

## 解説



## ファジィモデリング†

中森 義輝††

## 1. はじめに

ファジィモデリングとは、現実の問題に内包されている種々の「あいまいさ」を反映させるようなモデル構築手法の総称である。本稿では、データのあいまい性に注目した可能性線形回帰モデル<sup>1)</sup>と、構造のあいまい性に注目したルールベース型回帰モデル<sup>2)</sup>を紹介する。ともに線形回帰モデルの発展形である。ただし、後者はファジィモデルという名称で登場<sup>3)</sup>したが、一般的すぎるので、ここではルールベース型回帰モデルと呼ぶことにする。なお、ファジィ関係、ファジィ測度などを用いる他のタイプのファジィモデリングについては文献<sup>3)</sup>を参照されたい。

可能性線形回帰モデルは、回帰モデルの係数をファジィ数として同定することにより、目的変数の可能性分布を予測するものである。ここで、数直線上のファジィ集合をファジィ数と言い、そのメンバシップ関数を可能性分布とみなしている。通常回帰分析では目的変数のデータに確率的誤差が含まれるという想定のもとに、目的変数の挙動の期待値を予測するのに対し、可能性線形回帰分析では回帰係数にデータのあいまい性を担わせることにより、目的変数のとりうる値とその可能性を予測するものである。

一方、ルールベース型回帰モデルは if~then ルールの集合であり、各ルールの前件部がファジィ命題、後件部が回帰モデルから構成される。ここで、ファジィ命題とは「ある変数の値が大きい」などというものであり、「大きい」というファジィ集合のメンバシップ関数を適合度とみなすものである。すなわち、実際の値が入力されたときのメンバシップ値（条件が複数のときはメンバ

シップ値の積）がルールの確信度となる。目的変数の予測値はすべてのルールの回帰モデルによる予測値をルールの確信度による荷重平均として与える。この結果、予測値はあたかも一つの非線形モデルの出力値のような振る舞いをする。

## 2. 可能性線形回帰

基礎知識として可能性分布について説明し、ついで可能性線形回帰モデルとその代表的同定法を述べる。

## 2.1 可能性分布

「風呂の温度は適温である」というファジィ命題について考えよう。ある人にとって 42°C が適温の度合が最も高く、その度合を 1.0 としたとき他の温度の適合の度合は 図-1 のグラフのようであるとする。このとき、「適温」というファジィ集合が図-1 のグラフ（メンバシップ関数と呼ぶ）により特徴づけられたことになる。したがって、たとえば 41°C がその人の「適温」というファジィ集合に属す度合は 0.5 であるということになる。

今、「ちょうどいい湯かげんだ」というその人の声を聞いたとしよう。われわれはその人の「適温」というファジィ集合のメンバシップ関数を知っているので、現在の風呂の温度が 42°C であ




図-1 ファジィ集合「適温」のメンバシップ関数

† Fuzzy Modeling by Yoshiteru NAKAMORI (Konan University, Faculty of Science, Department of Applied Mathematics).

†† 甲南大学理学部応用数学科

る可能性が最も高く、それを1.0としたとき他の温度の可能性は図-1のグラフそのものとなると予想する。つまり、メンバシップ関数は現在の温度の可能性の度合を表していると考えられる。このようにメンバシップ関数とは可能性分布であるという解釈ができる。

その人が「風呂の温度は42°C ぐらいだ」と言ったとしよう。それはその人が自分の体に適した温度を知っていて、ちょうど良いと思ったとしてよい。温度計で計ったわけではないので、そのあいまい性を考慮してその人のことばの真実性をやはり図-1のようなグラフで表現できる。このとき「42°C ぐらい」をファジィ集合とみなせば、図-1のグラフはメンバシップ関数であるし、また実際の温度の可能性を表しているとも考えられる。

数直線上のファジィ集合（たとえば、42°C ぐらい）をファジィ数と呼ぶ。そして、そのメンバシップ関数を可能性分布とみなす。

風呂の場合は温度計で実際に計れるが、プロセス制御などで燃焼の色を見て「だいたい600°C ぐらい」と判定したり、テレビに出ている人が「だいたい35歳ぐらい」と推測したり、あるいは経済成長率が「だいたい4% ぐらい」と予測したりするのは、可能性分布で表現するのが妥当であろう。

