

EBL と SBL を併用した変電所最適母線構成の設計

小林 正明[†] 山田 直之[†] 小林 康弘[†]
伊藤 順子^{††} 矢部 邦明^{†††} 松田 聖^{†††}

厳密な最適解が望まれる組合せ最適化問題とみることができる変電所の最適母線構成の設計では、各構成のコストが、その構成において考えられる事故ケースの中から最悪のケースを想定して決定される。そのため、構成自体の探索とともに、事故ケース空間内の探索も必要となる点に特徴がある。いわば、二重にネストした組合せ最適化問題といえる。本稿では、二種類の機械学習手法を適用することにより、対象固有の特性をシステム自らが獲得し、現実的な時間内に常に厳密な最適解を得る設計システムについて述べる。本システムは基本的には生成検査法によって最適な母線構成を探索するが、生成時に必要な「構成候補を絞り込むための知識」の獲得には論理的に誤りのない知識を得る演繹的学習 (EBL) を用い、知識の誤りが最適解の見落としにつながらない「各候補に対する検査 (事故ケースの探索) 順序決定のための知識」の獲得には帰納的学習 (SBL) を用いる。また、EBL の学習途中に物理法則等に基づく手続きから領域理論を自動生成する手法を開発し、不完全領域理論問題を解決した。このように、二種類の機械学習手法を、それぞれの特性を活かしながら適用することにより、実用規模の問題の解決を可能とした。実現した手法は、他の組合せ最適化問題にも有効であろう。

Optimum Design of Substation Bus Configuration through Application of EBL and SBL

MASAAKI KOBAYASHI,[†] NAOYUKI YAMADA,[†] YASUHIRO KOBAYASHI,[†]
JUNKO ITOU,^{††} KUNIAKI YABE^{†††} and SATOSHI MATSUDA^{†††}

Configuration design of a transformer substation bus is a kind of combinatorial problems where the exact optimum solution is pursued. The design process requires not only search in configuration design space but also search in accident case space, because the performance of a bus configuration is evaluated on the basis of the most severe design basis accidental out of a large number of possible accident cases. It can be, therefore, said that the optimum configuration design with the lowest bus capacity is obtained through a doubly nested combinatorial search. Machine learning techniques have been extended and applied to develop a system that learns domain knowledge and utilizes it for the design problem to realize efficient search process and to assure the exact optimum solution. The system is based on the generate and test framework and searches the optimum configuration with self-acquired knowledge. For the exact solution through efficient search, two kinds of machine learning techniques are combined for knowledge acquisition in this system; i.e. deductive learning (EBL) for configuration screening knowledge which is required to be logically valid to avoid the exact optimum design omission in configuration generation, and inductive learning (SBL) for accident case ordering knowledge which is not necessarily required to be logically valid because of irrelevance to the optimum design omission. In this EBL application, the domain theory (DT) comprises thousands of pieces of knowledge due to combinatorial characteristics of the design. To cope with this "incomplete DT" difficulty, a template-based method is proposed to generate the complete DT automatically and dynamically on the basis of compact physical principles for electric circuits in the learning process. A real world sized design problem has been solved through the application of two kinds of machine learning techniques to the knowledge acquisition according to their characteristics. The results suggested that the proposed method for design knowledge acquisition is widely applicable to other combinatorial design problems.

[†] (株)日立製作所エネルギー研究所
Energy Research Laboratory, Hitachi, Ltd.

^{††} (株)日立製作所システム事業部
Systems Engineering Division, Hitachi, Ltd.

^{†††} 東京電力(株)システム研究所
Computer & Communication Research Center, The
Tokyo Electric Power Company

1. はじめに

知識処理システムの性能は、その知識ベースに依存するが、質、量ともに十分な知識を獲得することが困難な問題も多い。そこで、システムに学習機能を付与し、問題解決の事例から知識を獲得する機械学習の研

究が注目されている。

変電所の最適な母線構成の設計は、厳密な最適解が望まれる組合せ最適化問題とみることができ、いかに効率化のために探索空間を絞り込み、探索時間を短縮するかが重要である。したがって、そのシステム化にあたっては、対象固有の特性や設計者の知識を有効に活用する必要がある。しかし、母線構成の設計では、知識を体系的に整理することが難しく、専門家からの知識獲得には必ずしも多くを期待できない。そこで、機械学習技術を適用することにより、対象固有の特性をシステム自らが獲得し、問題解決に利用するシステムを開発し、常に厳密な最適解を得る効率的な探索を実現可能とした。

機械学習は大きく演繹的学習と帰納的学習とに分類でき、その代表的なものとして、前者には「説明に基づく学習」(EBL: Explanation Based Learning)、後者には「類似に基づく学習」(SBL: Similarity Based Learning)がある。

EBLについては、1986年に Mitchell らによってその基本概念が提案¹⁾されて以来、現在までに盛んに研究が行われてきた。近年、診断、設計問題を中心に EBL の適用²⁾⁻⁴⁾が試みられており、基礎研究から、適用研究のフェーズへと移行しつつある。しかし、EBL 適用上のボトルネックとして不完全領域理論問題^{1),5)}が指摘されており、実用規模の問題に適用可能な水準には至っていない。

また、SBL に関しては獲得する知識の正当性が保証されないため、変電所の母線構成の設計のように、厳密な最適解を要求される設計問題に対して適用された例はなかった。

本研究では、EBL、および SBL によって獲得した知識を、組合せ最適化の問題解決時に、それぞれ解候補の絞り込み、解候補の評価手順の決定に利用することで、目的関数の値が最小の解を見落とさずに問題解決を効率化する手法を開発した⁶⁾。また、EBL の適用においては、上記の不完全領域理論問題に対する一解決策として、学習途中に物理法則等に基づく手続きから領域理論を自動生成する手法を開発した。

本稿では、開発した機械学習の適用手法、および変電所母線構成設計システムを実用規模の設計に利用した場合の知識の利用効果について述べる。

2. 変電所母線構成設計問題への機械学習の適用

2.1 変電所母線構成設計問題

図 1 に、変電所母線構成設計システムの設計対象で

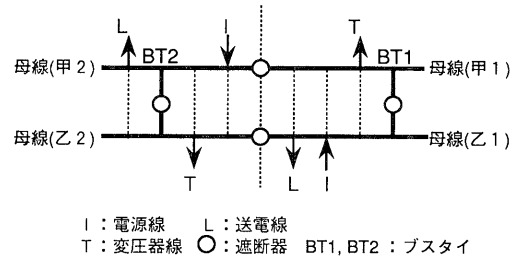


図 1 変電所機器構成の例

Fig. 1 Example of transformer substation structure.

