


人間との対話に基づくロボットの行動知能形成に関する研究

全
部
目
録



人間との対話に基づく
ロボットの行動知能形成に関する研究

稲邑 哲也

ついでに小説のついでに 読者のために小説のついでに

目次

目次

1 序論	1
1.1 本論文の概要	3
1.2 本論文の背景と目的	3
1.3 本論文の構成	6
2 人間との対話に基づくロボットの行動知能形成	9
2.1 はじめに	11
2.2 人間と知的機械との対話	12
2.2.1 機械と人間との間のインタフェース	12
2.2.2 自動運転システムにおける人間と機械の対話	13
2.2.3 エキスパートシステムにおけるユーザとの対話	15
2.2.4 自然言語による機械との対話	17
2.2.5 実世界指向のヒューマンコンピュータインタフェース	18
2.3 人間とロボットとのインタラクション	20
2.3.1 従来のロボット研究における人間の役割	20
2.3.2 ユーザとの視覚の共有によってインタラクションを行なうロボット	21
2.3.3 動作によるロボットとのインタラクション	22
2.3.4 自然言語による人間とロボットとの対話	23
2.3.5 実世界環境におけるロボットとユーザとの対話	24
2.4 人間共存型パーソナルロボットにおける行動知能の形成	26
2.4.1 日常空間へ進出する人間共存型パーソナルロボット	26
2.4.2 先天的行動知能を埋め込む事のできないパーソナルロボット	26
2.4.3 経験の蓄積に基づく行動知能の発達	27
2.4.4 経験の蓄積に基づく個人への適応	27
2.4.5 ロボットから人間への能動的な情報伝達	28
2.4.6 自然言語を用いた行動知能の形成	29
2.5 Bayesian Network を利用したロボットの行動知能の形成	30
2.5.1 統計的な行動知能の表現	30
2.5.2 Bayesian Network による確率的推論モデル	31
2.5.3 Bayesian Network を用いた対話経験の表現	34
2.5.4 Bayesian Network を用いた経験に基づく行動決定	36
2.5.5 Bayesian Network を用いた適切な発話の生成	37
2.5.6 Bayesian Network を用いた言語情報とセンサ情報の結合	37

2.5.7 Bayesian Network を用いる利点	38
2.6 本章のまとめ	44
3 対話経験の蓄積に基づく自律行動の獲得	45
3.1 はじめに	47
3.2 Bayesian Network を用いた対話経験の蓄積に基づく行動獲得	48
3.2.1 オンライン教示学習のための行動決定モデル	48
3.2.2 Bayesian Network による表現の利点	48
3.3 対話的教示方法を用いた移動ロボットの自律行動獲得	50
3.3.1 移動ロボットによる障害物回避実験への応用	50
3.3.2 行動決定の確信度による対話の制御	52
3.3.3 重み付け経験蓄積法に基づく事前確率の補正	53
3.4 仮想移動ロボットにおける自律行動の獲得実験	58
3.4.1 対話経験に基づく確率モデルの獲得実験	63
3.4.2 環境の変化への対応	64
3.4.3 不確実なセンサ情報への対応	68
3.5 実機移動ロボットにおける自律行動の獲得実験	69
3.5.1 移動ロボット:Hyper Mouse	69
3.5.2 ステレオ視覚による視差情報の取得	69
3.5.3 視差情報から距離情報への変換	70
3.5.4 実画像処理におけるセンサノイズへの対応	75
3.5.5 実環境における対話学習実験	75
3.6 本章のまとめ	79
4 対話経験の蓄積に基づくユーザへの適応化	81
4.1 はじめに	83
4.2 移動ロボットの障害物回避タスクにおける個人への適応	84
4.2.1 過去の経験の内省による行動決定モデルの最適化	85
4.2.2 推論のエラー値の有効性の検証	85
4.2.3 GA を用いた状態空間の最適化	86
4.3 相互情報量規準に基づく状態空間の最適化	91
4.3.1 障害物回避タスクでの状態空間の最適化	91

4.3.2 相互情報量を用いたセンサの重要度の評価	96
4.3.3 推論のエラー値と相互情報量の双方を用いた状態空間の評価法	97
4.4 個人に適応した語彙の獲得	98
4.4.1 色名と色パラメータの結合関係の表現	98
4.4.2 対話経験の蓄積に基づくモデルの更新	99
4.4.3 推論のエラー値に基づく状態空間の形成	99
4.4.4 新しい色名の追加	103
4.4.5 ユーザへの負荷軽減への展望	105
4.5 本章のまとめ	112
5 対話と自律行動に基づく環境知識の獲得	113
5.1 はじめに	115
5.2 対話に基づく環境地図の獲得	116
5.2.1 ビューシーケンスによる環境地図の表現とナビゲーション	116
5.2.2 自律的な環境地図の獲得	116
5.2.3 ユーザとの対話に基づく環境地図の更新	121
5.2.4 ビューシーケンスを用いた環境変動への対応	125
5.3 視覚情報に基づく人間の行動の観察	129
5.3.1 フレンドリーアーティファクトによる人間行動の観察	129
5.4 対話に基づく人間の行動の把握	132
5.4.1 Bayesian Network による環境情報の表現	132
5.4.2 Bayesian Network による環境情報の推定	133
5.4.3 新しい状態の追加	134
5.5 対話と自律行動に基づく環境知識の獲得実験	136
5.5.1 日常空間における人間活動の把握	136
5.5.2 移動ロボットにおける荷物配達行動への応用	140
5.6 本章のまとめ	144
6 対象の局在性に基づく適切な対話の生成	145
6.1 はじめに	147
6.2 対象の局在性に基づく発話生成	148
6.2.1 対話生成の適切さの評価基準	148

6.2.2	対象の局在性に基づく発話	149
6.2.3	必要十分な量の発話生成	151
6.3	曖昧性解消のための発話生成	153
6.3.1	対象物体指示における曖昧性解消行動	153
6.3.2	Bayesian Network を用いた対象の同定確信度の算出	153
6.3.3	対象の局在性に基づく対話制御	157
6.3.4	仮想環境における発話生成実験	157
6.4	発話行為と実世界への行動を伴う曖昧性の解消	166
6.4.1	発話行為と物理行動の統合	166
6.4.2	上半身ヒューマノイド型ロボット	167
6.4.3	実環境における対象物の同定実験	169
6.4.4	使用可能な言語表現が限定されている場合の対象物同定実験	170
6.5	実環境における人間発見タスクへの応用	174
6.5.1	屋外移動ロボットによる人間発見行動	174
6.5.2	対話による協調行動を前提とした人間の発見処理	175
6.5.3	対話による協調行動を前提とした人間の発見実験	177
6.6	本章のまとめ	181
7	言語情報と行動知能との結合関係の獲得	183
7.1	はじめに	185
7.2	自律行動の生成を伴う統語解析	187
7.2.1	構文解析部	188
7.2.2	意味文法を用いた意味解析	193
7.2.3	シンボル情報と物理パターン情報の変換	194
7.3	統語解析部の実装	196
7.3.1	単語辞書の定義	197
7.3.2	意味文法の定義	197
7.3.3	文法規則と意味文法コードの定義	202
7.3.4	意味解釈の実行	202
7.4	対話に基づく新しい単語の獲得	206
7.4.1	ディクテーション機能を用いた未知単語の検出	206
7.4.2	未知単語に対する意味文法要素の類推	207
7.4.3	単語の意味の獲得	208

7.4.4	未知語への対応の限界点	210
7.5	本章のまとめ	212
8	ヒューマンロボットインタラクションシステム:PEXIS	213
8.1	はじめに	215
8.2	人間とロボットとの対話を管理する機構	216
8.2.1	自然言語処理	217
8.2.2	短期的な記憶の管理	217
8.2.3	経験データベース機能	218
8.2.4	ロボットへの指令の生成	219
8.2.5	Bayesian Network による推論部	220
8.3	ユーザインタフェース	223
8.3.1	インタフェースデバイスのプラグイン機能	223
8.3.2	音声認識インタフェース	224
8.3.3	音声合成インタフェース	225
8.3.4	キーボードインタフェース	225
8.3.5	ジョイスティックインタフェース	225
8.3.6	サーバクライアント形式による携帯端末の利用	225
8.4	ロボットと PEXIS との接続環境	227
8.4.1	PEXIS とロボットの通信プロトコル	227
8.4.2	システム基本プロトコル	227
8.4.3	対話プロトコル	229
8.4.4	推論プロトコル	230
8.5	経験の蓄積と学習の機能	231
8.5.1	経験データの標準化	231
8.5.2	経験管理プロトコル	232
8.6	総合実験	235
8.6.1	荷物配達タスクへの応用	235
8.6.2	携帯型ユーザインタフェースの活用	237
8.6.3	PEXIS の複数ロボット間対話への応用	240
8.7	本章のまとめ	244

9 結論と今後の展望	245
9.1 本論文の結論	247
9.1.1 人間との対話に基づくロボットの行動知能形成手法	247
9.1.2 ユーザとの対話に基づく行動知能の後天的形成	247
9.1.3 パーソナルロボットとの対話を実現する基盤システム	248
9.2 課題点と今後の展望	250
9.2.1 言語獲得研究への展望	250
9.2.2 人間機械協調システムへの展望	250
9.2.3 日常空間に進出するロボットへの展望	251
9.2.4 脳の情報処理システムへの展望	251
参考文献	258
付録A	276
A.1 Bayesian Networ における再帰的な確率伝播計算法	279
A.1.1 Chain 型ネットワークにおける確率伝播	280
A.1.2 Tree 型ネットワークにおける確率伝播	281
A.1.3 Poly Tree 型ネットワークにおける確率伝播	282

第 1 章

序論

1.1 本論文の概要

近年、オフィスや家庭など、一般のユーザが活動する日常空間で行動する事を目的としたパーソナルロボットが注目されて来ている。ロボットがこのような環境で行動するためには、その環境の知識だけでなく、ユーザに関する知識や、ユーザに合わせてどのように自律行動を行なうか、という行動のための知識を後天的に獲得する必要がある。しかしながら従来の研究の枠組では、開発者が使用される環境を想定してロボットに知識を埋め込むなどして、開発者が先天的な知識を与えている事が多かった。

本論文では、日常空間においてロボットが適切に行動する事ができるように、ユーザとロボットとのインタラクションに注目し、そのインタラクションの経験を用いて柔軟な行動知識を後天的に獲得する事を目的とする。まず、経験から抽出した知識を、固定的ではなく環境の変動に応じて柔軟に変更して表現するための、確率的な知識表現を提案する。次に、その知識表現を用いて段階的に自律行動を獲得する手法、ユーザの嗜好や習慣などに適応する手法、および、使用される環境に関する知識をロボットが自発的に獲得する、などのパーソナルロボットに必要な要素行動を実現する。

1.2 本論文の背景と目的

従来のロボティクス研究では、ロボット自身のセンサーで外界を認識し、目的の仕事達成のためにプランニングを行ない、自律的に行動する事が大きな目標であり、前提であった。しかしながら近年のロボットの形態は工場で使用されていた単純な仕事を行なうロボットから、オフィスや家庭、病院など、人間が日常生活を営む環境において活動するロボットに注目が集まるようになってきた。このようなインフラストラクチャが十分に整備されていない実環境において、ロボットが完全に自らの能力のみで自律行動する事は大きな困難を伴う。この問題は、実環境の状況を認識させる事を目的として進められてきたコンピュータビジョンの研究における問題点と同じ要素を共有していると言える。なぜならば、例えば人間であっても、社会生活を営むためには、その社会を長時間観察し、環境とインタラクションを行ないながら、徐々にルールや習慣などを獲得して行くからである。逆に言えば、ロボットの開発者が前もってロボットが活動する環境を全て予測し、その環境に沿った自律行動を埋め込む事は到底不可能である。近年注目されてきている、実環境で行動するロボットを実現するには、従来取られてきたロボティクスの研究アプローチでは、人間が日常生活を営む空間をロボットが理解する事はできず、限界に達してしまう。

この問題に対して、ロボティクス研究は環境とのインタラクションを通じて学習を行なう研究パラダイムを生み出してきた。ロボットは目的を達成するための手段を知らない状態で

行動を開始し、試行錯誤しながら適切な手段を学習して行く。強化学習やニューラルネットを用いた数多くの学習に関する研究は、先に問題となった、開発者がすべてを予測できないという問題に対して解決の糸口を示したかのように見えた。しかしながら、学習に関する研究の多くの枠組は、開発者が準備した学習問題空間の中でロボットが探索を行なうタスクを実行しているだけであり、あらかじめロボットの行動を予測して学習のための条件を整備する、という、開発者の労力がロボットの行動の質を決めている状況に変わりはない。

日常空間で行動するロボットにおいて、従来のロボットとの根本的な要素の違いは、ロボットを使用するユーザが存在する、という事である。今までの自律行動を目指して来たロボット、学習をするロボットなどは、ロボット自身と外界環境との関係を扱うシステムであったが、日常生活で行動するロボットは、ロボット自身、環境、ユーザの3つの主体が密接に関係する状況を扱う必要がある。新しくユーザという主体を効果的に活用する事によって、ロボティクスの研究パラダイムは大きく変化する事になる。例えばロボットに対する教示という研究分野が存在する。開発者が想定していない行動をロボットに行なわせる場合に、ユーザが行動に関する知識を教示する事によって、自由度の高い行動を後天的に与える事が可能になる。しかしながらこの教示行動はユーザからロボットへ一方的に情報が流れるのみであり、ロボットからユーザへの情報の流れはほとんど活用されていなかった。一方的な情報の教示はレベルの違いはあるが、開発者が知識を埋め込むところを、代わりにユーザが埋め込んでいるだけであって、本当の意味でのインタラクションとは言い難い。

一方、ユーザとのインタラクションを実用レベルで活用しようとしているのが、HCI(Human-Computer Interaction)の研究分野である。コンピュータを使用するユーザをサポートする事を大きな目標としているこの分野では、システムエージェントがユーザとのインタラクションを通じて、コンピュータを操作するためのヒントを提示したり、ユーザの嗜好や習慣などに応じて挙動を変えるなど、ユーザの負担を軽減するための研究成果を多く生み出している。このHCIは、先に述べたようなロボティクスに存在している問題点を解決するのに有用な要素を多く持ちながら、容易にはロボット研究に応用できない問題を抱えている。それは、コンピュータ上で行動するシステムエージェントと、実際の物理世界で行動するロボットエージェントの間の格差があまりにも大きい点である。コンピュータシステム上のエージェントは、例えばHTMLで記述された、言わばインフラストラクチャが整備されたインターネット空間を探索して情報を集めてくるが、ロボットエージェントは自らの行動を介して物理世界の情報を集めるしかない。すなわち環境とエージェントのインタラクション、エージェントとユーザのインタラクション、この双方を同時に扱う必要があるのがロボティクスの難しさであり、双方を同時に扱うエージェントの研究は皆無と言って良い。

本論文では、これらの背景をふまえ、ロボットが環境およびユーザとのインタラクション

を介して、ユーザが活動する日常空間において行動するロボット(パーソナルロボット)の実現を目的とする。このようなパーソナルロボットにおいては、始めから開発者が自律行動のための知識を搭載して完全な自律行動を目指すのではなく、ユーザがロボットとインタラクションを行ない、人間が社会生活のルールや習慣を獲得するのと同じように、ロボットが日常空間での行動知識を獲得する、というアプローチが重要になってくる。このアプローチのキーとなる概念は、ユーザとロボットとの間に交わされたインタラクション結果を経験として活用する事である。本論文は、この経験を活用して、自律行動の戦略獲得、ユーザ個人の嗜好や習慣への適応、環境知識の獲得、などを実現する事を目的とする。このアプローチにより、開発者が想定していない環境へ進出し、ユーザの手によって後天的に日常空間に適応するロボットの実現が可能になる。

1.3 本論文の構成

本論文は全9章から構成される。まず第2章で、ロボット、人間、実環境の3つを統合するインタラクションモデルを提案する。第3章以降は、大きく二つのパートに分けられる。前半の第3章から第5章までは、パーソナルロボットが対話を通じて後天的に行動知能を形成する手法について述べる。後半の第6章から第8章までは、ロボットと人間の間の言語による自然な対話、状況に応じた適切な対話、などを実現するための対話システムを支援する手法について述べる。最後に第9章で結論および今後の展望について述べる。

第2章「人間との対話に基づくロボットの行動知能形成」では、従来古くから研究されてきた、人間と機械との対話の問題に注目し、一般の機械システムやコンピュータを対象とした対話の研究と、ロボットを対象とした対話の研究の違いについて、過去の研究例を整理しながら述べて行く。そして実世界で行動するロボット、特にパーソナルロボットにおける対話の重要性を述べ、ロボットと人間との対話を経験として蓄積するアプローチの有効性について検証する。パーソナルロボットにおける人間との対話行動のうち、経験の蓄積、ユーザ個人への適応、状況に応じた発話生成、言語情報と実環境の結び付け、の問題に着目し、それらを表現する枠組として Bayesian Network を利用する手法について述べる。