ファジィ数  $A$  のメンバシップ関数の代表的なものは

$$L(x) = \max(0, 1 - |x|) \quad (1)$$

という関数を用いて

$$\mu_A(x) = L\left(\frac{x-b}{c}\right), \quad c > 0 \quad (2)$$

という三角形で表される。図-1の場合は  $b=42$ ,  $c=2$  である。このように、中心  $b$  と広がり  $c$  で特徴づけられることから、ファジィ数  $A$  を

$$A = (b, c)_L \quad (3)$$

と表す。

## 2.2 可能性線形回帰モデル

係数がファジィ数である線形回帰式

$$Y = A_1x_1 + A_2x_2 + \dots + A_mx_m \quad (4)$$

を可能性線形回帰式と呼ぼう。ここで「線形」とは係数を主体的にみたときに、右辺がそれらの線形結合になっていることに由来する。したがってオリジナルな変数  $z_1$  があって、 $x_1 = z_1^2$  あるいは

$x_1 = \log z_1$  などであってもよい。また  $x_1 = 1$  であれば  $A_1$  は定数項のファジィ数である。

なお(4)式を可能性線形システム<sup>9)</sup>という言い方が定着しているが、本稿ではそう呼ばない。「システム」というときはオリジナルの入力変数を主体的にみる意識が強くなる。入力変数に関して非線形でも係数に関して線形な回帰式で表現できるならばここでの議論の対象である。

さて、(1)式の関数  $L(x)$  を用いてファジィ数  $A_i$  のメンバシップ関数  $\mu_{A_i}(a_i)$  が(2)式のように表せるとしよう。すなわち

$$\mu_{A_i}(a_i) = L\left(\frac{a_i - b_i}{c_i}\right) \quad (5)$$

これを(3)式のように表せば次のようになる。

$$A_i = (b_i, c_i)_L, \quad i = 1, 2, \dots, m \quad (6)$$

(4)式の右辺がファジィ数  $A_i$  の線形結合であるので  $Y$  もファジィ数となりそのメンバシップ関数は  $Y$  の可能性分布と考えられる。

$x = (x_1, x_2, \dots, x_m)^T$  に値があたえられたとき、そのメンバシップ関数  $\mu_Y(y)$  は次式で与えられる。

$$\mu_Y(y) = \bigvee_{\{a|y=ax\}} \{\mu_{A_1}(a_1) \wedge \dots \wedge \mu_{A_m}(a_m)\} \quad (7)$$

ここに、 $a = (a_1, a_2, \dots, a_m)$  であり、 $\wedge$  は最小、 $\vee$  は最大をとる演算である。つまり、ある値  $y$  に対しちょうど  $y = ax$  となる  $a_1, a_2, \dots, a_m$  の値の組をすべて考えて、各組における最も小さいメンバシップ値の中から最も大きい値を  $\mu_Y(y)$  の値とする。このような計算方式は拡張原理<sup>9)</sup>と呼ばれる。

(7)式を(3)式のように表すと

$$Y = (bx, c|x|)_L \quad (8)$$

となる。ただし、

$$b = (b_1, b_2, \dots, b_m),$$

$$c = (c_1, c_2, \dots, c_m),$$

$$|x| = (|x_1|, |x_2|, \dots, |x_m|)^T$$

である。証明は文献3)を参照されたい。このように  $Y$  のメンバシップ関数の中心は、

$$b_1x_1 + b_2x_2 + \dots + b_mx_m$$

広がりには、

$$c_1|x_1| + c_2|x_2| + \dots + c_m|x_m|$$

と計算される。あいまい性が大きく広がってしまうことがファジィ数の演算の特徴である。

ここで、ファジィ数  $Y$  の  $h$ -レベル集合  $[Y]_h$  を導入しておく。 $[Y]_h$  は通常の場合であり




図-2 ファジィ数 Y の h-レベル集合

$$y \in [Y]_h \Leftrightarrow \mu_Y(y) \geq h \quad (9)$$

と定義される。したがって、図-2 のような三角形のメンバシップを考えるとき、

$$\begin{aligned} [Y]_h &= [bx - |L^{-1}(h)| \cdot c|x|, bx + |L^{-1}(h)| \cdot c|x|] \\ &= [bx - (1-h)c|x|, bx + (1-h)c|x|] \end{aligned} \quad (10)$$