ある 275 kV 級の変電所構成例を示す。変電所は、甲側、乙側各 2 本の母線と、甲乙の母線を接続するブスタイ、および母線と接続する電源線（以下 I と表現する）、負荷側の送電線 (L)、変圧器への送電線 (T) とから構成される。

変電所の設備コストは各区間の母線の容量の総和に大きく依存し、各区間の母線の容量は、各種の線路や、母線同士をつなぐブスタイが、母線に対してどの順序で接続するかによって異なる。また、電力の供給信頼性を確保するために、図 1 の変電所においては、ある電源線の遮断事故時、そこに流れていた潮流（電流によるエネルギーの流れ）は他の電源線から供給する。例えば母線甲 1 が遮断した場合は、そこに接続している全線路の接続を乙 1 に切り替える。そのため、設計において母線の容量（太さ）を決定する際には、通常運転時よりも大きな潮流に耐えられるようにする必要がある。従来から、母線の容量を、母線も含む 2 種類の線路 2 本（例えば母線と電源線 1 本ずつ）が同時に停止となるようなすべての事故にも耐えられるよう決定している。

変電所母線構成設計問題とは、各線路の容量が与えられたとき、上述の電力の供給信頼性確保という制約の下で母線の定格電流を必要最小限にすることによって変電所の設備コスト低減を図る組合せ最適化問題である。最小化すべき目的関数として、供給信頼性を確保した上での「各区間の最大潮流値の和」を用い、目的関数最小の構成を最適解とする。

したがって、変電所の最適な母線構成の設計では、構成自体の探索のみならず、電力の供給信頼性確保のために、その構成において考えられる 2 種線路同時遮断の全事故ケースの中から最悪のケースを見出して各構成のコストを決定することが求められる。したがって、事故ケース空間内の効果的探索も必要となり、いわば、二重にネストした組合せ最適化問題となる点に大きな特徴がある。

2.2 従来手法と知識獲得のニーズ

従来は専門技術者が、経験的な知識に基づいて最適となりそうな構成の候補を絞り込み、直感的に厳しそうな事故について潮流計算を繰り返すことにより最適解を求めていたが、それが真に最適解であるという保証はなかった。そこで、専門技術者の負担を軽減するとともに、最適解を見落とさないために、変電所の母線構成の設計を計算機によって支援するニーズがある。

最適解を確保するための処理は、考えられる全変電所構成に対して、2種類線路同時遮断の事故ケースすべてを想定して母線の区間ごとの潮流を計算することで各母線区間の最大潮流値を求め、その和である目的関数の大きさを算出するという網羅的な生成検査法がベースとなる。しかし、この方法では、事故ケースの評価件数の組合せ爆発という問題がある。例えば、線路総本数が9本という実用規模の条件では、設計上の制約を考慮しても、網羅的な組合せで 5.6×10^7 回もの事故ケース評価が必要である。

実際の設計においては、条件を変えて試行錯誤的に設計を進めることもあるため、システムの応答時間は極力短縮する必要がある。

そのために、システムにも上記専門技術者の知識に相当する知識を持たせ、知識処理による絞り込みを行う手法が考えられる。最適解を見落とさないためには、後に説明するように、数千個程度の知識が必要となる。ところが、専門技術者はこのような具体的な知識を体系的に整理した形で所有しているわけではないため、インタビューによってこれらの知識すべてを獲得することは困難である。したがって、設計の事例から、知識を自動的に獲得する機械学習法の適用に着目する。

2.3 問題解決効率化のための知識とその獲得手段

網羅的な生成検査法をベースとした問題解決は図2のように、まず解の候補を生成し、次に各候補が最適解となりえるかどうかを評価するという生成検査法である。処理の中では次に示すように、解の候補である変電所構成の絞り込みと、各構成の目的関数計算のために評価すべき事故ケースの絞り込みとの2通りの効率化が可能である⁶⁾。

(1) 構成絞り込み用知識

知識の利用により最適解を見落とさないためには、論理的に正当な知識でなければならず、知識獲得手段としてEBLを採用する¹⁾。EBLは、訓練事例を領域理論と呼ばれる背景知識によって説明し、その説明の履歴である説明構造を一般化することによって論理的に正当な知識を獲得する手法である。

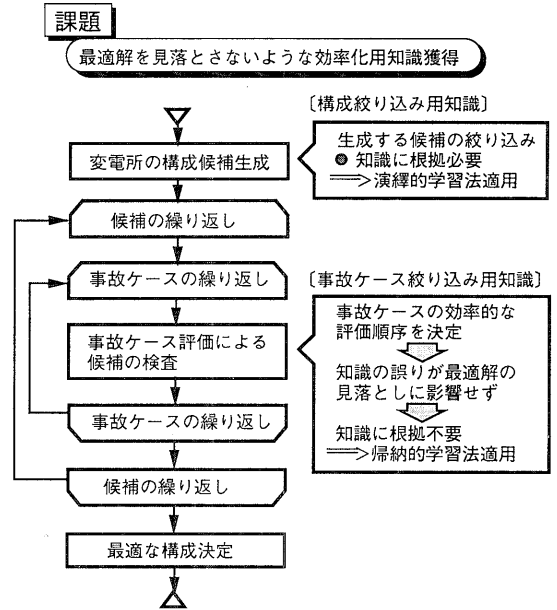



図2 機械学習法適用のアプローチ
Fig. 2 Approach to machine learning application.

もし (構成線路は、電源線; l(甲), l(乙)、送電線; L(甲), L(乙)、変圧器線; T(甲), T(乙))
かつ (線路の潮流値は、電源線; i, 送電線; I, 変圧器線; t)
かつ (0.0 ≤ t / I ≤ 1.0)
ならば <any>{L(甲), T(甲)} (右端2本がL(甲), T(甲)からなる構成全体のグループG) の中でコスト最小のものは、<any>{L(甲) T(甲)} (2本の並び順が内側から順にL(甲), T(甲)のグループg1)に属する

(a) 構成絞り込み知識の例

(a) Example of the structure restricting knowledge



(b) 構成絞り込みのプロセスの例

(b) Example of the process of the structure restriction

図3 構成の分類による絞り込み

Fig. 3 Configuration restriction by classifying structures.