第3章「対話経験の蓄積に基づく自律行動の獲得」では、ロボットとユーザとの対話経験を介して、ロボットが後天的に自律行動の戦略や環境に関する知識を獲得する手法について述べる。本章で提案する自律行動の獲得手法では、ロボットの自律的な学習機能と、ユーザとの対話、すなわち教示情報の双方を有効的に活用する。経験を蓄えるまでは、ロボットはユーザからの教示情報を元に行動を行なうが、ある程度経験を積みユーザからの教示が無くとも自律的な学習を行なう。この手法は従来の Human-Computer Interaction から Human-Robot Interactionへの発展を支える重要な指針となっており、本論文を通じて最も基本的な概念となっている。

第4章「対話経験の蓄積に基づくユーザへの適応化」では、ロボットが、ユーザ固有の癖や嗜好に応じて適応する手法について述べる。この場合にも過去にロボットとユーザが対話を行なった経験を利用する事を基本のアプローチとする。Bayesian Network による行動/対話モデルの欠点の一つは、あらかじめ開発者がネットワーク構造をロボットに与えなければならない事であり、本来のパーソナル化を目指す方向性とは矛盾してしまう。そこで、Bayesian Network の状態空間の形成を後天的に行なうために、過去の対話経験と結びつきの合うような状態空間を新しく形成する手法を提案する。そして移動ロボットにおける障害物回避タスクや、視覚探索タスクなどへの応用を通じて、ユーザへの適応化手法の有効性を確認する。

第5章「対話と自律行動に基づく環境知識の獲得」では、開発者があらかじめロボットに埋め込む事のできない、ロボットが活動する環境に関する知識を後天的に獲得する手法について述べる。従来の研究では、ロボットがそのような環境の情報を得る際にはセンサ情報を元に不完全な環境地図を作成するか、GPS やバーコードなどのインフラストラクチャを用いる事が多かった。ここで、人間と共存する事を前提としたロボットであれば、人間との対話を利用する事で両者の利点を兼ねそろえた環境知識の獲得が可能となる。すなわち、普段は自律行動によって環境知識を獲得し、不完全な情報がある場合にはユーザとの対話を活用するアプローチを取る。具体的な環境として、オフィスや病院などを想定し、ビューシーケンスと呼ばれる視覚に基づく地図表現によって部屋の配置関係を自律的に獲得させる。また、複数のユーザとの対話結果から、「いつ誰がどこにいるか?」という、部屋の名前や環境の中で活動するユーザの情報を獲得させる事を目的とする。

第6章「対象の局在性に基づく適切な対話の生成」では、ユーザがロボットに対して曖昧な指示を出した場合に、ロボットが行なうべき適切な対応行動を発話行為を介して決定する方法を提案する。ここでロボットが対応すべき行動を、「それを取って」というような対象物の参照行動に限定し、状況に応じて適切な発話を生成させる事を目標とする。ここで、実世界の環境内で対象物を参照する行動は視覚処理との関係が深く、視覚探索処理との密接な対応が必要となる行動である。そこで対象の局在性というパラメータを導入し、これを用いて発話を制御する手法を提案する。ユーザが曖昧な参照表現をした場合には、参照物と他の物体との混同が起こらないように、すなわち局在性が満たされるように視覚探索や発話行動を行なう。このアプローチによる対話がユーザにとって分かりやすい対話行動となる事を示す。

第7章「言語情報と行動知能との結合関係の獲得」では、ロボットと人間との自然な対話を実現するための、自然言語の処理、および言語情報とロボットの行動知能との結合関係の獲得について述べる。自然言語の解釈には曖昧性の解消という大きな問題が残されているが、この曖昧性の解釈の部分に本論文のアプローチである、対話の経験から得られた知識を活用する方法について述べる。また、新しく対話の中で使用された単語を検出し、その新しい意味を後天的に獲得する手法についても述べる。

第8章「ヒューマンロボットインタラクションシステム: PEXIS」では、各章で論じた手法をソフトウェアシステムとして統合する手法について述べる。このシステムにより、ロボットと人間との自然な対話を提供し、その対話経験の蓄積から自律行動を獲得し、ユーザ個人の環境に適応して行く、ヒューマンロボットインタラクションの枠組を実現する。また単なる人間とロボットのインタラクションだけでなく、ロボット同士のインタラクション、すなわちマルチロボット環境における協調作業や、遠隔操作ロボットにおける学習問題などへの応用可能性について検討する。

第9章「結論と今後の展望」では、各章で展開された議論をまとめ、本論文の結論を示す。また、対話経験に基づくロボットの知能形成手法における今後の展望について述べる。

Figure 1.1 に本論文における各章の関係図を示す。

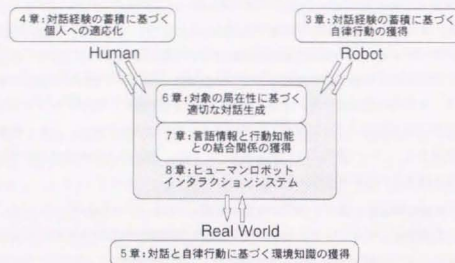


Figure 1.1: Relationship between each chapter in this thesis

第2章

人間との対話に基づくロボットの行動知能形成

2.1 はじめに

近年、日常空間に進出し、人間をサポートするパーソナルロボットの実現についての可能性が議論されてきている。このようなパーソナルロボットにおいては、従来のロボティクス研究が取っていた、行動知能を先天的にロボットに埋め込むアプローチは不適切であり、行動知能を後天的に獲得する事が必要とされる。

本章では、後天的に行動知能を獲得するために、ロボットとユーザの間の対話を経験として活用する事の必要性について述べ、対話経験から行動知能を形成する手法を提案する。

このような「ロボットと人間との対話」は、従来古くから研究されてきた、「人間と機械との対話」研究における成果を利用する事ができるように思われる。しかし、これらの研究では「ロボティクス」研究に必要な物理環境とのインタラクションに関する知見が少なく、単純に「人間と機械との対話」研究成果を「ロボティクス」研究に適用する事が難しかった。そこで、ロボットシステムと人間とのインタラクションにおける問題点を整理し、「人間」「物理環境」「ロボット」の3者の関係を有機的に結合し表現するモデルの必要性について述べる。そして対話に基づいてこのモデルを後天的に獲得するために、統計的表現が有利である事を示し、ベイズ統計理論に基づく Bayesian Network を用いた行動知能の形成手法について述べる。

2.2 人間と知的機械との対話

道具は人間の身体機能を延長するものとして発明され、機械はある一定の物理的作業を継続して行なうための、道具の延長上に位置付けられるものである。すなわち機械は人間の機能を補い、人間には実現不可能な物理的作用を行なうものである。と言える。しかしながら、近年の家電製品などを筆頭とする機械は、原始的な道具や物理的な作用を補助する機械などとは性質が異なる物になってきている。家電製品の一つであるビデオがその良い例である。物理的には電磁波で送信されてくる信号を受信し、符合化された情報を復号し、さらに情報を符合化して磁気テープ上に保存する。このように、人間が自分の身体を延長として使用してきた道具や機械と異なり、情報機械は人間が直接には操作できない抽象的な情報を扱う道具である。しかしながら機械とは通常通り物理的なインタフェースで結ばれている。このため、抽象的な機械内部の情報概念と、機械外部の物理的なインタフェースの乖離が生じ、タイマー録画を行なう際にどのような手順でボタンを押せば良いのかが分からなくなるなどの障害が起こる。

この問題は認知心理学の側面から、メンタルモデルの形成の失敗と言う形で表現される。メンタルモデルとは、機械内部で動作する物理的な作用の状態を、ユーザサイドで理解する際の認知モデルの事である。このメンタルモデルが正確に形成されていない場合、ユーザは機械の使用方法が理解できずに混乱してしまう。

このメンタルモデルという考え方は、道具、機械、などのレベルだけではなく、ロボットを使用する時や人間同士の対人関係を成立させる場合にも重要なものとなってくる。対人関係の場合は言語的なコミュニケーションがそのメンタルモデルを形成する手段になるであろう。もし、常識を逸脱したような行動を取る人間がいた場合、相手の言動を理解するためのモデルが成立せずに、コミュニケーションは成立しない。これと同じく、ロボットと人間との間のコミュニケーションも、メンタルモデルを構築する上で、非常に重要な要素になってくる。

本節では、ロボットを使用するユーザにとって、どのようなメンタルモデルを形成すれば良いのか、という事を議論するために、まず、一般的な知能機械と人間との対話に焦点を絞る。そして問題点などを挙げ、ロボットと人間とのコミュニケーションに必要な要素を考察して行く。

2.2.1 機械と人間との間のインタフェース

近年、インタフェースという言葉がシステム構築の分野において重要視されている。システム開発における労力の半分以上はユーザマニュアルの作成に費やされている、とも言われている。また、UNIX系のワークステーションで普及したX-windowシステムにおいても、誕生した当初は貴重なコンピューティング資源を直接の目的である計算とは関係のない、GUI

(Graphical User Interface)に費やす事が批判される事も少なくなかった。

これは機械システムが複雑化する一方で、そのシステムの動作速度、信頼性、拡張性、などの向上が主な目的として開発が進められてきた事が原因となっている。すなわち、ユーザがいかにその機械システムを使用し運用するか、という事に注意が注がれていなかったのである。ユーザがシステムを運用する際に生じる問題点が重要視され始めたのは、メカニカルな機械システムに計算機システムが適用されるようになってからである。今後のロボットシステムにおいてもこの傾向は同様に見られる事になるであろう。むしろ、ユーザとシステムの関係が問題になる分野のうち、最も重要で注目される分野となる事は明らかである。

Figure 2.1はシェリダンの「監視制御モデル」から派生したモデルである[Card 91]。この図は左から、タスク、タスクマシン、ユーザ会話型マシン、ユーザ、の4つの部分から成る。このユーザ会話型マシンの概念は非常に重要であると考えられる。なぜならば、このタスクマシンとユーザ会話型マシンの境界線は非常に密接しており、日常生活で受け入れられる電気製品などでは、この二つのマシンが同一である場合が非常に多いからである。

一般に普及しているコンピュータはその良い例である。このようなマシンではタスクを実行する知能と、ユーザと会話する知能が同一レベルで考慮されるので、システムを開発する際にその区別が不明瞭になり、ユーザ会話型マシンの位置付けが曖昧になってしまう危険性がある。

一方で、この境界線を明確にし、モジュール化することにより、二つのマシンを独立に開発できる、という利点を生むこともできる。

2.2.2 自動運転システムにおける人間と機械の対話

監視制御(Supervisory Control)とは、オペレータに委ねられるタスクを遂行するために自動化を利用するが、制御されるマシンやシステムのオペレータに対する制御可能性は保存されているやり方を言う。この制御方法は主に航空機のcockpitシステムに用いられていた。しかしこの監視制御はユーザとのコミュニケーション、システムからの情報提示を本質的な要素として含んでおり、人間とシステム間の相互作用が破綻してしまうと、重大な制御不能状態となってしまう事がまれにある。

1994年に名古屋空港で起こった中華航空機の事故では、このような人間と機械システムの間に存在する問題を痛感させられる事となった。

1994年4月26日名古屋空港で発生した中華航空のエアバスA300-600型機の墜落事故は、人間の操作にコンピューターが反発したために起こった。ハイテク機ではパイロットの負担が大幅に削減された一方で、「自動化への過信が安全を脅か




Figure 2.1: Triple agent model for human-computer interaction[Card 91]

す結果となった」と専門家は指摘する。エアバス側は事故を教訓に、一部手動を優先するシステムに機能を変更、すべての同型機を改修している。
(時事通信の記事より引用)

この事故の直接の原因は、機長の訓練不足であったようである。決して人間の操縦にコンピュータが反発したためではない。この事故が起こったのは着陸直前の事であった。機は手動操縦で着陸体制に入っていたが、間違えて着陸より直しのレバーを作動させた。このため機は高度を上げ、推力を増し上昇する事となった。しかしながら、乗員はなぜ機体がそのような挙動を示すのか理解できず、強引に手動で機首下げを行ない、着陸を試みようとした。しかしながら自動着陸モードとの動作の矛盾が生じ、失速し墜落に至った。

事故が起こった後によく聞かれた言葉は、「自動操縦が簡単に解除できなかったのが問題である。操縦輪に力を加えた段階で解除させる構造にすべきだ」というものであった。しかしながら、自動操縦モードでありながら、誤って操縦輪を動作させてしまい、自動操縦が解除されているのに気付かず墜落してしまった事故も過去発生しており[加藤 99]。この事故からは、「簡単に自動操縦が外れてはいけない」という結論が導き出されてしまう。

このように、自動操縦が前提となる航空機や、その他の機械システムにとっては、ユーザとシステム間の物理的インタフェース、情動的インタフェースをどのように設計すべきか、が大きな問題点となっている。この航空機の場合には、情動的インタフェースが不十分であっ

たと言えよう。情報の提示や、指示の確認など、ユーザシステム間のコミュニケーションが積極的に取られるシステムであれば、このような事故は未然に防ぐ事ができる可能性が大きい。

このような問題は原子力発電のプラントにおける、監視作業員とシステムの間の問題[古田 99]や、車の知的自動運転システムとドライバー間の問題[鷲野 99]とも共通しており、どのタイミングでシステムがどの程度の自律性を持ち、どの程度の仕事を人間に要求するのか、の設計が非常に難しい。

Figure 2.2 はロボット/コンピュータを自動化させるための人間とロボットのインタラクションを、10段階のレベルに分類したものである[Card 91]。ロボットを初めから完全に自動化させることは不可能であるため、第1段階のように、人間が初期状態を操作し、コンピュータが実行できる形に整えた後、実行依頼を行なう、という段階からスタートし、徐々にコンピュータが行なうタスクの質を高めて行く、という考えのもとに作成されている。産業用ロボットの分野においても、この思想と同等な設計法が提案されており、ロボットが完全に自律で行動する状況だけでなく、オペレータと協調しながら作業を行う設計が求められるようになってきている[Schraft 94]。

2.2.3 エキスパートシステムにおけるユーザとの対話

プロダクションシステムや、エキスパートシステムは、知的機械と人間との対話という分野において、過去最も印象に残った研究の代表例と言えるであろう。その中でも有名なものが、医療診断の分野で注目を集めた MYCIN[Shortliffe 76] がある。

このような初期の頃のエキスパートシステムは、膨大な量の論理的知識を背景にして、的確な推論を実行するという、工学的転換をむかえる事によって、一躍その有用性を認められながらも、現実的には推論がうまく行かない問題が露呈した。

この原因となった障壁は二つ存在した。一つ目は、厳密な論理対系に基づく、真が偽かの完全に白黒がついてしまうような推論は現実には人間は行なっておらず、現実的な問題に不適当であるという事。二つ目は、膨大な知識全体を論理的に結合して表現すると、結合数が指数的に大きくなってしまい、規模の大きい問題に適用できなくなってしまう事である。

前者の問題に対しては、MYCIN が採用した確信度と呼ばれる要素で問題を回避する事ができたが、後者の問題に対しては、決定的な解決策が見い出せず、エキスパートシステムはしだいに注目を失っていった。

この双方の問題をうまく解決する概念を提唱したのが、Kim&Pearl [Kim 83] である。後に Bayesian Network と呼ばれる事になる信念ネットワークに基づく確率的な推論方式をエキスパートシステムに適用するものである。この信念ネットワークは先の指数的に結合数が増大する知識表現とは異なり、互いに関係が近い知識だけを結合させる事によって、推論の性能を

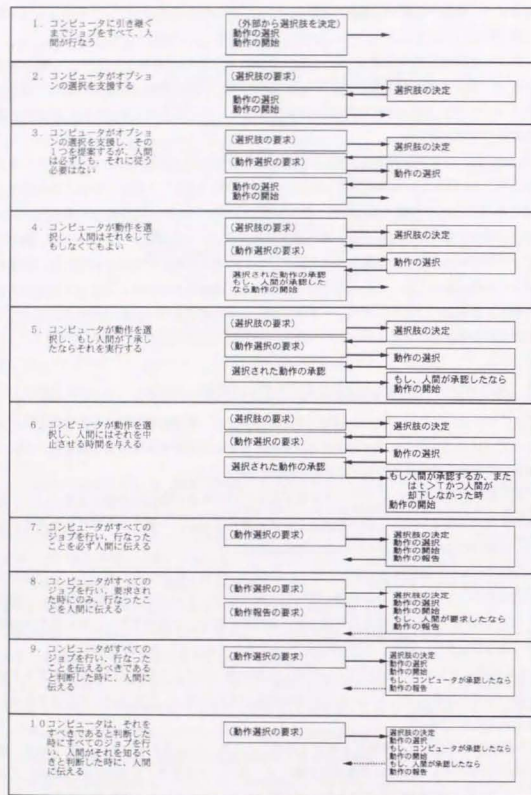


Figure 2.2: Autonomous level for behavior decision in human-computer interaction[Card 91]