である。最後の等式は三角形の相似比を考えれば容易に分かる。

2.3 可能性線形回帰分析

与えられたデータから(4)式を同定する問題を考えてよう。説明変数  $x_i$  ( $i=1, 2, \dots, m$ ) のデータは実数値  $x_{i1}, x_{i2}, \dots, x_{in}$  で与えられているとする。第  $j$  番目のデータを

$$x_j = (x_{1j}, x_{2j}, \dots, x_{mj}), \quad j=1, 2, \dots, n \quad (11)$$

と書こう。以下では、目的変数のデータがクリस्पな実数値で与えられる場合と、ファジィ数で与えられる場合のそれぞれについて(4)式と同定問題を定式化する。

まず目的変数のデータが実数値  $y_1, y_2, \dots, y_n$  で与えられる場合について考える。このとき各  $y_j$  に対してファジィ集合  $Y_j$  を想定し

$$y_j \in [Y_j]_h \quad (12)$$

を要求する。すなわち、データ  $y_j$  は  $Y_j$  の  $h$ -レベル集合に属するように要求する。  $h$  は主観的に定めるものであるが、  $h$  を大きくすることは  $y_j$  がファジィ集合の中央付近からのデータであるとみなすことになり、一般に  $Y_j$  のメンバシップ関数の広がりを大きくすることに対応する。

さて(10)式を参照すれば(12)式は次と同値である。

$$bx_j - (1-h)c|x_j| \leq y_j \leq bx_j + (1-h)c|x_j| \quad (13)$$

この拘束条件のもとで  $Y_j$  のメンバシップ関数の広がりの和を最小化

$$\sum_{j=1}^n c|x_j| \Rightarrow \min. \quad (14)$$

するように  $A_j = (b_j, c_j)_L$  を同定する。このように(4)式と同定問題は線形計画問題に帰着される。

次に、目的変数のデータがファジィ数

$$(y_j, e_j)_L, \quad j=1, 2, \dots, n \quad (15)$$

で与えられる場合を考える。  $L(x)$  はやはり図-2 のような三角形とする。この場合の考え方として

$$[(y_j, e_j)_L]_h \subset [Y_j^*]_h \quad (16)$$

のような  $h$ -レベルにおいてデータをおおうファジィ集合  $Y_j^*$  を想定するのを可能性回帰分析といい、一方

$$[Y_{*j}]_h \subset [(y_j, e_j)_L]_h \quad (17)$$

のようなファジィ集合  $Y_{*j}$  を想定するのを必然性回帰分析という。いずれの場合も、推定区間の広がりの和を最小化するようにそれぞれファジィ係数  $A_i^* = (b_i^*, c_i^*)$ ,  $A_{*i} = (b_{*i}, c_{*i})$  を同定する。ただし、後者の場合は解が存在するとは限らない。

なお、(13)式のような表現をすれば(16)式は

$$\begin{cases} b^*x_j - (1-h)c^*|x_j| \leq y_j - (1-h)e_j \\ y_j + (1-h)e_j \leq b^*x_j + (1-h)c^*|x_j| \end{cases} \quad (18)$$

と表すことができる。(17)式も同様である。図-3 は  $h=0$  とした場合の

$$Y = A_0 + A_1x + A_2x^2 \quad (19)$$

という形の可能性回帰モデルと必然性回帰モデルの例である<sup>3)</sup>。




図-3 可能性回帰モデル(破線)と必然性回帰モデル(実線)<sup>3)</sup>

### 3. ルールベース型回帰モデル

ルールベース型回帰モデル<sup>2)</sup>は、いくつかの部分データセットを用いて構築した線形モデル群を、メンバシップ関数を用いて統合することにより、非線形モデルをプロダクションルールの形式で組み立てるものである。ここでは、提案されている代表的な同定手法を概説し、制御問題へ応用する際の考え方を述べる。

#### 3.1 モデルの構造

ルールベース型回帰モデル<sup>2)</sup>は次のようなルールの集合からなる非線形モデルである。

ルール $R^k$ :

$$\begin{cases} \text{if } x_p \text{ is } A_p^k, \text{ and } x_q \text{ is } A_q^k, \text{ and } \dots, \\ \text{then } y^k = c_0^k + \sum_i c_i^k \cdot x_i \end{cases} \quad (20)$$