変電所構成をある共通の構成上の特徴によって分類し、各グループから目的関数最小となる構成を求めた例をEBLの訓練事例とし、電気回路に関する物理法則から導かれる知識を領域理論とすることで、後述するように、図3(a)に示すような知識を獲得できる。

これは、各グループの中で目的関数最小となるための条件を与える知識である⁶⁾。知識の記述中、例えば“T(甲)”は、甲母線に接続する変圧器線を意味する。

本研究で用いた生成検査法では、解の候補を網羅する範囲を対象としているが、知識を用いて見込みのない解の候補を絞り込むことにより、解の候補を絞り込んでいる。したがって、知識を網羅できない場合でも、絞り込み知識が正当であれば最適解を見落とすことはない。しかし、知識の不足により、検査すべきケースを十分絞り込めない場合、最適解の探索の効率を損なうことはある。

抽象度の低いレベルで知識を表現すれば、反例の排除が容易となり、知識の正当性を判別しやすくなる。しかし、知識ベースの規模が大きくなり、効率的に知識を獲得、利用することが難しくなる。そこで、知識表現の抽象度のレベル、すなわち知識記述の粒度 (granularity) が問題となる。ここでは、図3(a)のレベルに知識記述の粒度を設定し、設計者にとってわかりやすく、ルール数にして1000以下の規模で知識ベースを構成することを目指した。

また、図3(b)は、この知識を利用して評価すべき変電所構成を絞り込む様子を表している。図3(b)では、右側2本の線路がT(甲)とL(甲)(順不同)であり、その他の部分は任意であるような構成グループG(以下、 $\langle \text{any} \rangle \{L(\text{甲}), T(\text{甲})\}$ のように表現する)を、線路の接続順序が端へ向かってL(甲)→T(甲)であるグループ g_1 ($\langle \text{any} \rangle [L(\text{甲}) T(\text{甲})]$)と表現)と、T(甲)→L(甲)であるグループ g_2 ($\langle \text{any} \rangle [T(\text{甲}) L(\text{甲})]$)とに分類している。したがって、図3(a)の知識は、 g_1 の目的関数の方が小さいために、最適解を求めるには g_1 のみを評価すれば良いことを意味する。

(2) 事故ケース絞り込み用知識

ある候補Pが最適解となり得るかどうかを検査するためには、最適解候補 P_0 と目的関数の大小を比較すれば良い。 P_0 はユーザである設計者が最初に入力し、問題解決途中に P_0 よりも目的関数の小さな候補が見つければこれを更新する。候補Pの検査において、各母線区間の最大潮流値、およびそれらの和である目的関数 $C(P)$ の下限値は、事故ケースを評価するに従って更新され増加していく。図2の処理フローの二重ループに沿って、事故ケースの評価とともに最大潮流値は更新される。その結果、 $C(P)$ は、事故ケース評価件数について単調非減少関数となる。したがって、図2の検査においては、最適解でないこと、すなわち $C(P) \geq C(P_0)$ が確認できさえすれば、残りの事故ケ

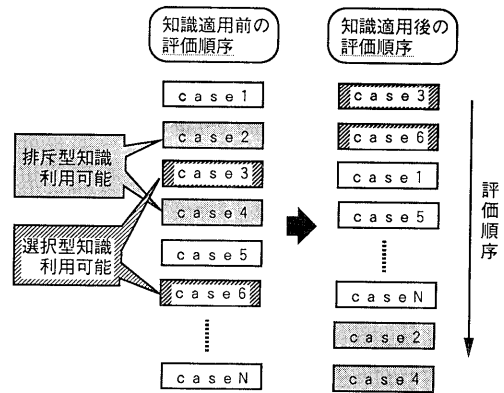


図4 事故ケース絞り込み知識による評価順序決定
Fig. 4 Test sequence determination using knowledge to reduce test cases of accidents.

ースを評価する必要はない。この処理では、 P_0 の選択段階で、できるだけ目的関数の小さな構成を選択することで、事故ケース評価件数は低減される。 P_0 選択の功拙は、設計者の経験や過去の類似設計例の有無に関わってくる。

一般には、母線に流れる潮流値の大きな事故ケース(過酷な事故ケース)から評価した方が、 $C(P)$ が更新される際の増加分が大きいために、候補の検査は少ない事故評価件数で済む。そのため評価順序を適切に決定することで、評価する事故ケース数を削減できる。順序決定のための知識には次のようなものがある。

- (i)優先的に評価すべき過酷な事故ケースを選択する知識(選択型知識)
- (ii)後回しにして評価すべき影響の小さな事故ケースを選択する知識(排斥型知識)

図4に、これらの知識利用による評価順序決定の様子を示す。図4において、case 3, case 6は過酷な事故ケース、case 2, case 4は影響の小さな事故ケースである。知識の利用によって、過酷なケースを先に、影響の小さな事故ケースを後に評価できるよう、評価順序が並べ替えられる。以上の知識は、評価順序の決定にのみ利用するので、論理的な正当性は要求されない。極論すると、仮に獲得した知識が不正確であっても評価件数の削減効率が向上しないだけであって、最適解を見落とすことはないからである。そこで学習方法としては、論理的に正当な知識は得られないが領域理論の入力が不要なSBLを採用する。これは多数の事例からある概念(例えば、厳しい事故ケースであること)を満たす事例の条件を、分類によって帰納的に学習する手法⁷⁾である。

3. 機械学習による知識の獲得

3.1 EBL による構成絞り込み知識の獲得

3.1.1 EBL 適用の概略

図 3 (a) に示すような知識を獲得するためには、知識の結論部の条件 (図 3 (a) のならば以下の記述) が成立するような事実が、訓練事例として必要である。そこで、ある共通の特徴を持った構成のグループ G をさらに分類し、G の中で目的関数最小の構成を含むグループ g_1 を求め、この事実を学習のための訓練事例とする。 g_1 を求めるには、G を分類して得られるすべてのグループについて、実際に潮流計算を行って、目的関数の値を比較する。そのために、特徴的な部分以外の部分 (図 3 (b) の <any> に相当する部分) を適当に固定し、線路の容量としては具体的な数値を与える必要がある。処理の詳細は、3.1.3 項で述べる。

EBL によって学習を行うには、例えば図 5 に示すような電気回路に関する物理的知識を領域理論として用い、 g_1 がグループ G の中で目的関数最小の構成を含む理由を説明する。この領域理論はキルヒホッフの第一法則から導かれるものである。説明の内容は変電所構成間の目的関数の大小比較であるから、この場合の EBL は、解の品質の比較による学習⁴⁾といえる。