落さずに、結合の複雑さを抑える事に成功している。

この信念ネットワークは、下火状態となっていたエキスパートシステムに再び勢いを取り戻させる事となった。David Heckermanによる、リンパ節病診断システム Pathfinder[Heckerman 91]や、Duda.R.による鉱石予測システム PROSPECTOR はこのような、確率モデルに基づくエキスパートシステムである。

2.2.4 自然言語による機械との対話

Terry Winograd の SHRDLU システム[Winograd 76, テリ 89]は Figure 2.3 のような積木の世界で、人間とコンピュータとの自然言語による対話システムを構築した。この世界は、「その赤い箱の上にある緑のピラミッドを掴め」などと自然言語での指示を理解するばかりか、「その箱を取って」などのように曖昧性を含む表現や代名詞表現に対して、曖昧性を解消して意味を推測する機能がかった。しかしながら、このシステムにおいては、統語解析に重点を置いており、曖昧性が解消できるのは、文脈が積木の世界に限定されているからである。




Figure 2.3: A brick world in SHRDLU system

また、この SHRDLU ではユーザのモデルを持っているわけではなく、一般的な人間が使用する言葉についての知識だけを持っており、システムが想定していない特殊な言い回しを使用すれば、システムは理解できず何れも動作を起こさないだけであらう。

長尾の論文「協調的対話の計算モデル」[長尾 92]では、文脈次のように定義している。

その他の情報が与えられるにつれて仮説の優先度に変化する。このような信念や意図を表す仮説の整合的な集合を「文脈」と呼ぶことにする。不完全な背景知識しか持っていない場合に、とりあえず仮説の解釈を与えておき、後になって文脈がより明確になったときに、以前に与えた解釈を修正し、また、より適切な解釈を与えるこ

とができる、という動的な性質を持っている。

この論文での多重文脈モデルは論理式ベースの推論で、Grice[Grice 75]が提案した「協調のための原理」(Cooperative Principle)を論理式で表現し、発話のプラン、信念意図の理解、文脈による曖昧性への対応、などを実現している。

このような文脈や状況に依存した内容解釈が、自然言語処理におけるもっとも困難な部分である。文脈や状況を扱うには、あらかじめ自然言語処理システムの開発者が想定した文脈カテゴリーを準備しておき、それに当てはまる場合にはその特定の文脈に依存した処理を行う、というアプローチが主流であった。前節で述べたエキスパートシステムにおいても自然言語のインタフェースが構築されているが、これも各専門分野ごとに文脈を設定しているに過ぎない。

そのような中で、Lenatらは開発者が文脈などをあらかじめ組み込むことなく、システム自身が新しい概念や文脈依存性を作り出すことのできるシステム:CYCを開発した[Lenat 95]。このシステムでは、新聞などの膨大な量の自然言語文章とともに、写真による画像データをシステムに与え、単語が持つ意味や概念などを写真イメージと関連付け、背景知識として抽出管理する事が可能である。

このように、機械と人間との間で自然言語による対話を行う場合には、開発者が埋め込んだ語彙や文脈だけでなく、システムがユーザとの対話の中から新しい概念や文脈などをくみ取り、発達するアプローチが必要となってくる。そのためには単なる自然言語による入力だけでなく、CYCのような視覚イメージの入力や、動作教示入力などが重要になってくる事は明らかである。

2.2.5 実世界指向のヒューマンコンピュータインタフェース

長尾、暦本らは、従来のHCI(Human-Computer Interaction)研究では、仮想世界やインターネット空間、データベースなど、「情報世界」とユーザとのインタラクションに注目が行きがちであるが、実世界の情報に対してユーザがインタラクションできるシステムが重要である、との提案をし、これを実世界指向インタフェース[長尾 96]と呼んでいる。

その例として、小型携帯端末を利用して、日常生活空間に存在する情報をユーザに視覚化して提示する、Ubiquitous Talker[Nagao 95]や、NaviCamを実現している。これらのシステムは本棚やカレンダーなど、いろいろな場所にバーコードを埋め込み、携帯端末はそのバーコードによって外界を認識し、その状況に適した情報をユーザに提供する。この他にも、GPS(Global Positioning System)を使って道案内や情報提供などを行なうウォークナビ[長尾 95]や、スーパーマーケットにおける情報提供システムショップナビ[長尾 97]など、日常生活空間におけるユーザとシステムのインタラクションにおける、新しい研究パラダイムを示し

ている。

この考え方はHCIの研究において、非常に重要な要素を含んでいる。従来のHCI研究では、エージェントは整備された環境の中で、与えられた情報をユーザに提示していただけない。実世界でのインタラクションを考えた場合、そのユーザが現在実世界の中でどのような場所にいるのか、どのような状況にあるのか、を考慮しなければ、エージェントは適切な情報提示を行なう事はできない。すなわち「情報世界」と「実世界」の双方を考慮するシステムが要求されるわけである。従来のHCI研究をFigure 2.4だとすると、長尾、暦本らの実世界指向インタフェースでは、Figure 2.5のようにユーザとコンピュータのインタラクション、コンピュータと実世界のインタラクションの双方を同時に考慮した構成である。




Figure 2.4: Concept of conventional HCI research




Figure 2.5: Concept of real world oriented HCI research

このような実世界指向のインタフェースの考え方は、ロボットと人間とのインタラクションに対しても重要な指針を示すものである。本2.2節で述べてきたように、ユーザと機械システムが実世界の情報を介さずに対話を行う事は不可能であり、無理に対話を行う事は矛盾や不都合を引き起こす原因となる。次節以降では、実世界指向のインタフェースをロボットと人間との間のコミュニケーションに発展させるための問題点と有効なアプローチについて述べていく。

2.3 人間とロボットとのインタラクション

2.3.1 従来のロボット研究における人間の役割

例えば従来のロボティクス研究の多くは、センサから得られる情報を入力とし、行動を決定し、モーターで外界に物理的アクセスを行なう、という形態が一般的なシステム構成であった、すなわち Figure 2.6 のような構成で表現される形態であり、ロボットを使用するユーザの事はあまり考えられていなかったのが現状であった。むしろ人間はロボットを開発するサイドに位置するべきである、という前提が半ば当然の事として研究が展開されていた、その最も顕著な例が Brooks によるサブサンプションアーキテクチャ (Subsumption Architecture) [Brooks 86] である。このアーキテクチャはセンサ入力と行動出力とをいかに結び付けるか、という当時のロボティクス研究の最大の目的となっていた部分に着目した研究であり、その斬新な発想に世界中の研究者が注目した。このアーキテクチャは、ロボットと実環境とがインタラクションを行なう際の核となるシステムの設計の指針となる方法論でもあり、研究者がいかにその設計法、開発法に注目していたかがうかがえる。




Figure 2.6: Concept of conventional robotics research

ロボティクスの研究が進み、工場の生産現場から、次第に日常生活へのロボットの進出が提案され始めてから、この流れは変わってくる事となる。しかしながら HCI で議論されているようなユーザインタフェースの要素技術をロボット研究に応用しようとした場合、単純に要素技術の連結では Figure 2.7 のような構成となってしまう。この構成では、先ほどの HCI の例で言えば、ユーザと「情報空間」との乖離を生んでしまった構成のように、うまく「ユーザ」「実環境」「ロボット」の間のインタラクションを実現する事ができない。

例えば、長尾らが提唱しているように、ユーザが実世界でどのような状況にあるのかを把握するためには、Figure 2.7 の構成では、左側の HCI エージェントと、右側の Robotics エージェントが乖離しているために、有機的なシステム構成を取る事ができない。

次節以降では、実世界で行動するロボットとユーザとがインタラクションを行なう研究例




Figure 2.7: Concept of simple connection between HCI and robotics

をいくつか紹介し、それらの研究を整理しながら Figure 2.7 の構成で生じる問題点を指摘し、その解決方法について述べて行く。

2.3.2 ユーザとの視覚の共有によってインタラクションを行なうロボット

ロボットとユーザとの視覚情報の共有は、Human-Robot Interaction を行なう際に非常に多くの情報を交換する事ができる手段である。

一番単純な例だと、ロボットが見ている画像を利用して人間が指示を出す例が考えられる。関本ら [関本 95, 関本 96, Sekimoto 97] は、移動ロボットを制御する手法の一形態として、ロボットの得た画像をオペレータの見えるタッチパネルディスプレイに表示し、人間が画像を直接指で指し示し、移動先を決定するシステムを開発している。

また、柴田らは Hyper Scooter と呼ばれる移動ロボット [Shibata 96] 上にユーザとの視覚共有インタフェースを設けている [Shibata 95]。このシステムでは、「何がどのように見えた場合はこのような行動を実行する」という環境情報と行動の関係を単純な指示の積み重ねで表現し、全体として複雑な動作 (例えばスクーターの切返し運転) を組み立てる事に成功している。

これらの研究は、Figure 2.7 での、Robotics 側の環境とのインタラクション処理と、HCI 側のユーザ / ロボットインタラクション処理の統合を可能とする形式の一つであると位置付けられる。これらのシステムは Robotics 側で何が起きているか、という事を画像というモダリティで表現し、必要に応じて画像に変化を加え、ユーザに表示している。つまり、Robotics 側の情報を欠落させないように直接画像で送信しているようなもので、言語情報などで変換するのに比べ、Robot におけるボトルネックが小さい。そのような観点からは視覚を共有し、また視覚だけでなく、音情報や空間情報など、様々な情報を共有する事は一つの方向でもある。しかしながら、大きな問題点として、情報が一方通行になり易い点が挙げられる。ロボットからは画像という密度の高い情報が流れ込んで来るが、ユーザ側からはタッチパネル

のある場所を押す、という単純な情報しか提供できない。

ユーザ側から複雑な指令や、きめ細かい指示を出すには、結局 Robot の段階で一旦情報を解釈する必要がある。

2.3.3 動作によるロボットとのインタラクション

また、直接視覚イメージを用いる方法だけでなく、ロボットに対して人間が動作をする、逆にロボットが動作を行なって人間に意思を伝える、という動作を介したインタラクションも数多く研究されている。

人間の動作によるインタラクション

MIT の Pfinder プロジェクト [Wren 97] は、仮想世界の中のエージェントと、実世界の人間との間を結ぶモダリティは動作であり、人間とエージェントは動作によるインタラクションを行なう。しかしながら実世界に関する情報を取り扱っている部分はユーザの動作を認識するフェーズのみであり、このエージェントシステムは、ユーザと仮想環境の2者間でインタラクションを行なうシステムである。Yoshiike らはリアルタイムに人間のポーズを認識し、ヒューマノイドに動作を指示するためのインタフェースを開発している [Yoshiike 98]。しかしロボットはユーザとのインタラクションを行なうのみで、実環境に対してインタラクションを行なう例については述べられていない。すなわち上記の二つの研究はインタラクションの形態から考察すると、まったく同一の構成であり、従来の Human-Computer Interaction の領域から抜け出していない事がうかがえる。

この問題は、そもそも動作によってロボットに意思を伝達する事が難しい事に起因しており、人間同士の場合でも日常生活において動作によるインタラクションが少ない事を考えれば当然であろう。

ロボットの動作によるインタラクション

一方ロボットが動作を行ない、人間に意思を伝達する試みもなされている。佐藤らは、「表現するロボット」において、動作を介してユーザにその場の状況を知らせる試みを行なっている [Mizoguchi 97, 佐藤 95, 佐藤 96]。このロボットはロボティックルーム内部でシステムがユーザの希望している通りの挙動を示しているかを監視しており、動作を用いてシステムの可視化を行なっている。実環境を観察し、意味を理解した上でユーザに表現して見せる、という行動は、処理の流れが一方通行になっており、ユーザの状況を観察した結果、実環境に対して働きかけを行なう、という双方向の処理の流れにはなっていない。

2.3.4 自然言語による人間とロボットとの対話

自然言語による人間とロボットとの対話に関する研究のうち、最も古くに行なわれた例は、白井ら [白井 85] による WABOT-2 におけるインタフェースであろう。この頃の音声認識システムは発展途上であり、音声によるロボットと人間の対話の可能性を示す一歩となった研究である。

その後、Torrance は自然言語を理解する移動ロボットにおいて自由に動作を指示できるシステムを構築した [Torrance 94]。しかしこの研究の中では、自然言語はキーボードから入力される文のみで音声認識は使用できず、また、あらかじめ組み込まれた行動を対話的に切替えるのみであり、自ら新しい行動を獲得する機能は持ち合わせていない。

佐藤らは、Linta と呼ばれるロボットの上に自然言語対話可能なシステムを構築している [佐藤 92, 安西 96]。このシステムでは自然言語による行動決定の曖昧性を解消するために、ロボットと人間との間で交わされた会話の履歴と、センサ情報を参照する、「前に進め」という発話の後の、「もうちょっと」とは、「もうちょっと前へ進め」という内容である事を推測する機能を持っているが、「ちょっと」という言葉そのものが持っている曖昧性などを扱う部分については言及されていない。

また、Jijo-2 プロジェクト [松井 97a, 松井 95] では、ユーザとの自然な対話を実現するためのシステムを開発している [麻生 98]。このプロジェクトの中では、オフィスロボットがユーザと会話を円滑に行なうためには、次の点が重要であるとしている [松井 98a, Fry 98]。

- システムの能力をユーザに知らせ、ユーザのスキル熟練度に応じた対話を行なう
- ユーザのコマンドとシステムが実行しようとしている処理の確認を取る。
- 対話理解の結果を即座にフィードバックする
- 会話の間違い（言い間違いや誤認識）の修正を可能にする
- 対話や文脈のジャンプを許す
- 会話を開始したり、文脈を変更するためのキーワードを限定する。

しかし彼らの指摘の中には、ロボットとの自然言語による対話を行なう上で、もっとも重要な点が欠けている。それは、新しい語彙の獲得という問題点である。この問題は近年注目されてきているパーソナルロボットにおいて、まだ解決されていない問題の一つである。例えば、Bischoff と Graefe はサービスロボット HERMES においてユーザとの自然言語によるインタラクションを実現しているが、新しい単語を獲得し、ロボットの持つ概念と結合させる機能についてはほとんど述べられていない [Bischoff 99, Graefe 97]。

この自然言語によるロボットとのインタラクションにおいても、2.3.2節で述べたような問題が生じる。自然言語によるコンピュータとの対話研究は1970年代のアメリカの Speech Understanding 計画など、1980年代にかけて数多くの研究成果を生み出した[堂下 98]が、そのいずれもコンピュータシステムの中の閉じた世界を対象としており、ユーザから得た言語に基づいて環境を認識したり、環境に対して行動を働きかけるには、Figure 2.7 の二つのインタラクションシステムが密に関係する必要がある。実世界指向の HCI 研究の中には、実世界で起こっている事を言語に変換し、言語から得られた情報を実世界に還元するコンセプトの研究例もあるが、ロボット研究においてユーザ、ロボット、環境の3者を密接に扱うモデルは提唱されていない。

このような観点からも、ユーザとロボットと環境の関係を表現するモデルに改良が必要となる。

2.3.5 実世界環境におけるロボットとユーザとの対話

以上の議論をまとめると、実世界で行動するロボットとユーザとのインタラクションを実現する上で問題となっていた事は、従来の HCI の要素技術と、従来の Robotics の要素技術の単純な結合ができない事であった。環境とロボットの間のインタラクション、すなわち Robotics と、ロボットとユーザとのインタラクション、すなわち HCI の二つのインタラクションシステムを同時に考慮する事が必要となる例は以下のようなものが挙げられる。

- ・ ユーザからの自然言語による指令を実世界で実行する場合
- ・ ユーザからの指示によって行動を学習して行く場合
- ・ ユーザ個人の違いに合わせて実世界での行動を変更する場合
- ・ タスクが実行不可能に陥った場合にユーザとの対話を用いて解決する場合

これらの問題を解決するには、HCI 側のインタラクションと Robotics 側のインタラクションを統合する必要があるため、本論文では、Figure 2.8 のような、「ユーザ」「ロボット」「環境」の3者を同時に扱う形態のインタラクションシステムの必要性が重要であるという主張を展開する。




Figure 2.8: Concept of Human-Robot Interaction in this thesis

2.4 人間共存型パーソナルロボットにおける行動知能の形成

2.4.1 日常空間へ進出する人間共存型パーソナルロボット

近年、SONY の AIBO [Fujita 97] や、本田技研工業の二足歩行ロボット P2, P3 [Hirai 97] などに代表されるように、人間が生活する環境に進出し、人間とコミュニケーションを行ないながら、日常生活をサポートするパーソナルロボットに注目が集まっている。

古くから日常空間の中で活動するロボットの必要性は求められており、1986 年の病院ロボット [木村 86]、1992 年のオフィスロボット [山本 92b]、1993 年の生活支援ロボット [加藤 93]、近年では家庭内での家事ロボット [Khatib 99]、というように、単純な環境から次第に複雑で、よりユーザとのインタラクションが必要になる環境へのロボットの進出が試みられている。

