようなものも多数存在した。我々は周りの庭や道路などの位置関係から建物であると類推できるが、今回のシステムはそのような機能をもっていないため、システムの検出した結果と我々の期待した結果の間には多少のずれがあった。ここでは、入力画像を目測した段階で容易に建物だと認識できるもの (明らかな建物) と、じっくり見なくては判断しにくいもの (曖昧な建物) を設定し、その中からシステムが検出できた数を評価の基準とした。図6-d、図7-d、図8-eはシステムが検出した建物であり、図6-e、図7-e、図8-fは主観的な目測による建物群を示している。濃度の暗い領域は明らかな建物を、濃度の薄い領域は曖昧な建物を示している。その結果は表1に示した。

表1 それぞれの航空写真における生成された建物の認知率

	明らかな建物	曖昧な建物	誤認した建物
図6	23/25 (92%)	6/37 (16.2%)	14
図7	28/29 (96.6%)	4/9 (44.4%)	8
図8	31/33 (93.9%)	28/48 (58.3%)	12

3つの航空写真において、明らかな建物の認知率の平均は94.2%であり、曖昧な建物は39.6%であった。以上から、明らかに認識可能な建物についてはかなり高い精度でシステムも認識できるが、曖昧な建物については、改良の余地があるといえる。

本プロジェクトの目的は、最適なニューラルネットワークの設定を探すことではなく、さまざまな種類の画像に適応できる3次元都市データ生成システムの構築にあるので、ニューラルネットワークにおける詳細な変数の調整による実験結果は割愛する。それら (隠

れ層の数、各々の隠れ層のニューロン数、サンプル数等)の変数は、1) 学習が終了するまでにかかったエポック数、2) サンプルの正当率、3) サンプルの自己組織化マップによるサンプルの分散、4) 出力された画像の目測による判断、から決定した<sup>文1)</sup>。

生成されたファジイルールについては、今回は出力された画像によってユーザが容易にニューラルネットワークに学習させられるものとさせられないものが判断できたので、その有効利用性は示せなかった。今後、出力からどのような要素間のルールによって出力が決定されたか判断しにくいものを扱った場合には、ファジイルールの必要性が大きくなると予想される。また今回生成されたファジィ If-then ルールは、その数が比較的多すぎたため、ルールの羅列からシステムがどのようなものを認識しているものを把握しにくいという側面もあった。

生成された3次元都市データ(図9)は、建物としてはやや精度が欠けていたが、広域な地域のおおよその3次元モデルが至急必要な場合、あるいは計画する土地の周囲の雰囲気を確認したい場合などには十分対応できるものであった。より精度の高い3次元都市データが必要な場合は、領域の整形に用いる関数の質と量を上げることが考えられる。

今研究では生成された3次元都市データにおける建物の高さは、あらかじめ用意された値を採用したが、今後は隣接する影領域の属性から建物の高さを推測する方法が思案される。本システムでは、ひとつの対象物(画素、領域)に対するいくつかの属性値から、分類されるクラスや関数を決定したため、建物領域と影領域といった異なるクラス間の関係を学習することはできない。しかし、実際人間が画像を認識する際には、周りの環境との関わりで判断することがほとんどである。そのような周りとの関係を学習できるようなシステムの開発を、今後の研究目標としたい。

## 7. おわりに

本研究において実現されたことには、以下のことが挙げられる。

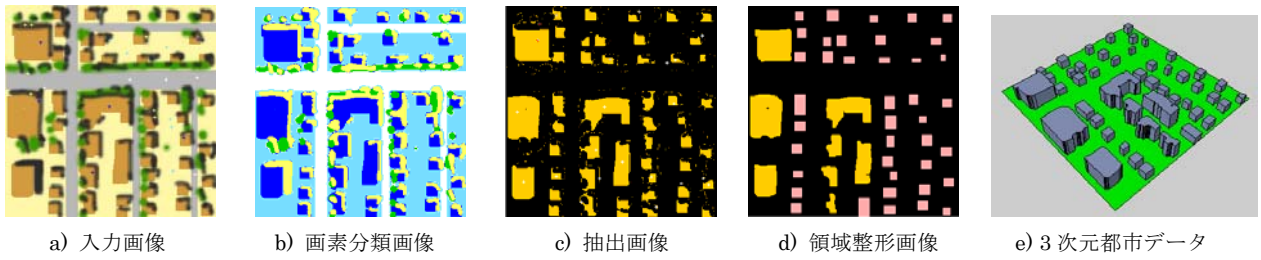
- 1) ファジィ多層パーセプトロンを用いることによって、ユーザが内部ルールを主観的に変更できるような3次元都市データ生成システムを実現した。
- 2) 本システムは、5-1と5-2で示されたように、全く異なる画像に対しても十分適応できるものであった。
- 3) また類似した画像から3次元都市データを作成することに対して、従来のようにはじめから建物をひとつひとつ入力する必要はなく、以前の学習したニューラルネットワークを用いさえすれば自動的に生成することが出来た。つまりユーザの主観的な選択と選択された事象に適用する関数の関係を蓄積することによって、人間的知識の再利用・再編が実現され、データ作成に要してきた時間と労力が改善された。

## 参考文献

- 1) Kobayashi, Y.: 3D City Modeler with Fuzzy Multiple Layer Perceptron, Dissertation, UCLA, Los Angeles, 2001
- 2) Connors, R. W., Trivedi, M. M., and Harlow, C. A.: Segmentation of a High-Resolution Urban Scene Using Texture Operators, Computer Vision, Graphics, and Image Processing,