3.1.2 領域理論の不完備問題への対策


(1) 変電所母線構成設計問題における不完備問題本問題に従来の EBL を適用する場合、図 5 のような領域理論があらかじめ学習システムに入力されていることが前提である。この領域理論は、ある特徴 (図の場合は右端 2 本が T と L であること) を持つ変電所構成における特定箇所の潮流値を一般的な数式によ

もし (構成線路は、電源線 ; l(甲), l(乙)、送電線 ; L(甲), L(乙)、
変圧器線 ; T(甲), T(乙))
かつ (線路の潮流値は、電源線 ; i、送電線 ; I、変圧器線 ; t)

ならば

(下図の構成

- (i) $\leq \text{any} > [T(\text{甲})L(\text{甲})]$ の甲側区間において、
- (ii) 乙 1 母線停止時
- (iii) 区間よりも左側の送電線が遮断したときの潮流値は、
- (iv) $2I$ である)



<any> [T(甲)L(甲)] : 右端から、L(甲)、T(甲)の順に
接続している任意の構成

(i)~(iv)の下線部 : 事例依存部分

図 5 EBL の領域理論の例

Fig. 5 Example of domain theory for EBL.

て与えるものである。これに含まれる数式は、対象としている構成、および事故ケースの特徴が与えられてから初めて決定するものであり、汎用性には乏しい。また、これが厳密性を保証した上での領域理論の汎用性の限界でもある。

しかし、あらかじめすべての訓練事例のパターンを想定し、説明に必要な領域理論をすべて網羅することは非常に困難である。これは、EBL 適用上のボトルネックである不完全領域理論問題の一つで、不完備問題 (Incomplete Problem)^{1),5)}と呼ばれる問題である。

(2) 不完備問題への対策

従来の EBL の適用研究における不完備問題への対策は、辻野ら³⁾による学習システム“KAISER”にみられるように、ユーザへのインタビューによる知識の補充が中心であった⁶⁾。また、荒木らは、背景理論と呼ばれる知識ベースから領域理論へ、不足した知識を移転するという手法を提案している。しかし、実用規模の変電所母線構成設計にこれらの対策を適用する場合、前者はユーザの負担が大きいこと、後者は背景理論を移転可能な知識の形で用意することが困難であることから、新たな対策が必要である。

本稿では、変電所母線構成設計問題の次の特徴に着目し、不完備問題への新たな対策を提案する。

(a) 基本的な内容は共通だが、構成や数式の記述などの一部 (事例依存部分) が異なる領域理論が多数必要である。

(b) 事例依存部分は決まった手続きによって求められる。

以上の特徴から、学習前に領域理論をすべて入力するのではなく、学習中に領域理論を自動生成する手法を開発した。

(3) 領域理論の自動生成手法

構成絞り込み知識獲得のための EBL の領域理論として、図 5 のように、知識の記述形は共通であるが事例依存部分について多数のパターンの知識が必要となる。この共通部分を「領域理論のフレーム」と呼ぶことにする。領域理論は、事例依存部分が未知のフレームについて、事例依存部分を補充することによって作成できる。したがって、「領域理論のフレーム」、および、「事例が与えられる度に事例の特徴から事例依存部分を求める手続き」を入力しておくことによって、図 6 に示すように領域理論を学習中に自動生成する。

領域理論のフレームは、知識の条件部、結果部に記述されるべき項目を定めてはいるが、各項目の具体的な内容が未定である点で、通常の領域理論とは異なる。例えば図 6 のフレームからは、(i) 母線停止時の線路

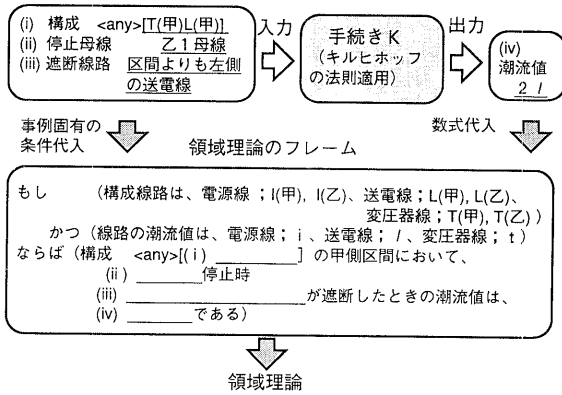


図6 領域理論の自動生成手法

Fig. 6 Automatic generation method of domain theory.

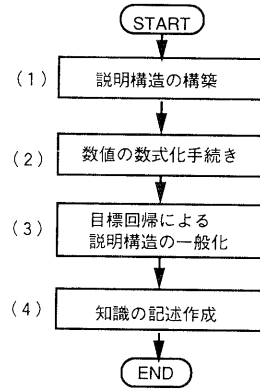


図7 改良した EBL の処理手順
Fig. 7 Modified EBL procedure.

の並び (ii) 事故時の停止母線 (iii) 遮断する線路の条件と、(iv) ある箇所における潮流値との間に因果関係があることはわかるが、その具体的な関係は不明である。しかし、(i) (ii) (iii) の情報から、(iv) に該当する記述を数式の形で求める手続き K は、キルヒホッフの第一法則によって定型化できる。この手続きをプログラムの形で学習システムに与えておく。

事例が与えられれば、(i) (ii) (iii) の事例の情報を入力として手続き K を起動することにより、図5と同様の領域理論を作成できる。すなわち、領域理論を網羅的に入力しておく代わりに、これを領域理論のフレームと事例依存部分を求める手続きとに分割して入力しておくことで、基本部分の共通な多数の領域理論を完備することができる。

3.1.3 改良した EBL の処理

領域理論をフレームと手続きに分離して使用する EBL の処理手順を図7に示す。このように分離することにより、手続き起動による数値の数式化処理が加わった点が従来の EBL と異なる点である。

また、EBL における入出力を図8に示す。図8(1)の目標概念は、「右端の2箇所接続する線路が x_1, x_2 のとき、これらが端から順に $y_2 \rightarrow y_1$ の順(ただし $(y_1, y_2) = (x_1, x_2)$ または (x_2, x_1) に並んでいる場合に、構成のコストが最小になる」というものである。

一方、図8(3)の訓練事例は、**T2, T3** に記述された設計条件のもとで、図3(b)の構成グループ g_1 とグループ g_2 とを、実際の潮流計算によって目的関数の大小比較した結果を事実の集合として記述したものである。最終結果は **T1** であり、目標概念が成立していることがわかる。