山崎と安西は、PRIME (Physically-grounded human-Robot-computer Interaction in Multiagent Environment) と呼ばれるプロジェクトの中で、実世界の中で行動するコンピュータの延長として、パーソナルロボットが活躍する環境を提案している [山崎 96, Yamasaki 95, 山崎 95]。このような考え方は、CSCW (Computer-Supported Cooperative Work) の環境におけるコンピュータをロボットに置き換えた、RSCW (Robot-Supported Cooperative Work) [山本 92a, 藤城 95] へと発展するものであり、同じような試みがいくつかなされている [Lee 98, Lesser 99, 武田 97]。

一般のロボットとパーソナルロボットの違いは、「パーソナル」という言葉が示すように、ユーザ個人の生活環境で行動し、ユーザ特有の背景知識などを理解して知的活動を行なうロボットの事である。すなわち物理的な行動を行なう事が可能である。パーソナルコンピュータの延長と考える事ができる。

2.4.2 先天的行動知能を埋め込む事のできないパーソナルロボット

パーソナルロボットは、通常の日常空間で行動する事を前提としたロボットであるため、ロボットは使用される環境に応じて適切な行動を行なう必要がある。しかしながら従来のロボット研究の枠組では、ロボットの行動を決めるのは開発者であり、パーソナルロボットの実現のためには、ロボットが使用される環境を開発者が綿密に分析し、最もふさわしい行動が実現できるような行動知能を設計し、それをロボットに埋め込む必要がある。しかしながら、そのような開発手法で設計された行動知能は、別の環境に適用できる保証はないし、開発にかかるコストも無視はできないものになってくる。

例えば、サービスロボット HERMES は高度な自律性を持つロボット [Bischoff 99, Graefe 97]

で、人間の言葉を理解し、荷物を運ぶ、地図を獲得する、などの行動が可能である。しかしながら、その機能を実現する行動知能のほとんどは開発者によって埋め込まれたものであり、異なる環境において動作させるためには、荷物を認識するための視覚処理や、人間が使用する事のできる言葉の種類などを再設計する必要がある。

2.4.3 経験の蓄積に基づく行動知能の発達

このような問題に対する大きな二つの流れとして、教示と学習がある。教示に関しては、日常空間で行動するロボット以外にも、工場での作業用ロボットにおける Teaching Pendant や、実際に人間が動作を見せて教示する、Teaching by showing [Kuniyoshi 94, 國吉 90] などの研究をはじめとして、ロボットに対して教示を行なう研究が数多く提案されてきた。

しかし、工場とは違った日常空間においては、センサによる環境の表現が変動してしまう場合が多く、ユーザは状況に合わせて教示を何回もやり直す必要がある問題があった。例えば超音波センサによる移動ロボットのナビゲーションの場合や、画像を記憶してナビゲーションに利用する方法などがその典型例である。

一方、そのユーザの負担を軽減するための手法である学習は、自律的に行動モデルを獲得するにも関わらず、ユーザの希望する通りの行動が獲得されるとは限らない。

すなわち、これらの問題点を取り除き、長所を最大限に生かすためには、自ら学習するべき部分は自律的な学習を行ない、ユーザが自分の希望を反映させるために、任意のタイミングで教示を行なう事ができる行動知能の発達システムが求められる。つまり、人間からの教示を含めたインタラクションを通じて学習を行ない、行動知能を発達させる事が重要なポイントであり、この考えは本論文を通して主張される事柄である。

2.4.4 経験の蓄積に基づく個人への適応

HCI の研究分野では古くから、いかに使用するユーザに適応したインタフェースを提供するか、という研究が行われていた。例えば MIT の Patty Meas らによる Interface Agent という概念が有名である [Maes 93, Maes 94]。この研究はおもに機械学習と関連が深く [Langley 97a]、ユーザが示す挙動を入力として、システムの挙動を学習させる問題に帰着して研究が進められていた。実際のロボットにおいても、日常空間でユーザと共に行動するロボットが求められており、個人への適応 (personalization) の必要性は非常に高まってきている。

佐藤らは、日常空間における人間の行動を理解し、その結果を蓄積していく事で、その人間に適合した知的支援を行なうシステムの必要性を述べているが、具体的な行動蓄積の表現方法や、適合手法については述べられていない [佐藤 99a, 佐藤 99b]。

ここで前節で説明した、HCI側のインタラクションと、Robotics側のインタラクションを統合する必要性が重要となってくる。上の例ではユーザはコンピュータとのインタラクションを行なうのみであるが、実際のパーソナルロボットにおいてユーザへの応答を行なうには、Robotics側のインタラクションシステムが、HCI側のインタラクションの結果を反映する必要がある。「ユーザ」「ロボット」「環境」を統合するインタラクションシステムであれば、ユーザとのインタラクションを行ないながら、環境へのインタラクションの挙動を修正する、という「パーソナル化」を極めてスムーズに実行する事が可能となる。

2.4.5 ロボットから人間への能動的な情報伝達

パーソナルロボットにとって必要となるもう一つの要素であるインタラクションを考えた場合、今までの議論ではユーザからロボットへ働きかける方向の情報の流れが主に考慮されており、ロボットからユーザへ働きかける方向のインタラクションについては、あまり考慮されていなかった。

ロボットからユーザへの情報伝達の一手法として、尾形らは、感情を持ったロボットの実現が、ロボットと人間との自然なコミュニケーションを支える基盤になる、という主張のもとに、感情に基づく行動決定モデル [Ogata 99] や、自己保存を目標とする行動モデル [尾形 95] を提案している。また一方で、佐藤らは第2.3.3節で述べたように、表現するロボットにおいて動作というモダリティを用いて人間にその場の状況を伝達する試みを行なっているが、いずれも明確な意思を伝達する事を目的とはしていない。

ロボットからユーザへの情報伝達による、行動知能の形成の例として、能動学習における「質問による学習」がある。能動学習 (Active Learning) は学習者が与えられた学習データだけでなく、自ら行動を行ないながら学習データを追加し、効率の良い学習を行なう学習形態の事である。この学習のうち代表的なものは「質問による学習」と「強化学習」の二つが挙げられる [安部 97]。

前者の「質問による学習」は、学習を行なう上で最も効率が良くなると思われる学習サンプルデータを推定し、教示者にそのデータに関する質問を投げかける事によって、効率の良い学習を行なうものである。この学習方法を最初に確立した Angluin は DNF (Disjunctive Normal Form) と呼ばれる積和形式のブール関数を学習するような概念の学習を実現している [Angluin 87]。近年では、主にニューラルネットワークの分野において、少ないトレーニングデータから効率の良い学習を行なうために活用されている。例えば ベイズ決定理論の枠組を用いて、過去に使用した学習データから、今後の学習に最も情報量をもたらすサンプルデータを推測し、質問を行なう研究がなされている [Paass 95]。この手法では同じサンプルデータ数の学習でも、情報量の多いと思われる学習データを用いた方が学習が速く収束することが確認さ

れており [福水 96, Fukumizu 99]。質問行動が学習を促進している事が良く分かる例である。

一方、後者の「強化学習」の方は自律行動を介して環境とインタラクションを行ない、得られる報酬に基づいて行動規範を学習する枠組である [Whitehead 95]。ここで注意すべき点は、「質問による学習」では主に概念獲得などのある目標となるモデルにより近いモデルを学習することが目的となっているのに対して、「強化学習」では、ユーザが保持している目標モデルに近付けるアプローチではなく、学習者の目的は得られる報酬を最大化するような行動のモデルを獲得する事である。つまり、獲得すべき対象が、前者の場合は学習データに用いられるサンプルデータ内部に存在するなんらかのモデルであり、後者の場合は教示者が与えた報酬を最大化するための行動選択関数、という事になる。強化学習は報酬を前提とした学習方法であるため、報酬をどのような形式で定義すれば良いのかが分からない場合には適用不可能という側面を持つ。「質問による学習」は統計的な側面を持つ概念学習に近く、教師信号や報酬の形式が不明な場合にも、事象間の因果関係を獲得する事は可能である。

これらの事が示していることは、強化学習はロボットと環境のインタラクションに基づく学習に向いており、質問による学習は、ユーザとロボットのインタラクションに基づく学習に向いている、という事である。

2.4.6 自然言語を用いた行動知能の形成

ロボットとユーザとの対話に基づく行動知能の形成について、いくつかの側面を見てきたが、対話を行うモダリティとして自然言語を使用すべきであるのは疑う余地がない。

しかしながら、自然言語対話を行う際には多くの曖昧性が生じるため、対話システムは不確実な情報を扱う必要がある。また、ユーザ個人によって言語表現や言い回しなどは微妙に異なるため、不確実な情報が多く存在する。

また、GUI などを利用する対話であれば、ユーザの挙動は必ずシステムにとって予測可能な範囲に収まるが、自然言語を利用する場合には、システムが予測する事のできない未知の語彙を使ってユーザが指示を行う事も考えられる。

このように、自然言語対話に基づく行動知能の形成には (1) 情報の不確実性、(2) 未知の語彙への対応、(3) ユーザ個人に依存した微妙な意味の違い、などを考慮する必要がある。

2.5 Bayesian Network を利用したロボットの行動知能の形成

2.5.1 統計的な行動知能の表現

以上の議論のように、パーソナルロボットにとって必要となるのは、経験を通じて段階的に環境の知識を獲得したり、使用しているユーザに適合する事である。ここでは、その経験をどのように表現するのが適切であるかを考察する。

一番単純な経験の表現方法は、情報を加工せずそのまま記憶する、メモリーベーストな手法である。説明に基づく学習 (EBL) [Mitchell 86] はその代表例である。ロボティクスの分野においては、カメラから得られた画像をそのまま記憶してナビゲーションに利用する研究などがある [松本 97d]。しかしこのナビゲーションの研究では、実世界における変動し易い視覚情報をそのまま記憶しているため、環境変動に対応できない問題があった。また一般的に記憶してある情報から、現在の状況に最も近いサンプルデータを検索する事は非常にコストのかかる事であり、検索方法に工夫が必要になってくる。

また、ユーザとのインタラクションの結果を経験とする手法としては、サッカーロボットのシュート行動において、ユーザの教示情報をそのまま蓄積する例がある [Veloso 98]。ユーザが間違った行動を教示した場合に、それをそのまま記憶してしまう事も問題となってくる。

前者のメモリーベーストな手法の問題としては、教示や学習などにおける固定的な知識表現であった。固定的な知識を表現してしまう事によって、(1) ユーザが誤って教示した情報をそのまま受けとってしまう。(2) 動的に変動する外界に追従する事が難しくなる。などの問題があった。また後者の個人への適応という観点から見ても、固定的な表現を行なう事によって、(1)の問題が生じる。すなわち、実世界における環境情報には不確実な要素が多く含まれるので、このような経験は固定的な表現ではなく、変動する情報に追従する事が可能な表現が求められる。

そのような非固定的、不確実な情報を扱う必要性は近年特に注目されてきており、Uncertainty in Artificial Intelligence という学会¹で議論が行なわれている。不確実な情報を扱う手法としては、主なものには次の手法が挙げられる。

- ニューラルネットワークなどによる非線形関係の表現
- Dempster-Shafer 理論 [松山 89] による「無知」の表現
- ファジー理論による曖昧性の表現
- 統計処理による確率的な表現

¹Association for Uncertainty in Artificial Intelligence. <http://www.auai.org/>

これらのうち、ファジーによる手法は、メンバシップ関数を対象の状態に応じて設計する必要があり、後天的な行動知能の形成を表現する手法としては不適切である。また、ニューラルネットワークでは、入力情報と出力情報の間の論理的因果関係については獲得する事ができない。ロボットがユーザ個人に適合していく際には、「どのような理由でユーザはそのような指示を与えたのか？」という事を推測する必要がある。一種の教師なし学習をする必要がある。ニューラルネットワークでは入力される教師信号には必ず対応するノードが決められており、言い替えば、データが持つ相互関係はあらかじめ決定している。これは経験を表現する手法としては適切であるとは言えない。そこで、本論文では統計処理を用いた確率的な手法を用いる事によって経験を表現する事とする。

2.5.2 Bayesian Network による確率的推論モデル

このようなモデルを構築するために、Bayesian Network [Pearl 88] を採用した。Bayesian Network はある領域における不確実性を持つ現象に関する知識を表現するモデルである。その領域において限定された情報が得られた場合、従来の記号論理をベースにした推論手法では、的確な推論が行なえなかったが、Bayesian Network は、この問題点を補うために、得られた情報が不確実であっても推論を進められるに考案されたものである [麻生 97]。

Bayesian Network では複数の事象間の因果関係を確率を用いて表現する推論モデルである。Figure 2.9 のように事象がノードとして表現され、原因となる事象 (親ノード) と結果となる事象 (子ノード) をリンクを張り、ネットワーク構造として事象間の関係を表現する。事象間の依存関係には「もしAならばBである」というような固定的な表現ではなく、「Aである時のBの確率は $P(B|A)$ 」というような確率的な表現を用いる。各事象は確率変数を持ったノードであり、いくつかの状態を取る。リンクに存在する確率的な因果関係はその確率変数を使った条件付確率で表現される。

Bayesian Network は現在幅広い分野において応用され始めている [Charniak 91]。MYCIN に始まった診療医療用などのエキスパートシステムの欠点を補う可能性が注目されたのをはじめ、エージェントと人間の音声対話の分野では、音響情景理解 [柏野 96, Kashino 95]、自然言語対話モデルの構築 [Akiba 94, 池田 95, 乾 95]、などへ応用されている。コンピュータビジョンでは、交通監視システム [Buxton 95]、注視点制御 [Rimey 92]、などにも応用されている。また、実務の商品としては、Microsoft Windows のソフトウェア、Office に搭載されている Office Agent と呼ばれるトラブル解消エージェントにおいて、Bayesian Network が利用されており、ユーザの質問からトラブルの原因となっている事象を推論するユーザインタフェースを実現している [Heckerman 94]。実際のロボットにおける応用としては、移動ロボットの地図獲得 [Basye 92, Asoh 96]、や強化学習によるナビゲーション [山村 97,




Figure 2.9: Connection between Hypothesis and Evidence in Bayesian Network Representations

小野塚 97] などに応用されている。このように様々な分野に Bayesian Network が応用されている最大の理由は、不確実性を伴うあいまいな事象間に存在する因果関係を扱うことに優れているからである。これらの理由から人間の心理的な行動決定や、曖昧な知識構造なども Bayesian Network で表現可能であると考えられている [Heckerman 95b]。

ノードは大別して確率変数が観測される証拠ノードとその証拠の観測から推論される目的事象である仮説ノードからなる。ロボットでは証拠ノードを外界の環境、すなわちセンサ情報、仮説ノードを取るべき行動と結び付ける。ロボットはセンサ情報などが観測された場合に、Input-Evidence の手続きを用いて、Bayesian Network の証拠ノードにデータを入力する。これはノードに割り振られている確率変数を、観測された状態のみが 1 になるように設定する事と同値となる。仮説ノードに関する推論を行なう場合には、Table 2.1 のようなアルゴリズムを用いて確率変数の確率分布を求める。このアルゴリズムの詳細は巻末の付録にて述べるが、一つのノードの確信度はネットワークの上側の情報から伝播する π と、ネットワークの下側から伝播する入を使って計算され、これらの情報はリンクに割り当てられている条件付き確率を考慮しながらネットワーク全体に伝播して行く。

Bayesian Network は結果から原因を診断的に推論するだけでなく、逆に原因から結果を予測するような推論も行なう事ができる。具体的には次のような 4 種類の推論が存在する。

- 診断的推論 (diagnostic inference) : 結果から原因を推論する。Figure 2.10 (a) に相当。
- 因果的推論 (causal inference) : 原因から結果を推論する。Figure 2.10 (b) に相当。

Table 2.1: Algorithm for query probability

```

function Query-Probability( $X$ ) returns a probability distribution over the values of  $X$ 
{
  inputs:  $x$ : a random variable /* 推論対象のノードの確率変数 */
  Calculate- $\pi(X, null)$ 
}

function Calculate- $\pi(X, V)$  returns  $\pi_V(X)$ 
{
  if Evidence?( $X$ ) then return observed point distribution for  $X$ 
  else {
    calculate  $\lambda_V(X) = \text{Calculate-}\lambda(X, V)$ 
     $U \leftarrow \text{Parents}[X]$ 
    if  $U$  is empty
      then return  $\alpha \lambda_V(X) P(X)$ 
    else {
      for each  $U_i$  in  $U$ 
        calculate and store  $\pi_X(U_i) = \text{Calculate-}\lambda(U_i, X)$ 
      return  $\alpha \lambda_V(X) CPT_{U|X} \prod_i \pi_X(U_i)$ 
    }
  }
}

function Calculate- $\lambda(X, V)$  returns  $\lambda_V(X)$ 
{
   $Y \leftarrow \text{Children}[X] - V$ 
  if  $Y$  is empty
    then return a uniform distribution
  else {
    for each  $Y_i$  in  $Y$  do {
      calculate  $\lambda(Y_i) = \text{Calculate-}\lambda(Y_i, null)$ 
       $Z_{ij} \leftarrow \text{Parents}[Y_i] - X$ 
      for each  $Z_{ij}$  in  $Z_i$ 
        calculate  $\pi_{Y_i}(Z_{ij}) = \text{Calculate-}\pi(Z_{ij}, Y_i)$ 
    }
    return  $\beta \prod_i \sum_{y_i} \lambda(y_i) CPT_{y_i|X+z_i} \prod_j \pi_{Y_i}(z_{ij})$ 
  }
}
  