条件部に登場する変数  $x_p, x_q, \dots$  を前件部変数、結論部の線形式右辺に登場する説明変数  $x_i$  ( $i=1, 2, \dots$ ) を後件部変数という。  $A_p^k, A_q^k, \dots$  はファジィ部分集合で、それらのメンバシップ関数  $A_p^k(x_p), A_q^k(x_q), \dots$  を規定する定数を前件部パラメータという。結論部の線形式の係数  $c_i^k$  ( $i=1, 2, \dots$ ) を後件部パラメータという。

ルールベース型回帰モデルによる出力  $y$  の予測値  $y_*$  は次式により求める。

$$y_* = \frac{\sum_k w^k \cdot y_*^k}{\sum_k w^k}, \quad w^k = \prod_p A_p^k(x_{p*}) \quad (21)$$

ここに、 $x_{p*}$  は入力値、 $y_*^k$  はルール  $R^k$  の出力値である。ルール  $R^k$  の重み  $w^k$  はすべての前件部変数の入力値に対応するメンバシップ値の積で与えられている。予測値はすべてのルールからの出力の荷重平均であり、「少なくとも一つのルールが発火する」という想定である。

図-4 に示すように、二つの線形モデル  $A$  と  $B$  とをメンバシップ値を用いて荷重平均すれば  $C$  のような非線形モデルを得る<sup>5)</sup>。これがルールベース型回帰モデルである。しかし、事態がこのように簡単ではないことは図-5 を見れば理解できる。すなわち、各部分データセットに対してあてはまりの良い線形モデル  $A$  と  $B$  とを荷重平均すれば、 $C$  のようにかえってデータから遠ざかってしまうことがある。

ルールベース型回帰モデルの構築においては次

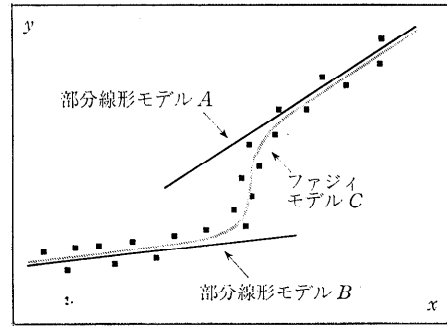


図-4 ファジィモデルの例 ( $A$ と $B$ を合成すれば、あてはまりの良い $C$ を得る)




図-5 ファジィモデルの例 ( $A$ と $B$ を合成すれば、あてはまりの悪い $C$ を得る)

のような課題を同時に考慮しなければならない。

(a)推論ルール構築のためのデータのファジィ分割、(b)線形モデルの説明変数の選択とパラメータ同定、および(c)前件部変数の選択とメンバシップ関数の同定。これらを総合的に非線形最適化問題として定式化することはやさしいが、最適解を発見するうまい手段がない。

また、実用的には目的変数が複数の場合や、後件部が時系列モデルとなる場合への発展を考えねばならない。さらに、後件部変数空間の分割だけでルールを記述することに限界があるとき、(d)ルールの荷重を後件部に登場しない変数で与える方法を考案しなければならない。

#### 3.2 同定アルゴリズム

ファジィモデル同定のために提案されている手法を簡単にレビューする。菅野・姜<sup>6)</sup>によるファジィモデル同定手順の一つの特徴は、与えられたデータをなるべく均質な二つの部分集合  $A, B$  に分割することである。これはモデル同定規範として A. G. Ivakhnenko が GMDH 法<sup>7)</sup>で用いた不偏性規範 (Unbiased Criterion):

$$UC = \left\{ \sum_{j=1}^{n_A} (y_j^{AA} - y_j^{AB})^2 + \sum_{j=1}^{n_B} (y_j^{BA} - y_j^{BB})^2 \right\}^{\frac{1}{2}} \quad (22)$$

を用いるためである。ここに、 $y_j^{AB}$  は部分データセット  $B$  を用いて構築したモデルによる部分データセット  $A$  の出力推定値であり、他も同様である。また、 $n_A, n_B$  はそれぞれ  $A, B$  のデータ数である。

さて、アルゴリズムはデータ空間を前進的に分割していき、各段階で後件部の線形回帰モデルを同定する。これは通常回帰分析である。また同時に前件部変数のメンバシップ関数を同定する。前件部変数は各ステップで最も良いモデルを得るデータ空間分割を行う変数が選ばれる。詳しくは文献 5) を参照されたい。

菅野・姜によるモデリング手法の特徴を変数の探索手法を中心にまとめると以下ようになる。

(a) 前件部変数の選択、つまりファジィ分割は前進法である。 $n$  分割を行う前件部変数は  $n-1$  分割における最小の  $UC$  値より小さな  $UC$  値をもつ変数にかぎる。