図8の入力を用いて、図3(a)に示す知識を獲得す

る処理手順を、図7に沿って説明する。

(1) 説明構造の構築

事例において目標概念(図8(1))が成立する理由を、通常の領域理論(図8(2) **DT1, DT3**)、および領域理論のフレーム(図8(2) **DT2, DT4**)を利用して説明する。目標概念説明の履歴である説明構造を図9に示す。

(2) 数値の数式化手続き

次に、図8(4)で定義される手続き K_1, K_2 を起動して、説明構造中の数値を数式に一般化する。この手続きによって生成された代入情報は、目標回帰とは逆に、代入情報を説明構造の葉から根の方向(図9中矢印の方向)へ伝播してゆく。

図9の例では、まず、条件文 **S1** において(手続き K_2)によって得られた代入情報“ $2l/1600$ ”は、その上位の条件文 **S2** に伝播される。ここで、例えば代入情報“ x/a ”は、定数 a が、変数または数式 x のように一般化されることを意味する。次に、(DT 2)には数式の和を計算する(手続き K_1)が定義されているので、**S2, S3** 中に代入された数式の和をとり($2l+2l=4l$)、条件文 **S4** に代入されるべき新たな代入情報“ $4l/3200$ ”を得る。

このような数式化手続きによって、領域理論のフレーム中の事例依存部分(数式を含む)はすべて求まり、図5のような領域理論が自動的に生成されたことになる。

(3) 目標回帰による説明構造の一般化

数式化を終えた説明構造に対して、数式に一般化されていない事例固有の定数を、変数に一般化する。これは目標回帰によって行うが、図8の操作性規範に従い、例えば線路名“**LI1 (甲)**”は“**L (甲)**”のような変数名に一般化する。

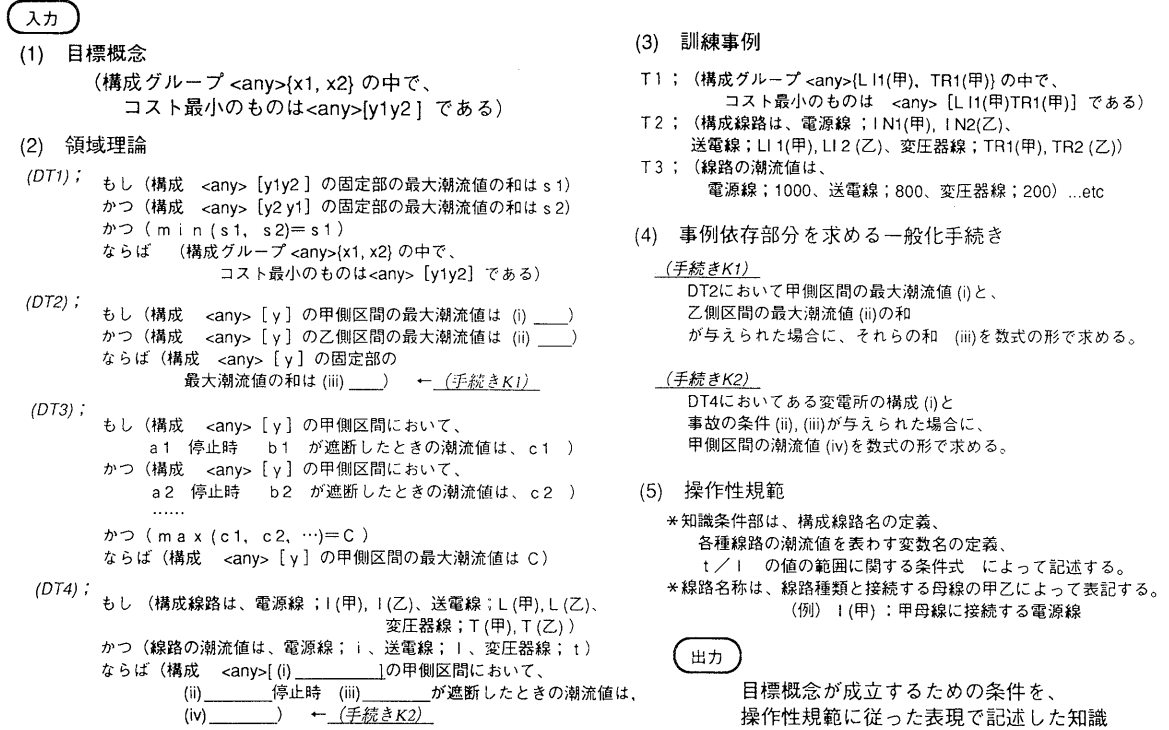


図 8 構成絞り込み知識の獲得における入出力
 Fig. 8 Input/Output data in acquiring the structure restricting knowledge.