```


- 原因間推論 (intercausal inference): 共通の結果をもたらす原因の間での推論。Figure 2.10 (c) に相当。
- 混合型推論 (mixed inference): 上記の2種類以上の推論の組合せ。Figure 2.10 (d) に相当。

それぞれの推論のタイプを Figure 2.10 に示す。図中の E は観測されている事象を意味し、Q は推論を行なう対象の事象を意味する。

このように、ネットワークの構造に束縛されることなく、自由に推論を行なえる点は、推論の形態が状況に応じて変動するロボットの推論システムにとって都合の良いものとなっている。




Figure 2.10: Four kinds of reasoning in Bayesian Network

2.5.3 Bayesian Network を用いた対話経験の表現

Bayesian Network の構成を決定するには、以下の3つのプロセスを必要とする。

1. ノードに割り振られる確率変数を決定する
2. ノード間に有向リンクを張る
3. リンクに対応する条件付確率を求める

上記のうち、1と2については第4章で述べる。ここでは3の条件付き確率を経験蓄積から求める手法について述べる。

証拠ノードの確率変数を $E = \{e_1, e_2, \dots, e_n\}$ 、仮説ノードの確率変数を $H = \{h_1, h_2, \dots, h_n\}$ とする。この二つのノード間に存在する因果関係を確率を用いて表現する方

Table 2.2: Algorithm for experience accumulation

```

global variables: Bayesian-Network  BN /* 行動知能を表現する Bayesian Network */
global variables: Experience-DataBase DB /* 行動の経験データベース */

function Experience-Accumulation()
{
    local variables: Sensor-Input      s /* 観測されたセンサ情報 */
    local variables: Recognition-Result r /* センサ情報を元に認識された上位概念 */
    local variables: User-Designation  u /* ユーザが行なった指示や教示情報 */
    local variables: Evidence-Data     e1, e2, e3 /* Bayesian Network の各ノードに入力するデータ構造 */

    while conversation do {
        e1 ← Translate-to-BN-Data(s)
        e2 ← Translate-to-BN-Data(r)
        e3 ← Translate-to-BN-Data(u)
        Store-to-DataBase(DB, DataSet(e1, e2, e3))
        Revision-Bayesian-Network(BN, DB)
        if Conversation-Done then exit
    }
}

```

法として最も単純な方法は、経験の頻度を用いる事である。すなわち、経験の蓄積データの中である仮説 h_j が観測された回数が N_h 回、証拠ノードとして e_i が観測された回数が N_e だったとした場合、

$$P(e_i|h_j) = P(E=e_i|H=h_j) = \frac{N_e}{N_h} \quad (2.1)$$

として、条件付き確率を定義する場合である。これは一般的な最尤推定量であり、経験のサンプル数が多い場合には有効であるが、サンプル数が少ない場合には適切ではない[本村 99]。通常のベイズ則では、条件付き確率を求める際にベータ分布などが用いられるが、ここでは式 (2.1) の最尤推定量を適応する事を考える。

リンクは複数の状態を持つノード間の因果関係を示すものなので、条件付き確率値の集合である次の CPT 行列を求め、それをもってリンクの因果関係を表現する。

$$CPT_{E|H} \stackrel{\text{def}}{=} P(E=e|H=h) = \begin{pmatrix} P(e_1|h_1) & P(e_2|h_1) & \dots & P(e_n|h_1) \\ P(e_1|h_2) & P(e_2|h_2) & \dots & P(e_n|h_2) \\ \vdots & \vdots & \ddots & \vdots \\ P(e_1|h_m) & P(e_2|h_m) & \dots & P(e_n|h_m) \end{pmatrix} \quad (2.2)$$

蓄積されたデータは、Bayesian Network に対して蓄積されるわけではなく、ネットワーク内のノードに対して蓄積される。従って、異なる Bayesian Network であっても同一のノードを使用する Bayesian Network であれば、過去に蓄積したデータを再利用する事が可能となっている。Table 2.2 に対話経験の蓄積のアルゴリズムを示す。

対話経験を蓄積する具体的な手法については、第3章で述べる。

2.5.4 Bayesian Network を用いた経験に基づく行動決定

逆に自律行動を行なう場合には、証拠ノード E を観測し、その結果と過去の経験から仮説ノードに対応しているロボットの取るべき行動を選択する。Bayesian Network の計算から仮説ノードの確率変数 H は次式のように推論される。

$$BEL(H) \stackrel{\text{def}}{=} P(H|E) = \frac{P(E|H) \cdot P(H)}{P(E)} = \frac{CPT_{E|H} \cdot P(H)}{P(E)} \quad (2.3)$$

推論された結果 $BEL(H)$ は確信度と呼ばれ、その名前の通り、ロボット自身の推論に対する確信の度合を意味する。この計算は通常であればベイズの定理を用いて行なわれるが、複数のノードがネットワーク構造を成している場合は計算が容易ではなくなる。この計算を簡略化する方法が Bayesian Network に特有の再帰的な計算方法である。簡単なアルゴリズムを Table 2.3 に示す。再帰的な計算手法の詳細については、付録を参照されたい。

この確信度は仮説ノードに対する確信度であり、自律的な行動を決定する場合や、2.4.5節で説明したような能動的な質問を行なう場合に使用する事になる。この、対話経験を利用した行動決定および能動的な質問の生成手法については、第3章、第6章にて詳しく述べる。

Table 2.3: Algorithm for autonomous behavior decision

```

global variables: Bayesian-Network  BN /* 行動知能を表現する Bayesian Network */
global variables: Experience-DataBase DB /* 行動の経験データベース */

function Behavior-Decision()
{
    local variables: Sensor-Input      s /* 観測されたセンサ情報 */
    local variables: CF-for-Behaviors CF /* 各行動候補に対する確信度 */
    local variables: Evidence-Data     e
    local variables: Behavior          b

    Revision-Bayesian-Network(BN, DB)
    e ← Translate-to-BN-Data(s)
    Input-Evidence-into-Bayesian-Network(BN, Node(Sensor), e)
    for each Behavior b in Node(bhavior) do {
        CF[b] ← Exec-Reasoning(BN, Node(Behavior)) {
            if MAX[CF] > Threshold do {
                Execute-Behavior(MAX[CF])
            }
        }
    }
    exit
}

```

2.5.5 Bayesian Network を用いた適切な発話の生成

第6章では、ロボットがユーザと対話を行う際に、ユーザに負担をかけたり混乱させたりすることのない、自然な発話を生成するための手法について述べるが、この際に Bayesian Network を用いている。ユーザが曖昧な自然言語で指示をした場合に、タスクを達成する事ができる可能性を確信度として表現し、この確信度を Bayesian Network で算出する。ロボットはユーザに対して質問や確認行動を行う事によって、曖昧になっている情報を補おうとするが、この質問や確認行動のプランニングの評価基準として、Bayesian Network によるタスク達成の確信度を利用する[稲色 00a]。Table 2.4 に Bayesian Network を利用した対話の制御アルゴリズムを示す。この、状況に応じた適切な発話生成の具体的な手法については、第6章で述べる。

2.5.6 Bayesian Network を用いた言語情報とセンサ情報の結合

前節にも述べたが、ロボットとの自然言語対話を行う際には多くの曖昧性が生じるため、ロボットは不確実な情報を扱う必要がある。特にユーザがロボットに対して言語による指示や教示を行った場合、指示に使用される言語情報と、実際のロボットに入力されるセンサ情報と

Table 2.4: Algorithm for generating adaptive utterance

```

global variables: User's-Instruction inst /* ユーザの与えた指示内容 */

function Utterance-Generation()
{
  local variables: Sensor-Input s /* 観測されたセンサ情報 */
  local variables: CF-for-TaskAchieve CF /* タスクが成功すると思われる確信度 */
  local variables: Strategy St /* 取り得る発話戦略の集合 */

  CF ← Calculate-CF-for-TaskAchieve(inst, s) {
    if CF > Threshold do {
      Execute-Task-Using-Strategy(inst)
      exit
    }
    else do {
      for each st in St do {
        CF ← Calculate-CF-for-TaskAchieve(inst ∪ st, s) {
          if CF > Threshold do {
            Generate-Utterance("How about doing" + st + "?")
            Execute-Task-Using-Strategy(inst ∪ st)
            exit
          }
        }
      }
    }
  }
}

```

の関係を適切に表現しなければならない。また、ユーザ個人によって言語表現や言い回しなどは微妙に異なるため、不確実な情報が多く存在する。そこで言語情報とセンサ情報を Bayesian Network によって統計的に表現するアプローチを取る。長期間ロボットと対話を継続する事によって、ユーザが使用する言語と、ロボットに入力されるセンサ情報との関係が統計的に獲得されるので、ユーザ個人ごとに適応した、言語-センサ間の関係が形成される。

この、言語情報とセンサ情報の結合関係の獲得については、第7章で詳しく論じる。

2.5.7 Bayesian Network を用いる利点

ロボットの行動知能の表現に Bayesian Network を使用する利点としては、

1. 視覚的意味的に透明性があり、ユーザが直接モデルに介入できる
2. オフラインでの大規模な学習が要らず、オンライン学習ができる
3. 確率による表現で環境の変動に応じたフレキシブルな表現が可能

4. 行動決定モデルとの親和性が高い
5. ある程度の先見的知識を埋め込む事が容易である。
6. データのノイズや欠落に対してロバストである

などが挙げられる [Friedman 97b]。

これらの性質について、詳しく述べていく。

人間が簡単にモデルを理解できる透明性

学習を行なうにあたって、採用すべき手法を考慮するための性質は数多く存在するが、その中のユーザへの透明性を取り上げる。システムが学習を行ないさえすれば、システムを使用する立場のユーザからはそれがブラックボックスのままで良い、という使用形態であれば、この側面から考慮する事は何もない。問題となるのは、ユーザがシステムの中で起こっている事を理解し、そのシステムに介入する使用形態の場合である。この場合には、ユーザが、システムの学習の進行状況を明確に理解できる事や、獲得されたモデルがユーザにとって理解し易く、変更や編集などの動的な介入をし易い事が望まれる。

例えばニューラルネットワークのような学習モデルの場合、学習された結果はノード間の重み付けで表現され、またノードは実際に人間が知覚する物理的な観測パラメータと必ずしも対応していないため、システムはブラックボックスとなり、ユーザが介入する余地はなくなる。Pomerleauらはニューラルネットによる自動車の自律運転システム ALVINN [Pomerleau 93] を構築したが、行動決定を行なうニューラルネット部はドライバーの意思を正確に反映しているかどうかはまったく分からないため、ドライバーは常にシステムのミスを監視する必要がある。またエラーが生じたとしても、原因が何であるかを突き止めることは不可能に近いシステムとなっている。また、強化学習の枠組においても同様の事が言え、行動決定のプロセスがどのように行なわれているのかは、ユーザにとって理解できないという問題がある。

一方、Raymondらは、古典的な人工知能研究で用いられていた、意味ネットワークを拡張し、確率的な情報を埋め込む事のできる IS-A Bayes tree と呼ばれる知識表現構造を提案した [Rimey 94]。これは意味ネットワークなどで用いられる IS-A 関係を示すリンクに確率を付加させたものである。彼らはこの IS-A Bayes tree を用いて視覚探索問題を行ない、状況に応じた注視点の制御を実現させている。意味ネットワークは知識を可視化するのに適した手法であり、この表現方法はユーザにとって非常に分かりやすい構造となっている。

オンライン学習が可能である事

強化学習の場合、学習を収束させるためには100回～1000回のオーダーで行動を行なう必要があり、一回の報酬を獲得するのに必要な行動が、ある程度の時間を必要とする場合、実機ロボットのみでの学習はほぼ絶望的である。そのため、ほとんどの研究例がシミュレーションでの学習を行なった後に、実機ロボットでの学習に移行する方法を取っている [Morimoto 98, Asada 96]。

また、ニューラルネットにおける学習で最も良く使われているバックプロパゲーションは、収束計算による学習手法である。そのため、学習に用いるサンプルデータが頻繁に更新されるような環境においては、そのサンプルデータの更新と同時に学習結果を更新して行く事が難しい。この問題点はロボットが学習しようとしているタスク領域と、学習に必要な時間との組合せに左右される。ロボットが行なうべき行動が非常に大きなサンプリング周波数で駆動されている場合には、さほど問題は生じないが、画像処理などのリアルタイム性が要求される動作を伴うロボットにとって、オンラインでの学習はほぼ困難なものとなってしまう。

Bayesian Network では単純な統計計算 [Langley 97b, Pearl 88] を用いる事で、CPT を算出し確率モデルを更新できる。この利点は行動決定モデルを段階的にオンライン学習していくロボットにとって非常に重要なポイントとなる。式 (2.2) のような $m \times n$ の条件付き確率値行列 (CPT) を計算するのに必要とされる計算量は、そのノードに関する経験データのサンプル数を E とした時、 $O(mnE)$ となる。通常の実験を通じて m , n の値はたかだか10程度、計算対象の CPT も多くて数十、サンプル数 E も多い場合で数千というオーダーである。実際に第3章で説明する行動決定モデルにおける計算時間は、CPU Pentium-II 450MHz (Linux) のマシン上で、サンプル数 $E = 3000$ 、計算対象 CPT 数8、という条件下で 4.2[ms] という数値である。これはリアルタイム性が要求されるロボットで十分にオンライン計算が可能で時間である。

また、ロボットと人間が長期間インタラクションを重ねた経験から累積頻度を用いて簡単にオンラインでの確率モデルの獲得が可能になるという点も長所の一つである。

環境の変動に応じたフレキシブルな表現

Shibata らによって開発されたパーソナル指向の移動ロボット Hyper Scooter は、人間からの教示を復元する形で、複雑な環境内を自律走行する事ができる [Shibata 96, 柴田 96b]。しかしながら Kuniyoshi らの人間動作の観察に基づく教示手法 [Kuniyoshi 94] と同じように、視覚情報の見え方と行動が密接に関連しているために、環境の変動に対応不可能であったり、一般的な行動のモデルを獲得するまでには至っていない。

これは、環境情報と取るべき行動の関係が動的ではなく、固定的に表現されていたためと考えられる。動的に変動する環境において有効な行動モデルは環境変動に応じてその形を変動させて行く必要がある。環境情報と行動パターンを一体に対応させるのではなく、確率や統計などのクッションを経由して環境と行動の結合関係を表現する事が望ましい。

行動決定モデルとの親和性

行動計量学という分野では社会や経済の動向を予測するために、過去に得られたデータから統計処理に従って人間の活動における意思決定モデルを明らかにする事を目的としている [繁例 95]。ここで用いられているのがベイズ理論であり、合理的な意思決定は全てベイズ則を規範としてモデル化する事ができるとされている [繁例 85]。Bayesian Network の根底にある規範はベイズ則であり、この主張が揺るぐ事はない。

また、Howard らによって提唱された意思決定モデルの一つである、影響図 (influence diagram) は、そのネットワーク構造が Bayesian Network と酷似しており、実際に Bayesian Network は 影響図を発展させた意思決定ネットワークの一部としてみなす事も可能である [Russell 95]。

先見的知識の埋め込み

また、Bayesian Network による学習手法は後天的な学習が可能になるだけでなく、ノードに割り当てられた確率変数によって、先天的な知識を表現することが可能である。強化学習に代表される後天的な学習機構においては、初期の段階での学習の収束が遅い事が問題になる。この問題を解決するために、Hailu らはファジールールによる学習補助²を設計し、効果的な学習を実現している [Hailu 98]。また、Ishiguro らは学習を開始する段階の初期知識としてユーザの教示を用いている [Ishiguro 96]。

Bayesian Network による表現は、事前確率を用いることで、このような学習のための先見的知識をあらかじめ埋め込む事が容易である。この要素は学習の収束を行なう際に非常に重要な性質となってくる。また、人間が自然と日常生活で使用している背景知識を、事前確率の形で表現する事も可能であり、パーソナルロボットの知識表現として適切なものであると言える。