Vol. 25, pp. 273-310, 1984

- 3) Harwood, D., Chang, S., and Davis, L.: Interpreting Aerial Photographs by Segmentation and Search, Proceedings of the DARPA Image Understanding Workshop, pp. 475-482, 1987. 2
- 4) Herman, M. and Kanade, T.: Incremental Reconstruction of 3D scenes from Multiple, Complex Images, Artificial Intelligence, Vol. 30, pp. 289-341, 1986
- 5) McKeown, D. M., and Denlinger, J. L.: Map-guided feature extraction from aerial imagery, Workshop on Computer Vision-Representation and Control, Annapolis, MD, pp. 205-213, 1984
- 6) McKeown, D. M.: Toward Automatic Cartographic Feature Extraction from Aerial Imagery, Mapping and Spatial Modeling for Navigation, Vol. F65, pp. 149-180, 1990
- 7) Huertas, A. and Nevatia, R.: Detecting Buildings in Aerial Images, Computer Vision, Graphics, and Image Processing, Vol. 41, pp. 131-152, 1988
- 8) Liow, Y. T. and Pavlidis, T.: Use of Shadow for Extracting Buildings in Aerial Images, Computer Vision, Graphics, and Image Processing, Vol. 49, pp. 242-277, 1990
- 9) Shufelt, J. A.: Projective Geometry and Photometry for Object Detection and Delineation Techniques, APRA Image Understanding Workshop, pp. 1113-1132, 1996. 2
- 10) Jaynes, C. Stolle, R. and Collins, R.: Task Driven Perceptual Organization for Extraction of Rooftop Polygons, ARPA Image Understanding Workshop, pp. 359-365, 1994
- 11) Pal, S. K. and Mitra, S.: Neuro-Fuzzy Pattern Recognition, John Wiley & Sons Inc., New York, 1999
- 12) Pal, S. K. and Mitra, S.: Multi-layer perceptron, IEEE Trans. of Neural Networks, Vol. 3, pp. 683-697, 1992
- 13) Bezdek, J. C., Tsao, E. C. and Pal, N. R.: Fuzzy Kohonen clustering networks, IEEE International Conf. on Fuzzy Systems, San Diego, USA, pp. 1035-1043, 1992
- 14) Carpenter, G. A., Grossberg, S. and Rosen, D. B.: Fuzzy ART-Fast stable learning and categorization of analog patterns by an adaptive resonance system, Neural Networks, Vol. 4, pp. 759-771, 1991
- 15) Ghosh, A., Pal, N. R. and Pal, S. K.: Self-organization for object extraction using multiplayer neural network and fuzziness measure, IEEE Trans. of on Fuzzy Systems, Vol. 1, pp. 54-68, 1993
- 16) Lee, S. C. and Lee, E. T.: Fuzzy neural networks, Mathematical Bioscience, Vol. 23, pp. 151-177, 1975
- 17) Small Blue Planet Atlas Company: Los Angeles CityRom (CD-ROM), 1999
- 18) Yager, R. R. and Zadeh, L. A.: Fuzzy Sets, Neural Networks, and Soft Computing, Van Nostrand Reinhold, New York, 1994




a) 入力画像      b) 画素分類画像      c) 抽出画像      d) 領域整形画像      e) 3次元都市データ

図5 簡単なドローイングの場合の結果




a) 入力画像      b) 画素分類画像      c) 抽出画像      d) 領域整形画像      e) ユーザの期待出力

図6 航空写真の場合の結果



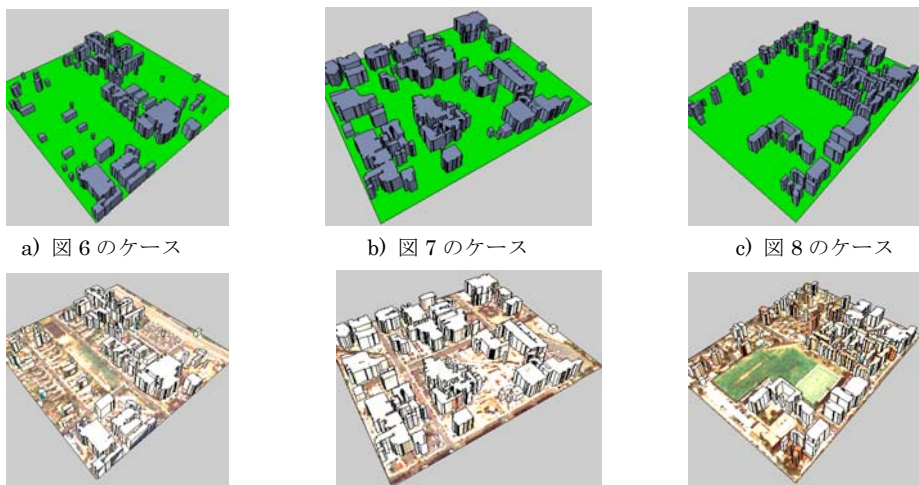
a) 入力画像      b) 画素分類画像      c) 抽出画像      d) 領域整形画像      e) ユーザの期待出力

図7 類似した航空写真の場合の結果（修正プロセスを必要としないケース）



a) 入力画像      b) 画素分類画像      c) 画素分類画像      d) 抽出画像      e) 領域整形画像      f) ユーザの期待出力  
(修正プロセス前)      (修正プロセス後)

図8 類似した航空写真の場合の結果—2（修正プロセスを要したケース）



a) 図6のケース      b) 図7のケース      c) 図8のケース  
d) 図6のケースの最終データ      e) 図7のケースの最終データ      f) 図8のケースの最終データ

図9 生成された3次元都市データ