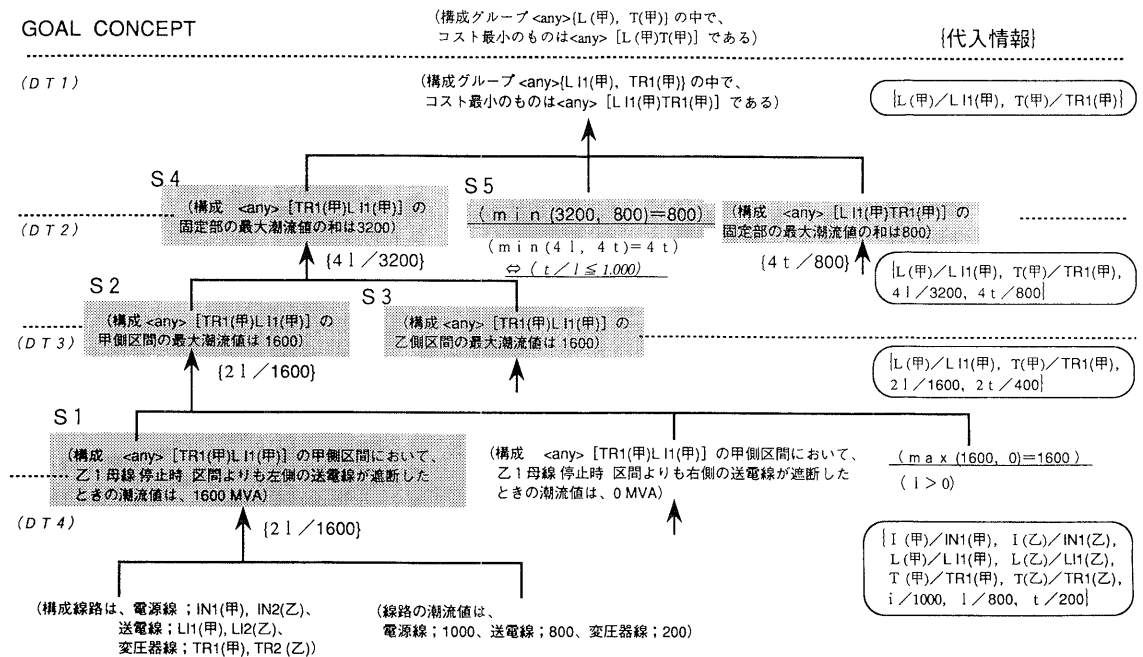


図 9 構成絞り込み知識の獲得のための説明構造
 Fig. 9 Explanation structure to acquire structure restricting knowledge.

(4) 知識記述の作成

図9において説明構造の末端の条件式の and 条件をとることによって、知識の条件部の記述を求める。ただし、図9のS5のように“max”，または“min”によって表現された条件式は図8(5)の操作性規範に従い、変圧器線の容量と送電線の容量との比の値 t/l に関する不等式に同値変形する。その結果、図3(a)に示すような知識を獲得できる。

3.1.4 改良した EBL に関する考察

獲得される知識から、訓練事例における設計条件、 $t/l=200/800$ が、不等式条件 $0.0 < t/l \leq 1.0$ と一般化され、目標概念が成立するためのより一般的な条件が学習されていることがわかる。すなわち、訓練事例の一般化による、目標概念成立のための一般的条件獲得の機能を持っている。

また、上述の EBL は領域理論をフレームの形で与えておき、一般化の際に物理法則に基づいた手続きによって情報を補充することが特徴である。これによって、問題解決に利用可能な具体的知識を全パターン獲得する。すなわち、ここでの EBL の役割は、深い知識(物理法則)から浅い知識(構成絞り込み知識)への知識コンパイルともいえる。

3.2 SBL による事故ケース絞り込み知識の獲得

3.2.1 知識の獲得方法

Quinlan の学習システム ID3 で用いられている決定木による分類手法⁷⁾によって事故ケースを分類し、その結果から事故ケースの評価順序を決定する知識を獲得する方法を説明する。

(1) SBL の入力

(a) 目標概念

図4において選択型知識の獲得のための目標概念として、ある事故ケースが厳しいケースであるための条件 G、排斥型知識の目標概念として、ある事故ケースが軽度のケースであるための条件 H を用いた。

G: 「ある構成の変電所について、ある事故ケースで潮流値最大となる区間があるとき、それらの潮流値の和の大きさが、その構成に対する全事故ケースの中で上位 n 位以内である。」

n は適当な値を学習前に指定する。

H: 「ある構成の変電所において、ある事故ケースで潮流値最大となる区間が存在しない。」

(b) 事故ケースの集合 (訓練事例)

様々な構成の変電所に対して、全事故ケースについて潮流計算を行い、その結果、各事故ケースが目標概念を満たすかどうかを判定する。これを満たす事故ケースを正例、それ以外を負例とする。

(c) 事故ケースを特徴付ける属性

事故ケースの集合を分類するための属性として、事故時の電源線と送電線の並び順、遮断する線路の種類などを用い、各事故ケースについてこれらの属性値を求める機能を組み込んでおく。

(2) SBL の処理

上記入力を用いて、ある事故ケースが目標概念を満たすための条件を帰納的に学習する。その内容は図10に示すように、全事故ケース C を属性の値の組合せによって複数のグループ ($C_{12}, C_{21}, C_{22}, \dots$) に分類し、各グループに含まれる正例、負例の個数を数える。あるグループで正例の比率が一定値(学習前に指定する)を上回る場合、そのグループの属性値の組合せが求める条件である。

様々な属性によって事故ケースを分類した結果、「遮断した線路の種類」、「母線停止時の電源線と送電線の並び順」などの属性を用いることで、事故ケース絞り込み用知識を獲得できることがわかった。獲得できる選択型知識の一例を図11に示す。知識条件部の「電源線と送電線の並び順」とは、図において、母線の端(乙2側)から I と L とがどのような順番で並んでいるかである。

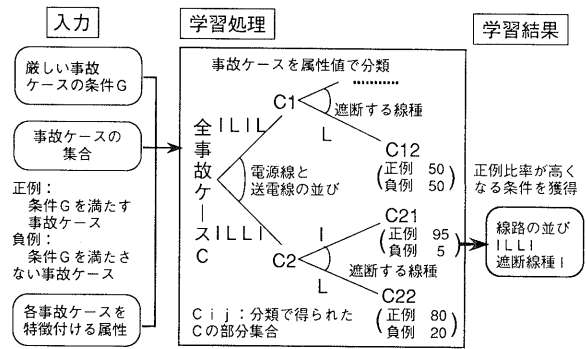


図10 SBL による事故ケース絞り込み知識の獲得処理
Fig. 10 Acquisition of knowledge to reduce test cases by SBL.

もし (母線停止時の回路で、電源線 I と送電線 L の並び順が I L L L) ならば (電源線遮断事故を優先的に評価する)




図11 事故ケース絞り込み知識の例
Fig. 11 Example of knowledge to reduce test cases of accidents.

3.2.2 SBLの適用法に関する考察

帰納的学習法であるSBLは、獲得する知識に論理的正当性が保証されないため、厳密な解を要求される問題に適用することは一般には不相当である。しかし、その適用箇所を限定すれば、このような問題に対しても適用可能な場合がある。

例えば本稿の変電所母線構成設計問題は、厳密な解を要求されるが、次の特徴を持っている。

- (1) 生成検査法をベースとした組合せ最適化手法で、生成した各候補が最適か否かを検査するために、多数のパターンの評価が必要である。
- (2) 評価の順序によって検査の効率が大きく異なる。