²彼らはこの機構を Learning by biasing (傾向による学習) と呼んでいる

ノイズやデータ欠落などの不確実な情報に対する適応性

実環境で行動するロボットにおいては、センサのノイズなどが原因となるため、不確かな情報に基づいて行動する必要がある。このような行動を実現するための手法として統計的決定理論が存在するが、Bayesian Network はこの統計的決定理論の一種でもある。統計的決定理論を利用したロボットの行動制御の例としては、三浦らは、ベイズの規則に従って視覚処理で生じる不確かさを考慮しながら、行動のプランニングを行なう手法を提案している[三浦 92, Miura 93]。また、不確実な情報から合理的な決定を行なうためのモデルとして、インフルエンスダイアグラム(Influence Diagram)という手法が提案されている。これは意思決定ネットワークと呼ばれることもあり、いくつかの状況証拠から確率的に意思を決定するモデルである。橋本らは influence diagram をロボットの運動スキーマを表現する形態の一つとして位置付け、時間的制約条件のある状況で、プランニングの時間コストを考慮した行動決定モデルを提案している[橋本 95, Sawaragi 97]。このように、Bayesian Network は不確実な情報を取り扱わなければならない実環境において、有効な手法と言える。

ここで、他の種類の行動決定手法との比較を行なう。Figure 2.11 は、入力された事例データ(観測データ)がどのクラスに属するかを分類するための、3つの主な手法の概念図である。(1)はFisherの判別分析法などに代表される判別分析を示したもの。(2)はQuinlanによるID3[Quinlan 86]やC4.5などに代表される決定木を示したもの。(3)はDasarathyによるNearest Neighbor法を示したものである[毛利 95]。

これらの手法は事例データが完全な形で得られる事を前提としている。例えばFigure 2.11では事例データは2次元のベクトルであるが、2つの成分のうち片方が欠落してしまえば、分類計算を実行する事はできない。Bayesian Network では、このような事例データのうち部分的に欠落が生じてても、「その事例は観測されていない」という状態のまま、推論を続行する事が可能である。

また、Nearest Neighbor法の誤分類率は、連続値を扱うBayesian Network、すなわちBayesの決定法の誤分類率より低くなる事がない、という事が数学的に証明されている[毛利 95]。つまり逆に考えれば、ベイズ則はNearest Neighbor法より劣る事はあり得ない、という事である。

このような性質は実世界で行動し、ノイズや信頼性のないセンサデータを扱うロボットのための推論モデルに適切なものであると言える。




Figure 2.11: Three classification models

2.6 本章のまとめ

本章では、HRI(Human-Robot Interaction)の研究の難しさが、単なるロボティクスと、HCI(Human-Computer Interaction)の要素技術の統合では達成できない事にある事を述べ、人間、ロボット、実環境の3者を有機的に結合するインタラクションモデルの必要性について述べた。そしてそのようなインタラクションモデルを先天的にロボットに埋め込むのではなく、後天的に獲得する事が日常空間で行動するパーソナルロボットに必要な事を述べ、ユーザとのインタラクションの経験を蓄積しながらモデルを構築するために統計的処理が有利である事を示した。実際の表現方法として、ベイズ則を基本原理とする Bayesian Network による行動知能モデルの表現を導入し、経験の表現や、行動決定、ユーザへの質問の生成などの実現方法について述べた。

ここで、他の手法による行動知能の表現と、Bayesian Network を利用した行動知能の表現の相違点を Figure 2.12 に示す。

	Online	Flexibility	Transparency	Complexity of design	Tolerant for uncertainty
Neural Network	△	△	×	○	○
Fuzzy	×	×	△	△	○
Reinforcement Learning	△	△	×	×	△
Decision Tree	○	○	△	○	×
Bayesian Network	○	○	○	△	○

Figure 2.12: Comparison between five models

第3章

対話経験の蓄積に基づく自律行動の獲得

3.1 はじめに

第2章で説明したように、パーソナルロボットは様々な環境、様々な状況において活動する事が求められる。そのような状況においては、ロボットの開発者はすべての状況を予測する事はできないため、自律行動のための行動決定モデルをあらかじめロボットに組み込む事が不可能になる。そのため、パーソナルロボットは主に後天的に行動を獲得する必要がある。

行動を後天的に獲得させるための手法として、大きく二つのアプローチが存在する。一つはユーザがロボットに教示を行なうアプローチであり、もう一方はロボットが学習を行なうアプローチである。しかしながらユーザがロボットに教示を行なう場合、ロボットが遭遇した事のない場面对して必ずユーザが指示を行なう必要がある。これはパーソナルロボットが活動するような、環境の変動が大きい状況の場合、ユーザにとって負荷がかかる要因となる。

一方ロボットが自律的に学習を行なう場合、ユーザの負荷が減る反面、希望する行動を獲得する保障がなくなってしまう。また、強化学習 [Asada 99, 畝見 92, 浅田 95] などの枠組では、センサや行動の状態空間の形成方法の違いによって、獲得される行動が大きく影響を受ける。これは学習に必要な条件設定を開発者が事前にトライ&エラーで調査する必要がある事を示しており、後天的な行動の獲得を目指すパーソナルロボットに取ってふさわしい学習方法とは言えない。

このように、ユーザの教示による行動獲得、自律学習による行動獲得、そのどちらも単体では、パーソナルロボットを構成するための行動獲得手法として採用する事が難しい。すなわち、ユーザの教示と、ロボットの自律学習を状況に合わせて融合させる事がパーソナルロボットにとって最もふさわしい行動の獲得法であると言える。

本章では、そのような行動獲得の手法について述べる。まず、環境の変動やユーザの交替、実環境におけるノイズなどに依らず、ユーザの教示情報を再利用するための、確率的な行動決定モデルを導入する。次に、ユーザの教示ベースの行動からロボットの自律学習へ、行動のモードを速やかに移行するための、ロボットとユーザ間のインタラクションについて述べる。実際の移動ロボットにおける障害物回避タスクにおいて、その有効性を検証するのが、本章の目的である。

3.2 Bayesian Network を用いた対話経験の蓄積に基づく行動獲得

3.2.1 オンライン教示学習のための行動決定モデル

何の知識も持っていないロボットに新しい知識を教示する場合、一般的な教示方法では環境から得られる情報やロボット内部状態の情報に応じて、固定的に取るべき行動を教示していた。この手法によって形成されたモデルは、複雑な環境や状況に対応できる代わりに、環境の変動などに影響を受けやすい。環境が変動して獲得したモデルが使用できなくなると、また初めから教示を直す事になり、以前に獲得していたモデルを再利用する事が難しい側面があった。また、人間の教示も完全である保障はなく、人間が教示ミスを行なうと、そのまま反映されたモデルが形成されてしまう。

これは、環境から得られる情報と取るべき行動が固定的に表現されていたためと考えられる。この問題を回避するには、教示の結果を環境の情報とダイレクトにバインドして記録するのではなく、確率的に表現する事が望ましい。他にもニューラルネットワークのように非線形に対応関係を学習させる方法 [Pomerleau 89] も存在するがニューラルネットを用いる学習の場合、は長時間の学習フェーズが必要であり、オンラインでの学習には不向きである。環境と行動の関係を固定せず、フレキシブルに表現する手法としてファジーによる手法もあるが、メンバーシップ関数の設計など、開発者の手腕に寄る部分が多い。

Figure 3.1 に Bayesian Network を利用した行動決定モデルの概念を示す。これは第2章の Figure 2.9 と対応しており、証拠ノードをセンサと対応させ、仮説ノードを行動と対応させている。すなわち、センサから得られたデータを証拠として、取るべき行動の仮説を立て、それを推論しながら適切な行動を選択する。

3.2.2 Bayesian Network による表現の利点

Yairi [Yairi 98] は Bayesian Classifier [Langley 92, Langley 99, Friedman 97a] を用いて、ロボットの行動獲得を行なっている。このシステムは複数の異なる種類のセンサを冗長に持つロボットにおいて、入力されたセンサから状態を認識し、的確な行動を実現するものである。学習の際には、ランダムに行動を選択し、その結果としてどのような状態になったか、どのようなセンサを観測していたか、をデータベースに蓄え、Bayesian Classifier の判断基準を求めている。Bayesian Classifier の特性により、センサ情報のノイズ、欠落、オフセットなどにロバストに対応できるとしている。しかし、Bayesian Network 化はされておらず、複雑な状況に対応できない、またシミュレーションでの実験のみで、実機における実用性を検証していない。学習には、10000 回以上の行動を必要としており、実機で行動する前段階としてのシ




Figure 3.1: Connection between Behavior and Sensor in Bayesian Network Representations

ミュレーションの重要性を物語るている。

Bayesian Network による表現にはもう一つの利点が存在する。この手法ではロボットは自分の取るべき行動を確率的な信念で表現する。その信念と違う事象に遭遇した場合、ロボットの推論が間違っているか、ユーザの教示が間違っているか、どちらかである事を予想する事ができる。さらに推論が間違っている場合には、どの部分での推論に誤りがあったのか、ネットワークの構造を参照する事によって容易に人間が理解する事ができる。Minato らは障害物回避タスクにおいて、強化学習を適用し、純粋にロボットが得た経験に基づいて状況に応じた回避戦略モデルを獲得する手法を提案している [Minato 98]。しかしながら、ロボットが獲得した戦略はロボット内部でそのロボット特有の方法で表現されており、他のロボットがそれを解釈したり、人間が解釈する事は不可能である。人間とロボットとのインタラクションを考えた場合には、ロボットと人間の間での共通の知識表現手法が重要となる。

3.3 対話的教示方法を用いた移動ロボットの自律行動獲得

本節では、Bayesian Network で表現された自律行動のモデルを移動ロボットに適用し、その有効性を検証する。まず仮想環境における移動ロボットにおいて有効性を検証し、その後実際の移動ロボットにおける実験を行なう。

3.3.1 移動ロボットによる障害物回避実験への応用

まず、Bayesian Network 表現による自律移動の有効性を検証するために、移動ロボットにおける障害物回避タスクを実行する事とした [Inamura 99]。

移動ロボットの障害物回避タスクにおける応用を考え、ユーザーから与えられる教示情報を、ジョイスティックレバーによる直接的な行動の指示と、言葉による間接的な指示の2種類に設定した。この2種類のユーザーの指示を入力するためのノードとして、行動ノードを用意する。また、外界環境から得られる情報を表現するセンサノードとしては、障害物回避タスクであることから、距離センサを使用する。使用する Bayesian Network のモデルは Figure 3.2 のように設定した。移動ロボットは Figure 3.3 のように視野角に広がる領域に対して距離を求め、Bayesian Network に入力するものとした。ここでの距離センサの値は整数値で、近い場合は0を、遠い場合は255を出力する。それぞれのノードは確率変数で表現されているので、それらのセンサの生データを離散化し状態値に変換した上でノードに入力するものとした。




Figure 3.2: Configuration of Bayesian Network for avoidance behavior

実験環境として設定した条件は廊下環境を移動するロボットであり、ロボットに与えられ




Figure 3.3: Disparity calculation based on stereo camera

ているタスクは、いくつかの障害物を回避しながら廊下に沿って進む事である。仮想環境における距離センサは、Figure 3.4 のように実際の移動ロボットに搭載されているカメラの画角と同じ56[deg]として、距離を求める。廊下の長さは60、幅は8とした。ロボットは直径2の円柱で近似されている。ユーザはジョイスティックや音声による指示でロボットを操縦し、正面つき当たりの目的地に到達するまで操縦を行なう。




Figure 3.4: Distance sensors and corridor environment conditions

使用する距離センサノードの確率変数として、Figure 3.5 のように $S_i = \{Near, Middle, Far\}$ の3つの状態を設ける。また人間の操縦を表す行動ノードについては、前進、停止、左折、右折、の4状態すなわち、 $B = \{Forward, Stop, Left, Right\}$ の確率変数を用いる。

これらの距離を示すセンサノードの観測から、未知の状態である行動ノードを推論し、と




Figure 3.5: State space of sensor node

るべき行動を決定する。推論の計算は、

$$BEL(\mathbf{B}) = P(\mathbf{B}|\mathbf{S}) = \alpha \prod_i \lambda_i(\mathbf{B}) \pi(\mathbf{B}) \quad (3.1)$$

で表される。ただし α は正規化のための係数、 $\pi(\mathbf{B})$ は行動の確率変数の事前確率分布、 $\lambda_i(\mathbf{B})$ は i 番目のセンサの観測結果から求められるベクトルで、 j という観測結果が得られた場合確率変数の j 番目の成分を1、他の成分を0としたベクトル \mathbf{e}_j を使って

$$\lambda_i(\mathbf{B}) = CPT_{S_i|\mathbf{B}} \mathbf{e}_j \quad (3.2)$$

と表される。例えば距離センサ S_1 の入力が Near であれば、Near である確率が100%であり、Far である確率が0%になったと考えて、 $\mathbf{e}_1 = (1.00, 0.00)$ というベクトルとなる。Bayesian Network の推論計算は、すべてこのような確率を表すベクトルで表現される。つまり取るべき行動の推論結果は、4次元のベクトルとなり、それぞれの値が、「前進」「停止」「左折」「右折」を表す。

ユーザから行動 b_j が N_j 回指示されたうち、センサ情報が s_i だった回数を n_{ij} だったとする、

$$P(\mathbf{B}) = P(\mathbf{B} = b_j) = \frac{N_j}{\sum_j N_j} \quad (3.3)$$

$$P(s_i|b_j) = \frac{n_{ij}}{N_j} \quad (3.4)$$

となり、最終的に式(3.1)は次のようになる。

$$BEL(\mathbf{B}) = \alpha P(\mathbf{B}) \prod_i CPT_{S_i|\mathbf{B}} s_i \quad (3.5)$$

3.3.2 行動決定の確信度による対話の制御

ロボットの推論結果と人間の指示が異なった場合、大概の場合はロボットの推論結果の誤りに原因がある。しかしユーザの指示にミスがある事も否めず、いつでもユーザの指示を受け

付けていけば良いという事にはならない。人間同士の場合でもそうであるように、このどちらに原因があるかは、対話を行なって確認するのが最も効果的な方法である [Oviatt 91]。しかし、推論結果と異なる指示が行なわれた時に毎回対話を行なっているのは、逆にユーザに負担になる。Grice [Grice 75] の提案する協調的対話の原理のように、状況に応じた必要十分な量の対話を行なうべきである。そこで、この確信度の高さと、ユーザが行なう指示とロボットの推論結果の相違に応じて、Table 3.1 のように自律のレベルを切替える。それぞれのレベルに応じて、提案を行なう、選択肢を提示する、質問を行なう、などの対話行動を行なう。これらの対話の結果によって、重みが決定して行く。

Table 3.1: Interaction process for each situation

Certainty Factor of Reasoning[%]	The difference of user's operation from robot reasoning		
	Same Case	Difference Case	Human doesn't operate
80 ~ 100 Autonomous Level 4	Obey user's operation	Execute reasoning result while point out user's mistake	Execute reasoning result
65 ~ 79 Autonomous Level 3	Obey user's operation	Wait user's operation while showing the reasoning result	Execute reasoning result while showing choices
50 ~ 64 Autonomous Level 2	Obey user's operation	Obey user's operation while showing reasoning result	Execute reasoning result while showing second selection
0 ~ 49 Autonomous Level 1	Obey user's operation	Obey user's operation	Wait for user's operation while showing choice candidate

3.3.3 重み付け経験蓄積法に基づく事前確率の補正

式(3.4)、式(3.3)で表現したような単純な累積頻度度数を用いた手法では、次の問題が生じる。時々しか指示されないような行動があった場合、事前確率 $P(\mathbf{B})$ が頻繁に指示された行動に偏ってしまい、滅多に指示されない行動を選択する確率が実際より小さい値になってしまうのである。

もう一度式(3.5)を振り返って考えてみる。センサ情報が入力された場合に取りうるべき行動の尤度は

$$BEL(\mathbf{B}) = P(\mathbf{B}|\mathbf{S}) = \frac{P(\mathbf{S}|\mathbf{B}) \cdot P(\mathbf{B})}{P(\mathbf{S})} \quad (3.6)$$

$$= \frac{P(\mathbf{S}|\mathbf{B}) \cdot P(\mathbf{B})}{\sum_i P(b_i)P(\mathbf{S}|b_i)} \quad (3.7)$$

である。ここで登場する項のうち、未知であるものは、 $P(B)$ と $P(S|B)$ であり、 $P(S|B)$ はユーザーの行動教示時に観測される。すなわち未知である項は $P(B)$ のみとなるが、この確率値をどのように扱うか、が問題となって来る。まったくユーザーの教示が観測されていない時期においては、 $P(B)$ は4状態を持つ確率変数である事から、

$$P(B) = \left(\frac{1}{4}, \frac{1}{4}, \frac{1}{4}, \frac{1}{4} \right) \quad (3.8)$$

と考えるのが妥当のように思われる。しかし、ある程度の観測がなされた結果、「その観測データ中に含まれる行動の種類の種類によって代用すべきである」という結論が導き出される可能性が高い。しかしながら、実際の問題として、 $P(B)$ を単独の確率値として議論する事自体に意味がない場合が多い。天気予報などは事なり、人間の行動はあらかじめ決定されるはずはなく、ある行動を行おうと決定する瞬間における周囲の状況によって決まる。すなわち、 $P(B)$ を事前決定する事には意味がなく、あくまでセンサ情報を得られた後の事後確率のみが、意味のある情報であると判断できる。