(b) 前件部パラメータの最適化は非線形最適化手法の一つであるコンプレックス法<sup>9)</sup>を用いる。ここでの規範は残差 2 乗和である。このとき、後件部変数は候補となっている変数をすべて用いるように固定しておく。

(c) 後件部変数の選択は後退消去法を用いる。各ルールの線形式の係数は最小 2 乗法を用いるが、変数選択の優劣はトータルモデルの  $UC$  値により決定する。ただし、全域線形モデルで落ちた変数は用いない。

高木・菅野の提案は構造が複雑で非線形なシステム・モデリングに直面していた人々にとってはきわめて魅力的なアプローチであったため大きな注目を集めた。以下では、菅野・姜の最初のアルゴリズムからどのような展開がみられたかについて整理する。

まず、入力空間のファジィ分割において、分割数の増加による組み合わせ爆発を抑えることと直方体型分割を嫌って、楕円体型分割法が提案されている<sup>9)</sup>。メンバシップ関数は多次元ガウス型となり、パラメータは最急降下法で求める。次に、ファジィとニューラルネットの融合の契機となった、入力空間のニューラルネットによる分割法が

登場する<sup>10)</sup>。メンバシップ関数をニューラルネットによりチューニングするものであり、入力空間分割に関する教師データを必要とするため、クラスタリングなどによりデータ分割についての先験情報を必要とする。また、ファジィ分割を実時間処理に対応できるように簡略化する方法として、ファジィ c-Means 法<sup>11)</sup>あるいはファジィ c-Varieties 法<sup>12)</sup>を用いたクラスタリングを行うことが考察されている<sup>13)</sup>。適切な分割数を求めるには、いくつかの分割例についてモデルを評価・検討することになる。

以上の方法はオリジナルの方法と同様、データに最終決定を委ねるという方法である。しかし、結果が直感とかけはなれているとき、どのように規範や手続きを変更すればよいのかはあらかじめ分かるものではない。実際にはデータ解析や知見により目安をつけておくことが必要である。

予測したい目的変数が複数の場合、一つずつの目的変数ごとにファジィモデルを構築するのがオリジナルの考え方であるが、同一の入力空間分割で十分対応できるという確信が得られるならば、すべての目的変数について前件部を統一できる。実用的には後件部が時系列モデルの場合が重要である。後件部の構造同定は変数選択にかわり次数の決定という仕事になる。また、一般に前件部変数集合は後件部変数集合にこだわらず、たとえば、ある後件部変数の微分値あるいは積分値などを用意したほうがよい。データ前処理によりデータ空間分割の勘を養っておくことが大切である。

### 3.3 適応制御

制御理論の分野では古くから次のようなモデルが検討されてきた。

モデル  $M^k$ :

$$\begin{cases} x(t+1) = A(\theta^k)x(t) + B(\theta^k)u(t) + w(t) \\ y(t) = C(\theta^k)x(t) + v(t) \end{cases} \quad (23)$$

ここに、 $\theta^k$  はシステムの異なる状況を記述するパラメータである。このモデルを用いて次のような適応制御が試みられる。

$$u(t) = \sum_k p(\theta^k | Y_t) u(t; \theta^k) \quad (24)$$

ここに、 $Y_t$  は現在時刻までの観測系列集合であり、 $p(\theta^k | Y_t)$  は観測に基づいた  $\theta^k$  の生起確率である。

(20)式のようなルールベース型回帰モデルを用いて同様な適応制御を考えることができる。ところで、このような複数のモデルを用いてシステム分析あるいは制御問題を考えるとき、以下の二つの技術を開発しなければならない。

(a) 異なるモデルを比較し、システムを最も良く近似するものを選ぶ技術。すなわち、モデルをうまく分類するためにモデルの性能を評価する規範を選択し、各モデルのベストポジションを決める技術。ルールベース型回帰モデルにおいてはメンバシップ関数が主要な役割を演じる。

(b) システムを最も上手に制御する技術。各フェーズで最良のモデルによる単独コントロールでうまくいかない場合は、単独コントロールのコンビネーションによるコントロール技術を開発する必要がある。(24)式のような荷重平均制御であり、ルールベース型回帰モデルによる制御ではやはりメンバシップ関数が活躍する。単独コントロールの合成ではなく、トータルな非線形モデルによる制御則の開発も試みられている<sup>14)</sup>。