以上のような問題については、評価順序を決定する知識の獲得に対してSBLを適用すれば、知識利用によって最適解を見落とすことなく、問題解決の効率化が可能である。

4. 知識利用効果と汎用性の評価

4.1 変電所母線構成設計システム

問題解決の効率化のための知識を機械学習によって獲得する機能を持つ設計システムを開発した。設計対象は、変電所の母線構成であり、システムは、C言語で記述されており、エンジニアリングワークステーションHITAC-2050 G (約7 MIPS相当) 上で稼働する。本システムは、知識獲得部と問題解決部とからなる。知識獲得部による学習は問題解決前に行っておき、新たな条件で設計する場合には問題解決部を起動し、獲得された知識を利用しての、解の候補、評価すべき事故ケース数の絞り込みを行いながら最適解を求める。このシステムを用いて上記の知識獲得機能の検証を行った。

問題解決における事故ケースの評価件数は、初期に入力する解の候補 P_0 に依存するため、以下に示す結果は、あくまで効果の一例である。

4.2 構成絞り込み知識の適用効果と汎用性

構成絞り込み知識をEBLによって獲得するため、通常の領域理論24個、領域理論のフレーム8個、事例依存部分を求める手続き7件を入力した。次に、開発したシステムの知識獲得部を起動して、次の条件のもとで知識獲得を行った。

- (1) 線路本数: I 2本, L 3本, T 4本
- (2) 線路容量: $i=950$ MVA, $l=500$ MVA, $t=100$ MVA

その結果、図3(a)のような知識を474個獲得できた。3.1節で述べた知識の獲得、利用法が有効であるた

表1 構成絞り込み知識の汎用性と利用効果

Table 1 Availability and efficiency of structure restricting knowledge.

| 設計条件 t/l | 利用可能な知識の比率 (%) | 構成評価件数 (比率%) | 処理時間 (hr) (比率%) |
|---------------|----------------|---------------|-----------------|
| [0.125, 0.20] | 95.7 | 39,857 (4.39) | 32.1 (4.92) |
| [0.20, 0.231] | 100.0 | 14,500 (1.60) | 12.2 (1.87) |
| (0.231, 0.25] | 99.6 | 17,356 (1.91) | 14.6 (2.24) |
| (0.25, 0.333] | 61.2 | — | 48 hr で打ち切り |
| 知識なし | — | 907,200 (100) | 653 (100) |

めには、知識が訓練事例よりも汎用的であることが必要である。すなわち、ある訓練事例の条件のもとで獲得した知識が、他の条件の問題解決にも利用可能でなければならない。

問題の条件は、同一種類の線路容量を共通にし、母線構成を2重母線4ブスタイに限定すれば、線路本数と t/l の値のみにより決定する。これは、任意の箇所の潮流値が、 i , l , t の一次式で表わせるからである。

図3(a)の知識の記述からわかるように、獲得した知識は線路の本数についての汎用性は持たないが、線路の潮流値について t/l に関する不等式の範囲だけの汎用性がある。そこで、知識の汎用性を調べるために、ある t/l の値の条件で獲得した知識が、他の t/l の値の問題に対してどの程度有効かを調べた。 $t/l=0.20$ の条件で獲得した知識を、 t/l の値が近い条件の問題に対して利用したときの、有効な知識の比率、問題解決部のパフォーマンス向上を表1に示す。表1の構成評価数、および処理時間の()内は、知識を利用しない場合を100としたときの値である。また、知識なしの場合の構成評価件数は理論値、処理時間は件数から見積った値である。

その結果処理時間は、知識を利用しない場合に比較して、最大で約1/54に削減されることがわかる。また、表1中の四つの t/l の区間から1個ずつ t/l の値を選び、それぞれの値の条件で知識獲得を行えば、 $0.125 \leq t/l \leq 0.333$ の範囲において利用可能な知識を100%獲得できる。このように、適当な間隔(0.03~0.05)の t/l の値の条件で、設計をする前に知識をバックグラウンドで獲得しておけば、常に最大限の処理時間削減効果が期待できる。

さらに、より小規模の設計において知識を利用した場合としない場合とで、得られた最適解は完全に一致し、知識処理による絞り込みによって最適解を見落とさないことを確認済みである。

表 2 事故ケース絞り込み知識の汎用性と利用効果
Table 2 Availability and efficiency of knowledge to reduce test cases.

| 設計条件 t/ℓ | 事故ケース評価 件数 (比率%) | 処理時間 (sec) (比率%) |
|------------------|---------------------|---------------------|
| 0.20 | 963 (57.1) | 192 (69.1) |
| 0.60 | 985 (58.4) | 194 (69.8) |
| 1.00 | 998 (59.2) | 198 (71.2) |
| 知識なし | 1686 (100) | 278 (100) |

4.3 事故ケース絞り込み知識の適用効果と汎用性

条件 $t/\ell=0.20$ の下で、変電所 500 構成成分の事故ケース、約 3 万個を訓練事例として、3.2.1 項に述べた手法で事故ケース絞り込み知識を獲得した。その結果、選択型知識 114 個、排斥型知識 95 個を獲得できた。

これらの知識を他の条件の問題解決に利用した場合の、知識の利用効果を表 2 に示す。効果測定は、無作為に選んだ変電所 100 構成成分の事故ケース評価によって行った。利用効果は t/ℓ の値によらずほぼ一定で、獲得した知識は線路容量の条件に関して汎用的であると言える。

また、事故ケース絞り込み知識を利用することにより、事故ケースの評価件数を約 40%、処理時間を約 30%削減できることがわかる。10%の差は、知識検索などのオーバーヘッドにより生ずる。

4.4 獲得した知識全体の適用効果

EBL によって獲得した構成絞り込み知識と、SBL による事故ケース絞り込み知識とを併用した場合の問題解決部のパフォーマンス向上を表 3 に示す。

評価すべき事故ケース数は、構成絞り込み知識の単独利用の場合に比較してさらに削減されて、知識を全く使用しない場合の約 1/80 となり、処理時間は 1/65 に削減できた。また、得られた最適解も、構成絞り込み知識の単独利用の場合と完全に一致した。

本システムでは、二種類の機械学習方法を、それぞれの特性を活かしながら適用し、現実の実用規模の問題の解決を可能とした。実現した手法は、本論で取り上げた問題のように、解の評価に探索の要素が含まれ、二重にネストした組合せ最適化に帰着される設計、計画問題に対する実用的な解法として広く利用可能であると考えられる。SBL は、その性格上、解の探索手順の決定に適している。また、提案した EBL は、解の品質の比較による探索空間の削減に有効であるが、その利用には、領域理論のフレーム部分の記述を決定できること、事例依存部分を求めるための手続きがプログラムできることが必要条件となる。