実際に、移動ロボットにおける障害物回避タスクにおいて、この事前確率の計算手法が、行動を適切に選択できるかどうか、に非常に関わりが深い。例えば行動ノードの確率変数が4状態の場合、障害物がない場合は、ほとんどの観測結果が、「前進」となるはずである。「左折」や「右折」という行動は減多に起こる事象ではなく、極まれにしか観測されなかったとする。ここで式(3.3)による事前確率を使用すると、 $P(B_{Left})$ や $P(B_{Right})$ は非常に小さい値となり、 $P(B_{Forward})$ は非常に1に近い値となる。このような状況で、減多に現れない障害物が右手前方に現れたとする。本来であれば、このようなセンサ情報を得られた場合、 $P(B_{Left}|S)$ の値が高くなるはずなのだが、式(3.3)の分子に存在する事前確率 $P(B)$ において、 $P(B_{Left})$ の値が非常に小さい値となっているために、その値にひきずられるようにして、 $P(B_{Left}|S)$ の値が極端に小さくなってしまふ現象が実験から観測された。

この問題は、上記の例で言えば、「前進」を経験した頻度に比べ、極端に「左折」を経験した回数が少ないために生じる。経験の不均衡が原因であると考え、この問題を解決するために、行動の事前確率 $P(B)$ を式(3.3)でも式(3.8)でもなく、新たな基準で計算する必要がある。

減多に起こらない事象であってもそれは重要な状況である。人間の心理的な経験の蓄積においても、単に遭遇した頻度ではなく、その重要度で経験に重み付けされていると考えられる。この考え方を本研究に適用すると、重要な状況とは、ユーザーの教示とロボットの推論が食い違った場合、確実な推論が行えない場合、の二つである。この状況は、通常に推論を行ない自律行動の選択がうまく行っている状況に比べて重みをかけて経験に蓄積する[稲色 99c]。重み付けの例をTable 3.2に示す。

推論の結果がユーザの希望と異なる場合に対話的にその結果を訂正する事で、経験から算出されるCPT値を更新する手法を導入する。

Table 3.2: Weights of experience storage for each situation

Certainty Factor of Reasoning[%]	The difference of user's operation from robot reasoning		
	Same Case	Difference Case	Human doesn't operate
80 ~ 100	Do not storage	weight 10	weight 1
65 ~ 79	weight 1	weight 5	weight 1
50 ~ 64	weight 3	weight 5	weight 1
0 ~ 49	weight 5	weight 10	Do not storage




Figure 3.6: Weight for experience based on importance of situation

具体的にこのような重要な状況に対して重みをかける方法を説明する。取るべき行動の確信度のベクトルが $BEL(B) = (0.01, 0.97, 0.02)$ というような結果になった場合は、まず間違いなく確率変数が意味する選択肢のうち、2番目の行動を選択すれば良い。という事になる。逆に $BEL(B) = (0, 0, 0.5, 0.5)$ という確信度ベクトルが得られた場合には選択肢のうち2番目と3番目の行動を行なうべき確率が等しく50%である。という解釈になる。このような状況に陥った場合、ロボットは行動決定ができずに迷う事になるが、逆に考えるとこの状況はロボットにとって初めて遭遇した状況であり、後々の学習などのために特に注目しなければならない特徴的なシーンである。

実際の計算では以下のように定式化する。ユーザから行動 b_j が N_j 回教示されたうち、状況 c_k であった回数を $N_j^{(k)}$ とする。同様に行動 b_j の観測と同時にセンサ情報 s_i が観測された回数が n_{ij} だったうち、状況 c_k であった回数が $n_{ij}^{(k)}$ であったとする。状況 c_k の重みが w_k である場合に重み付けを考慮した事変数を l を付けて表現し、

$$N_j' = \sum_k w_k N_j^{(k)} \quad (3.9)$$

$$n_{ij}' = \sum_k w_k n_{ij}^{(k)} \quad (3.10)$$

$$P'(s_i|b_j) = \frac{n_{ij}'}{N_j'} \quad (3.11)$$

$$CPT_{S|B}' = P'(S = s|B = b) \quad (3.12)$$

$$P'(B) = P'(B = b_j) = \frac{N_j'}{\sum_j N_j'} \quad (3.13)$$

とする。Figure 3.6 にこの処理の模式図を示す。このような重みを導入する事でロボットは経験した事のない状況をより多く経験に蓄え、頻繁に遭遇する状況はあまり経験に蓄えない、という効果を得る。式 (3.4) のような単純な累積頻度数を用いている場合に問題となる事として、学習サンプルが十分に揃っていない場合には、確率分布の信頼性が低いという事がある。Dirichlet 分布を用いてこれに対処する数理的手法 [Heckerman 95a] も提案されているが、この重み付き経験蓄積法は、センサ情報と行動決定の問題に特化したヒューリスティクスを用いてこれに対処する手法であると位置付けられる。

最終的に式 (3.12)(3.13) より、式 (3.1) は次式のようになる。

$$BEL(B) = \alpha P'(B) \prod_i CPT_{S|B}' s_i \quad (3.14)$$

以上までに述べた、移動ロボットの行動決定処理の概要を Figure 3.7 に示す。

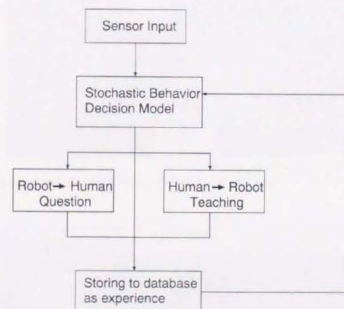


Figure 3.7: Abstract of behavior acquisition using stochastic behavior decision model

3.4 仮想移動ロボットにおける自律行動の獲得実験

上記の移動ロボットにおける障害物回避を行なうための検証用実験として、Figure 3.8 のような仮想空間における移動ロボットと、Figure 3.9 のようなユーザインタフェースを持つ仮想コックピットを作成した。




Figure 3.8: Virtual environment for obstacle avoidance tasks



Figure 3.9: User interface terminal for obstacle avoidance tasks

仮想空間および仮想移動ロボットは OpenGL 互換の Mesa ライブラリを使用して作られ

ており、距離センサとして、3D モデル内で得られる Z バッファを利用している。仮想コックピットにはジョイスティック型のレバーデバイスがあり、ロボットとの対話のための装着型マイク、スピーカー、キーボードなどのデバイスが用意されており、ユーザは Figure 3.11 のような GUI を見ながらロボットを操作する。ユーザが発話した音声情報は音声認識システムでシンボル化され、データベース部に送られる。キーボードから入力される場合には直接そのシンボルがデータベース部に送られる。ロボットがユーザに対して質問を行なっている場合には、その応答を管理する。ロボットが自分の意図の提示や提案を行なったり、質問をする場合には、音声合成システムを通して音声発話を行なう。

Figure 3.10 のような仮想環境における対話学習実験の様子を Figure 3.12 ~ Figure 3.14 に示す




Figure 3.10: Virtual corridor environment

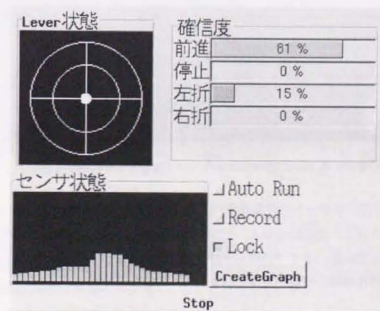


Figure 3.11: GUI window for mobile robot operator

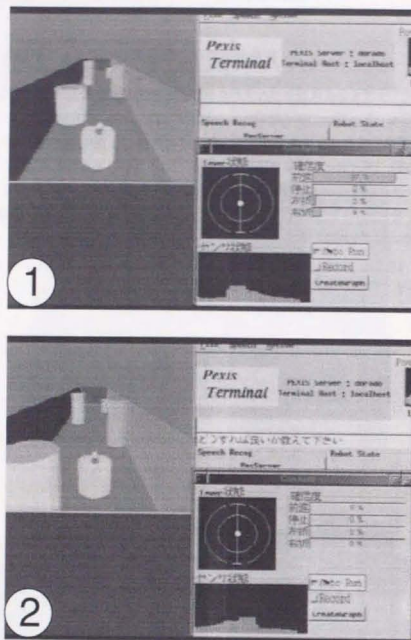


Figure 3.12: Experiment in a virtual environment (1)

画面1の状況では、ロボットの行動決定は「前進」を確信度100で選択しており、自律的に前進している。画面2の状況になると、センサ情報が変化し、どの行動を選択して良いかわからない状態に陥っている。そこでロボットは「どうすれば良いか教えて下さい」とユーザに発話し、ユーザの操作を待つ状態になっている。ユーザはここでジョイスティックレバーによる操作を行なった。

Table 1: Calculation Time: a) Correlation, b) Recursive Correlation Method, c) Cache Optimal Correlation, d) Adopt MMX Instructions

	PentiumIII-500MHz			
	Disparity Map Generation		Flow Generation	
	WithCC	WithoutCC	WithCC	WithoutCC
a)	5,332.7	2,594.5	1,928.7	903.5
b)	66.5	51.2	78.3	63.6
c)	41.9	34.0	40.9	31.5
d)	32.6	23.6	25.4	18.6

(N=128, W=15, D=20 in Disparity Map Generation and, N=64, W=16, D=8 in Optical Flow Generation)

CC:Consistency Checking



Fig. 3: Vision-based mobile robot

市販の車輪型ロボット(Nomadic社のScoutII), ステレオカメラ, PCによる視覚処理・ロボットシステムを組み合わせ, 図3に示すような視覚移動ロボットを構築した。

Nomadic社のScoutIIは円形の二輪を有する車輪型ロボットで電源と制御用DSPを搭載し, 完全な自立が可能なシステムである。仕様は以下である。直径41[cm], 高さ35[cm], 重量23[kg]であり, 最高速度1.0[m/sec]で移動でき, 16個の超音波センサと, 6個のバンパー上の接触センサを持つ(但し, これらのセンサは本論文における実験では利用していない)。外部のコンピュータとScoutIIはシリアル通信を介しての接続することが可能で, 外部のコンピュータからロボットの行動指令を与えることができる。通信処理装置としてMotrolaの68332を, 制御用のDSPとしてTMS320C14を搭載し, 制御周期は2[KHz]である。




Fig. 4: Hardware components of vision-based mobile robot system

また, 視覚処理を実現するためにPCを用いた視覚処理・ロボットシステムを構築しScoutIIのボディ内に搭載した。CPUはIntel PentiumIII 500[Mhz]を搭載し, メモリ128 [MB], ハードディスク1.5[GB]であり, 無線LANを用いて研究室内のLANに接続されている。OSはLinuxを採用し, Bt848を搭載した画像キャプチャ装置を2枚利用し, それぞれ右カメラ, 左カメラを接続した。また, 左右のカメラには同期信号生成装置から外部同期信号を与えた。

PC上で画像処理に基づき決定されたロボットの行動は, シリアル通信を介して指令する。

4.2 移動障害物回避実験




Fig. 5: A situation of an experiment

三次元フローとそれを考慮したポテンシャル場を用いることで, 障害物の形状や運動が未知の環境において, 複数の障害物の運動を考慮した行動を実現できることを示すために実験を行った。実験では三人の歩行者が存在

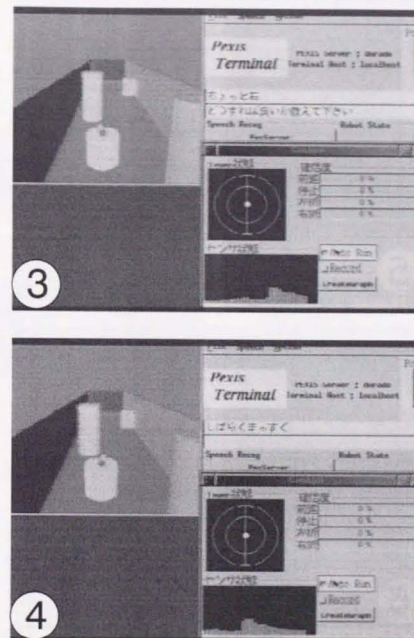


Figure 3.13: Experiment in a virtual environment (2)

初めての走行であるため、画面3,4の状況においても、どの行動を選択して良いかわからない状態になっている。ここでユーザは音声による指示を行なっている。画面3では「ちよっと右」という発語を行ない画面4では「しばらくまっすぐ」と指示を出している。「ちよっと」や「しばらく」という表現は行動を継続する時間の幅に変換される。ここでは「ちよっと」が1[sec], 「しばらく」が3.5[sec]に対応している。

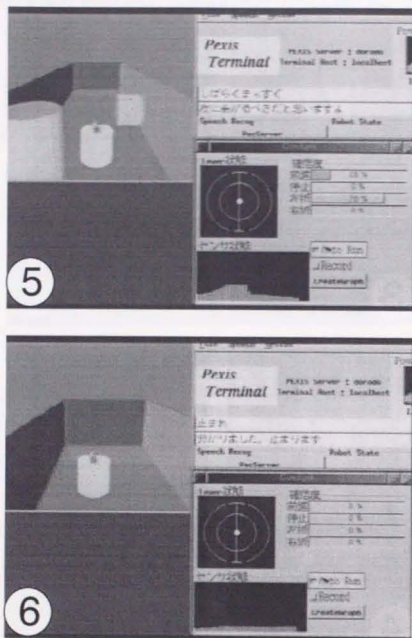


Figure 3.14: Experiment in a virtual environment (3)

画面5では、ロボットは左折行動を選択しているが、ユーザは「しばらくまっすぐ」という指示を出している。この場合確信度が70と高い数値を示しており、ロボットは「左に曲がるべきだと思いますよ」とユーザの指示のミスの可能性を指摘しながら、行動を継続している。画面6は停止すべきシーンであり、ユーザが「止まれ」と指示を出している。




Figure 3.15: Result of CPT acquisition for each node

3.4.1 対話経験に基づく確率モデルの獲得実験

Figure 3.15 に各ノードに対して獲得されたCPTの状態を示す。グラフの読み方は、ユーザからの行動指示 B が得られた場合の観測された距離センサ S の事後確率 $P(S|B)$ が Z 軸、 X, Y 軸は B, S それぞれの状態値を示している。ここでは $S = \{\text{Near}, \text{Far}\}$ の2種類の確率変数である。各図の一番右側の「右折」に注目すると分かるが、ロボットの視界の左側を担当する Node 1 では、「近い」センサ状態の場合には「右折」の確率が高く、逆に視界の一番右を担当する Node 8 では「近い」センサ状態の場合には「右折」の確率が低くなっている。この確率値 (棒グラフのうちの一番右) は Node 1 から Node 8 まで、ほぼ滑らかに変化しており、直感的に正しい事が分かる。

このように、得られた条件付き確率値に対して、それぞれの状態値が意味を持っているので、ユーザやシステムの開発者は正しく確率が得られたかどうかを直接理解する事ができる。このような直接理解は、ニューラルネットワークをベースとした行動決定システムには困難な問題であるが、Bayesian Network であれば容易である。

障害物回避の学習曲線を Figure 3.16 に示す。グラフの横軸は人間が行なった操縦の回数を示しており、スタート地点からゴール地点までの走行で1回の走行とみなす。グラフの縦軸は確信度を示している。Figure 3.16 の (a) では直進すべきシーンであるが、操縦を行ない

始めたばかりの初期の段階では、右折の行動が推論されている。また Figure 3.16 の (b) では右折と直進の二つの確信度がほぼ 50% と同じ値になっており、ロボットはこの瞬間にユーザーに対して、「正しい操縦を教示して欲しい」と要求している。

このグラフから、ユーザーが約 4 回の操縦を行なった後にはロボットの推論モデルの獲得は収束し正しい推論が可能となっている事がわかる。モデルの獲得が十分に収束していればロボットは高い確信度をもって推論結果を導出するので、もしユーザーが間違った操縦をした場合、「その操縦は間違いだと思うので直進します」と発言を行ないながら、自分の推論した行動を選択する。当然この際にはロボットの推論の方が間違いを犯している可能性は十分に高く、常にこのような対話を行なうべきではない。実際には 3.3.2 節で述べたように、ロボットの自律行動に数段階のレベルを設けて、対話を制御する。

3.4.2 環境の変化への対応

本手法で用いている統計的行動決定モデルは、環境と行動の関係を固定的に表現していないため、環境の変動に対してロバストである性質がある。行動決定モデルを獲得した環境とは異なる環境においても、柔軟に対応する事が可能である。

Figure 3.17 の環境 A において回避戦略を学習した後に、環境 B (Figure 3.18), 環境 C (Figure 3.19), と環境を変動させながら自律行動を行なわせた。Figure 3.20 は各段階での操縦において、Table 3.2 の各状況が観測されたサンプル数の分布を示している。この走行においては、5 回目に環境 B に移行し、12 回目に環境 C に移行している。図からわかる通り徐々に自律性の高い状況の割合が増加している。強化学習やニューラルネットワークの学習では試行回数のオーダーが 100 や 1000 に及ぶ事があるが、この手法では数回というオーダーで自律行動が可能になっている事がわかる。