#### 4. おわりに

数値データからファジィモデルを同定する二つの手法を紹介した。ともに線形回帰分析の発展形であり、一つは回帰式の係数をファジィ数として同定するものであり、他の一つはいくつかの部分線形モデルをメンバシップ関数で統合するものである。ところで、モデルの重要な任務の一つは分析者や研究者の「ものの見方」の表現力にあるといえる。部分的構造を確かめ、メンバシップ関数をチューニングしつつシミュレーションを実行し、将来実現するかもしれない状況に想いを巡らせる。ファジィモデリングの魅力はまさにそこにある。そこで、「あいまい」な知識や情報の整理、あるいは主観判断を支援するメカニズムが用意されなければならない。ファジィモデリング手法がそういう方向に発展していくことを期待したい。

#### 参考文献

- 1) Tanaka, H., Uejima, S. and Asai, K.: Linear Regression Analysis with Fuzzy Model, IEEE Trans. Syst. Man and Cybern., Vol. SMC-12, No. 6, pp. 903-907 (1982).
- 2) Takagi, T. and Sugeno, M.: Fuzzy Identification of Systems and Its Applications to Modeling and Control, IEEE Trans. on Systems, Man

and Cybernetics, Vol. SMC-15, No. 1, pp. 116-132 (1985).

- 3) 田中: ファジィモデリングとその応用, システム制御情報学会編, 朝倉書店, 181 p. (1990).
- 4) Zadeh, L. A.: The Concept of a Linguistic Variable and Its Applications to Approximate Reasoning, Memorandum No. ERL-M 411, Electronic Research Lab., University of California, Barkley (1973).
- 5) 菅野: ファジィ制御, 日刊工業新聞社, 183 p. (1988).
- 6) Sugeno, M. and Kang, G. T.: Fuzzy Modeling and Control of Multilayer Incinerator, Fuzzy Sets and Systems, Vol. 18, pp. 329-346 (1986).
- 7) Ivakhnenko, A. G.: The Group Method of Data Handling, A Rival of the Method of Stochastic Approximation, Soviet Automatic Control, Vol. 13, No. 3, pp. 43-55 (1968).
- 8) Box, M. J., Davies, D. and Swann, W. H.: Non-Linear Optimization Techniques, Oliver & Boyd, pp. 52-54 (1969).
- 9) 菅野・田中: システムのファジィモデリングとその解析, 第13回システムシンポジウム講演論文集, pp. 81-84, 沖縄 (1987).
- 10) 林・野村・若見: ニューラルネット駆動型ファジィ推論による推論ルールの獲得, 日本ファジィ学会誌, Vol. 2, No. 4, pp. 585-597 (1990).
- 11) Dunn, J.: A Fuzzy Relative of the ISODATA Process and Its Use in Detecting Compact Well-Separated Clusters, J. Cybernetics, Vol. 3, pp. 32-57 (1974).
- 12) Bezdek, J. C. et al.: Detection and Characterization of Cluster Substructure II, Fuzzy c-Varieties and Convex Combinations Thereof, SIAM J. Appl. Math., Vol. 40, No. 2, pp. 358-372 (1981).
- 13) 廣田・吉成: FCV (Fuzzy c-Varieties) によるファジィ分割アルゴリズム, 計測自動制御学会第13回知能システムシンポジウム資料, pp. 13-18 (1991).
- 14) 田中・佐野・鈴木: ファジィ最適フィードバック制御系の設計, 第7回ファジィシステムシンポジウム講演論文集, pp. 17-20, 名古屋 (1991).

(平成4年7月17日受付)



中森 義輝

昭和24年生。昭和54年京都大学大学院工学研究科博士課程数理工学専攻修了。工学博士。現在甲南大学理学部応用数学科教授。昭和59年10月から昭和60年11月まで国際応用システム解析研究所研究員。昭和61年環境庁国立環境研究所客員研究員兼務。平成4年中国大連理工大学客員教授兼務。著書「新しいシステム工学入門—しなやかなシステムズアプローチ」(オーム社, 共著)。システムモデリングやシミュレーションにおける対話的かつ知的支援の方法論、およびそのコンピュータソフトウェアの開発に従事。システム制御情報学会, 計測自動制御学会, 日本OR学会, 環境科学会, 日本ファジィ学会, IEEE各会員。