表 3 知識の総合利用効果
Table 3 Efficiency of overall acquired knowledge.
知識獲得時の訓練事例条件 $t/\ell=0.20$
設計条件 $t/\ell=0.20$

| | 構成評価件数 (比率%) | 事故ケース評価 件数 (比率%) | 処理時間 (hr) (比率%) |
|------|-----------------|---------------------|--------------------|
| 知識使用 | 14,500 (1.60) | 162,936 (1.25) | 10.0 (1.53) |
| 知識なし | 907,200 (100) | 13,063,680 (100) | 653 (100) |

5. ま と め

本研究では、機械学習技術を適用することにより、対象固有の特性をシステム自らが獲得し、問題解決に利用する設計システムを開発し、常に厳密な最適解を得る効率的な探索を実現可能とした。設計対象は、変電所の母線構成であり、膨大なパターン数の変電所構成の中から目的関数最小の構成を効率的に得ることが求められている。

本システムは基本的には生成検査法によって最適な母線構成を探索するが、生成時に必要な「構成候補を絞り込むための知識」の獲得には論理的に誤りのない知識を得る演繹的学習 (EBL) を用い、知識の誤りが最適解の見落としにつながる「各候補に対する検査 (事故ケースの探索) 順序決定のための知識」の獲得には帰納的学習 (SBL) を用いる。このように、二種類の機械学習手法を、それぞれの特性を活かしながら適用することにより、実用規模の問題の解決を可能とした。

学習に必要な背景知識 (領域理論) を予め入力する従来の EBL では、領域理論を事前に完備することが困難である。そこで、領域理論の記述を汎用的なフレーム部分とそれ以外に分離できることに着目し、学習途中に、物理法則等に基づく手続きによってフレームを具体化し、領域理論を自動生成する手法を開発した。この手法により、数千個の領域理論を網羅的に入力する代わりに、本手法で導入した領域理論のフレーム 8 個、フレームの具体化手続き 7 件を入力することで、構成絞り込みのための厳密な知識 474 個を自動的に獲得できた。

また SBL は、一般に獲得した知識が論理的に正当であることが保証されない難点があるが、本システムでは、知識の誤りが最適解の見落としにつながる検査手順の決定に適用することにより、SBL の特性を活かしている。事故ケース約 3 万個を様々な属性に基づいて分類して作成した決定木から、事故ケース絞り込み知識 209 個を獲得できた。

以上の知識を用いて、現実規模の線路総本数9本の変電所の設計に本システムを適用した結果、知識を利用しない場合に較べて、問題解決における潮流計算回数を約1/80に、処理時間を約1/65に削減でき、現実的な時間内に厳密な最適解が得られることを確認した。

実現した手法は、生成検査法をベースとしているため、組合せ最適化に帰着される設計、計画問題に対する実用的な解法として広く利用可能であろう。今後は、ケーススタディを通じて手法の有効範囲を明確にし、他の組合せ最適化問題への利用も検討していく。

参考文献

- 1) Mitchell, T. M., Keller, R. M. and Kedar-Cabelli, S.: Explanation-Based Generalization; A Unifying View, *Machine Learning*, Vol. 1, pp. 47-80 (1986).
- 2) Bergadano, F., Giordana, A. and Saitta, L.: Automated versus Manual Knowledge Acquisition, *Proc. of the 1st JKA W '90*, pp. 301-313 (1990).
- 3) 辻野克彦, 西田正吾: 帰納的学習と演繹的説明づけに駆動された知識獲得システム: KAISER, 人工知能学会誌, Vol. 7, No. 1, pp. 149-159 (1992).
- 4) 岩本雅彦: 解品質の比較解析による効率化学習, 第7回人工知能学会全国大会論文集, pp. 229-232 (1993).
- 5) Yamamura, M. and Kobayashi, S.: Towards Unifying EBL and SBL to Solve Imperfect Theory Problems, *PRICAI 90*, pp. 1-6 (1990).
- 6) 松田 聖, 矢部邦明ほか: 機械学習を用いた変電所機器構成設計システムの開発, 情報処理学会第94回人工知能研究会資料, 93-14, pp. 103-110 (1994).
- 7) Quinlan, J. R.: Induction over Large Data Bases, Technical Report HPP-79-14, Heuristic Programming Project, Stanford Univ. (1979).
- 8) 荒木裕浩, 山村雅幸, 小林重信: 背景知識を利用した領域知識の逐次的学習, 第11回知識・知能シンポジウム論文集, pp. 87-92 (1990).

(平成6年7月8日受付)

(平成7年1月12日採録)

小林 正明 (正会員)

1965年生。1988年、東京大学工学部原子力工学科卒業。同年より(株)日立製作所エネルギー研究所に勤務。電力分野に対する知識工学、近年は特に機械学習技術の適用に関する研究に従事。



の研究に従事。

山田 直之 (正会員)

1953年生。1976年大阪大学工学部原子力工学科卒業。1978年同大学院原子力工学専攻修士課程修了。工学博士。同年(株)日立製作所入社、同社エネルギー研究所勤務、現在に至る。その間、1986年米国オハイオ州立大学客員研究員。設計、制御等への人工知能の応用研究に従事。人工知能学会、日本原子力学会、AAAI、IEEE各会員。



小林 康弘 (正会員)



1970年東京大学工学部原子力工学科卒業。1975年同大学院原子力工学専攻博士課程修了。同年(株)日立製作所入社。1978年より同社エネルギー研究所勤務、現在に至る。プラント設計自動化に関連した研究開発等に従事。工学博士。人工知能学会、電気学会、日本原子力学会、AAAI、IEEEなどの会員。

伊藤 順子



1985年日本女子大学家政学部物理学科卒業。同年、(株)日立製作所入社。現在、システム事業部に勤務。プロセス産業分野CIMの計画・開発に従事。

矢部 邦明



1956年生。1980年東京大学工学部電気工学科卒業。同年東京電力(株)入社。1992年よりシステム研究所AI研究室にて電力系統への知的システム技術の応用に従事。電気学会会員。

松田 聖 (正会員)



1949年生。1971年早稲田大学理工学部電気通信学科卒業。1976年同大学院博士課程修了。工学博士。同年富士通(株)入社。OS、オンラインシステムおよび人工知能等の研究に従事。1987年より東京電力(株)。現在、同社システム研究所。研究分野は人工知能、神経回路網理論等を中心に、コンピュータサイエンス全般に興味をもつ。電子情報通信学会、ソフトウェア科学会、人工知能学会、ACM、IEEE、NY科学アカデミー各会員。米国数学会評論員。