また Figure 3.21 のように廊下に対して斜め方向からスタートさせた場合についても正常な軌跡を描く事がわかる。

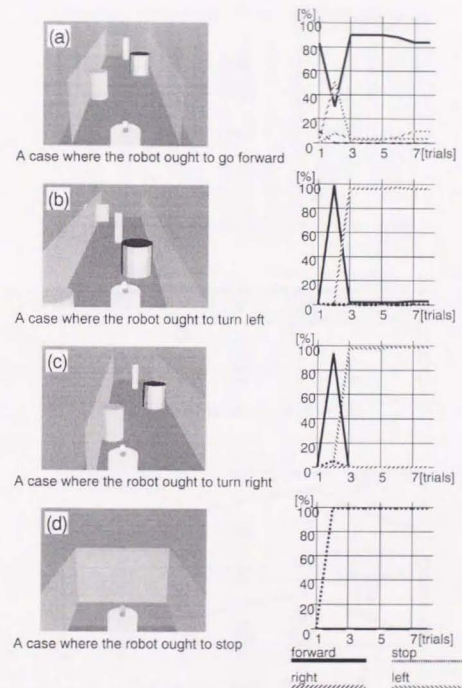


Figure 3.16: Result for virtual mobile robot environment




Figure 3.17: Virtual environment A




Figure 3.18: Virtual environment B




Figure 3.19: Virtual environment C




Figure 3.20: Distribution of each autonomous level




Figure 3.21: Result of autonomous running in virtual environment

3.4.3 不確実なセンサ情報への対応

環境の変動だけでなく、センサ情報が不確実な状態においてもロボスタな行動を選択する事が可能である。センサ情報にノイズがある、センサが壊れてしまい情報が得られなくなる、の二つの状況について検討する。Bayesian Network の推論の枠組では、いくつかの証拠ノードに関して未観測のまま推論を実行する事は可能である。すなわち、センサが壊れている場合には、センサノードに何も情報を入力しない未観測のまま推論を実行する。Figure 3.22 に、センサが故障し機能していない場合に行なった自律移動行動の結果を示す。(a)では8つのノードのうち、左から3番目と右から3番目の2つのセンサが壊れている状態。(b)では8つのノードのうち、左から2番目と右から2番目の2つのセンサが壊れている状態。(c)では8つのノードのうち、左から2,3番目および右から2,3番目の4つのセンサが壊れている場合である。(a)と(b)の場合には正しく障害物を回避する事ができているが、(c)の場合には回避する事ができない。このことから、全体のセンサのうち約25%が失われても十分に障害物を回避する能力が保たれている事がわかる。




Figure 3.22: Result when sensors were broken

3.5 実機移動ロボットにおける自律行動の獲得実験

本節では、以上に述べた対話に基づく自律行動の獲得を実際の移動ロボットに適用し、その有効性を検証する。

3.5.1 移動ロボット:Hyper Mouse

実際に使用した移動ロボット:Hyper Mouse の仕様を以下の Table 3.3 挙げておく。このロボットは PC/AT 互換機をベースに構築されているハイパーマシ [松本 97b, 井上 92] の一つである。ロボットは左右の車輪が二つのモーターにより独立に駆動できる、PWS(Power Wheeled Steering) を用いている。この移動ロボットの外形を Figure 3.23 に示す。

Table 3.3: Specification of real mobile robot system

移動ロボットシステムの仕様	
PC/AT 互換機	PentiumII 450MHz + Memory(128MB)
視覚処理システム	富士通 カラートラッキングビジョン TRV-CPW5
ビデオカメラ	ステレオ視覚 (SONY EVI-370 + 広角レンズ)×2 + 全方位視覚 (SONY EVI-310 + ACCOWLE 双曲面ミラー)
制御システム	富士通 ロボット用インターフェイスボード RIF-01 + Titech Robot Driver × 5
パンチルタ	ステレオカメラ用パンチルタ (3 自由度)
モニタ	SONY LMD-1041 (NTSC & VGA 表示可能)
その他	PC 用内蔵型無停電電源 AUP-250AT

3.5.2 ステレオ視覚による視差情報の取得

仮想環境における自律行動獲得実験では、使用する距離センサとして、OpenGL のライブラリで提供される Z Buffer を用いて距離を求めていたが、実機移動ロボットでは、Figure 3.24 のステレオカメラを用いて、実際の距離を計測する。

入力に必要なセンサ情報は、仮想環境の場合と同様に、水平方向 1 ラインに並んでいる距離情報である。このため、水平方向一列に沿って左右画像での対象物の視差を求め、その視差情報から距離を算出するものとした。

視差情報を求める方法として、テンプレートマッチングに基づく手法を採用した。基本的には、領域間の相関の評価基準を用いてマッチングを行なう。しかし画下などの均一なテクスチャを持つ対象物処理の場合には、正しくマッチングが行なわれず、視差を算出する事が




Figure 3.23: Photo of HyperMouse

できない場合がある。そのため、Figure 3.25 のように大域的なマッチングと局所的なマッチングを組み合わせて視差情報を求める手法を採用した。

画像処理を行なうハードウェアとして、富士通トラッキングビジョンを使用した。このハードウェア上では処理に使用する画素数が 640×480 [pixel] である。なるべく多くの視差情報を得るために、テンプレートのサイズを 16×16 [pixel] とし、水平方向一列にそのウィンドウを並べ、合計 32 個の視差情報を得られる仕様とした。実際の廊下での画像に対してステレオ視差を求めた結果を Figure 3.26 と Figure 3.27 に示す。

図中の○印は、その領域における視差の大きさを示しており、円の直径が大きいほど、視差が大きく、距離に近い事を示している。

3.5.3 視差情報から距離情報への変換

次に、視差情報を距離情報に変換する方法について述べる。ステレオカメラと対象物の関係は、Figure 3.28 のように表現できる。

左右のカメらは同一水平面内 (xy 平面内) にあり、各カメラの光軸は x 軸と垂直に固定してあると仮定する。また、左右のカメらの焦点をそれぞれ $F_R(D, 0)$, $F_L(-D, 0)$ 、焦点距離を f とする。いまある点 P が右カメラでは p_R 、左カメラでは p_L に結像したとする。各カメラの




Figure 3.24: Stereo cameras and a omnidirectional camera on the Hyper Mouse

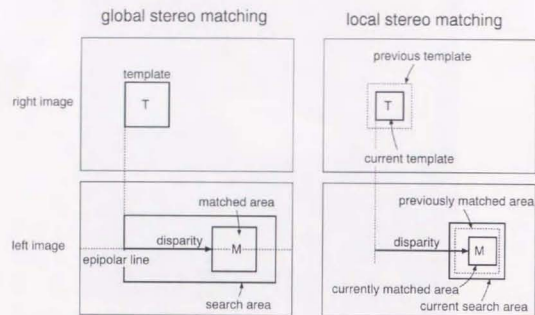


Figure 3.25: Global stereo matching(left) and local stereo matching(right)




Figure 3.26: Disparity image at near the end of a corridor




Figure 3.27: Disparity image at the center of a corridor




Figure 3.28: Transformation from disparity to distance

光軸から p_R, p_L までの距離をそれぞれ X_R, X_L として、 X_R, X_L から点 P の位置 (x_p, y_p) を求める。

F_R と p_R 、 F_L と p_L を通る直線をそれぞれ l_1, l_2 とすると、

$$l_1: y = \frac{f}{X_R}(x - D) \quad (3.15)$$

$$l_2: y = \frac{f}{X_L}(x + D) \quad (3.16)$$

式 (3.15) と式 (3.16) を連立させて交点 P の座標 (x_p, y_p) を求めると、

$$x_p = \frac{X_L + X_R}{X_L - X_R} D, \quad y_p = \frac{2}{X_L - X_R} f D \quad (3.17)$$

式 (3.17) における X_R, X_L の単位は長さであるが、実際に画像処理を行なって p_R, p_L の位置を求める場合、その位置は [pixel] で表すことになる。また式 (3.17) では焦点距離 f を定数として与える必要があるが、 f を直接計測することは困難である。そこで、画素の番号 n_R, n_L 、及びカメラの画角 γ (計測しやすい) を使って式 (3.17) から X_R, X_L, f を消去することにする。

カメラの画像面と光軸の交点を C、C から $n=0, 1, \dots, N-1$ の N 個の画素を考え、その端点を E、CE の距離を w 、C から E までの画角を γ とする。

$$\tan \gamma = \frac{w}{f} \quad (3.18)$$

一方、C から画素 n の中心までの距離 $X(n)$ は

$$X(n) = \frac{w}{2N} + \frac{w}{N} n \quad (3.19)$$

式 (3.19) に n_R, n_L を代入して、

$$X_R = X(n_R), \quad X_L = X(n_L) \quad (3.20)$$

式 (3.18)、式 (3.20) を式 (3.17) に代入して整理すると、

$$x_p = \frac{n_L + n_R + 1}{n_L - n_R} D, \quad y_p = \frac{2}{n_L - n_R} \frac{N}{\tan \gamma} D \quad (3.21)$$

N [pixel] 分の画角 γ 、及びカメラの位置 D をあらかじめ計測しておき、 p_R, p_L の位置を求めれば、式 (3.21) により対象 P の座標を計算できる。最終的に、対象物までの距離 l は

$$l = \sqrt{x_p^2 + y_p^2} \quad (3.22)$$

と、式 (3.21) を用いて算出する事になる。また、式 (3.21) の定数のうちカメラの位置 D は長さを計測するだけで値が決定でき、結果は $D=0.15$ [m] である。また、カメラ (SONY EVI-330 倍率 0.6 倍の広角レンズを使用) の $N=304$ [pixel] 分の画角を計測すると、 $\tan \gamma=0.58$ ($\gamma=30$ [deg]) であった。

3.5.4 実画像処理におけるセンサノイズへの対応

求められた画面上 32ヶ所の距離情報は、平滑化処理を行なった後に、Bayesian Network で表現されている。8 個の距離センサノードに入力される。しかしながら、実際の画像でのステレオ視覚の場合、先に説明した通り、対象領域が均一なテクスチャを持っているプレーン領域の場合や、左右のカメラの位置の違いから生じるオクルージョンのため、正確な距離情報を求められない事がしばしばある。しかしながら Bayesian Network による推論モデルは、3.4.3 節で説明した通り、まったく情報が入力されない事象が存在したとしても、推論を行なう事が可能となっている。そのため、このような正確な距離情報が求められなかった場合には、情報そのものを入力しない事とした。

実際には、センサより得られた 32ヶ所における距離情報から、4ヶ所づつ距離の値を平均し、8 個の距離センサノードに値を入力していく。4ヶ所全ての距離の値が不定となっていた場合、距離センサノードには何も情報を入力しないものとした。

3.5.5 実環境における対話学習実験

実際の廊下環境における対話学習実験の様子を Figure 3.30 に示す [図色 98b]。この場合、ユーザはロボットの後ろに立ち、ジョイスティックレバーや音声による指示でロボットを操縦するが、遠隔操作によってもロボットを操縦する事が可能になっている。

実際の廊下環境での実験の結果、獲得された条件付き確率テーブル (CPT) の状態を Figure 3.29 に示す。また、Figure 3.31 にその学習曲線を示す。獲得された CPT は、3.4.1 節の Figure 3.15 で考察したのと同じように、得らな確率値が変化しており、定性的に正しい確率値である事が分かる。また、学習曲線を見ても分かる通り、仮想環境の場合とほぼ同等のパフォーマンスを持ち、4 回から 5 回程度の操縦を行うのみで、正しく障害物を回避する行動を獲得する事が可能である事が確かめられた。




Figure 3.29: Result of CPT acquisition at real environment




Figure 3.30: Experiment in a real corridor environment

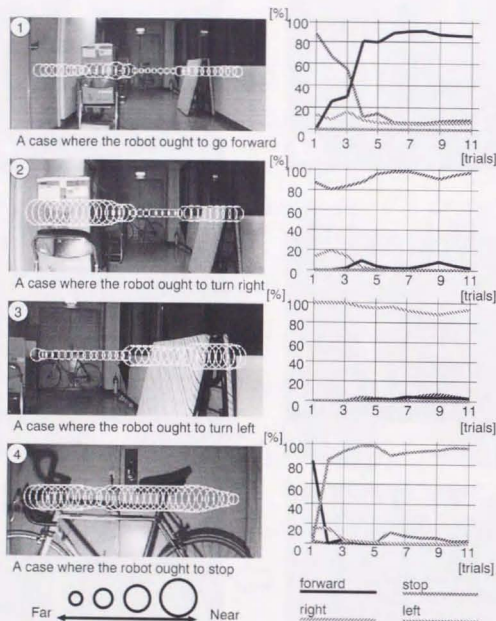


Figure 3.31: Result for real mobile robot environment

3.6 本章のまとめ

本章では、Bayesian Network による行動知能の表現方法のうち、センサ情報と行動との結合関係について述べた。従来研究で良く見られていた、単なるロボットと環境とのインタラクションに基づく学習ではなく、ロボットとユーザと環境の3者のインタラクションに基づく学習手法について述べた。

実環境におけるセンサ情報にはノイズが含まれていたり、センサの故障によるデータ欠落などが起こりやすいが、Bayesian Network による統計的行動決定モデルにおいてはその影響を回避する事が可能である事を示し、環境の動的変動にもロボストに対応する事が可能であることを示した。

問題として残されている事は、どの程度複雑なタスクへ適応可能であるかを見極める評価手法である。本章で述べたタスクは8つのセンサ情報と2つの自由度を持つモータの間の因果関係を獲得するものである。ヒューマノイドのように多数の自由度を持ち、多数のセンサ情報を扱うロボットにおいて、どのようなネットワーク構造を設計し、どの程度の信頼度でタスクを実行させる事ができるかについては、今後の課題となっている。前者のネットワーク構造を組み立てる指針については、次章で述べる手法を適用可能であると考えている。

対話経験の蓄積に基づく自律行動の獲得

対話経験の蓄積に基づく自律行動の獲得

対話経験の蓄積に基づく自律行動の獲得

対話経験の蓄積に基づく自律行動の獲得

第4章

対話経験の蓄積に基づくユーザへの適応化

対話経験の蓄積に基づくユーザへの適応化

4.1 はじめに

「パーソナルコンピュータ」という言葉が持つ性質の側面として、ユーザが一人一人コンピュータを保有し、ユーザがそのコンピュータの個人環境などをカスタマイズし、より使いやすい環境を構築する事ができるコンピュータ、というものが挙げられるであろう。このような考え方は、ロボットにも当てはまり、第2.4節で説明した通り、パーソナルロボットもその側面を持ったロボットであると位置付けられる。

このような個人への適応という側面を研究する分野は、コンピュータを中心に発展しており、例えば、MIT Media Lab. の Pattie Maes が精力的に研究を行っている。彼女らはユーザの音楽の好みを推測し、お勧めの音楽を選んでくれるシステム [Shardanand 95] を構築している。同じような研究は多く、複数のユーザが映画に対して批評を行なった結果を用いて批評空間を形成し、まだ見た事のない映画を推薦するシステム [館村, Ghosh 99] や、コンピュータを使いこんで行くうちに、ユーザが次に実行するであろうコマンドを予測して自動的に実行するシステム [Yoshida 96] など開発されている。これらの手法はユーザがどのような嗜好を持っているか、というユーザモデルに関するシンボルレベルの知識を獲得しているわけであるが、パーソナルロボットのようにユーザのために行動するロボットにおいては、単にユーザモデルを保持しておくだけでは適切な行動はできない。ユーザモデルに沿ってロボットの行動モデルも変更する必要がある。同時に双方のモデルを獲得する必要があるからである。

一方で、近年、対話型進化的計算手法と呼ばれるアプローチ [中西 98, 長尾 98] が注目され始めている。この計算手法ではユーザモデルやシステムの挙動などを遺伝子情報として表現し、対話を通じて遺伝子の適合度を評価し、遺伝的アルゴリズムを使って最適な解を探索する手法である。この手法はユーザモデルとシステムの動作のモデルを遺伝子の形に統合しているために、ユーザの嗜好に適した挙動をシステムに行なわせる事が容易である。このようにユーザとの対話を用いて評価を行なう事はユーザ個人への適応化には必要不可欠な要素ではあるが、遺伝的アルゴリズムであるために、膨大な数の遺伝子についてユーザが評価をしなければならず、ユーザへの負荷が大きな問題となっている [鈴木 99, 大崎 98]。

本章では、これらの点を踏まえ、ユーザに負荷のかからない手法でロボットの行動をユーザ個人へ適応化する事を目標とする。第3章で導入した確率的な行動決定モデルを利用する事で、ユーザがロボットを対話的に使用しているうちにユーザ個人の好みや癖、傾向などを学習し、よりユーザがロボットを有効に使用する事が可能である事を示す。

4.2 移動ロボットの障害物回避タスクにおける個人への適応

本節では、第3章で扱った、移動ロボットにおける自律移動行動の獲得タスクにおいて、ユーザへの適応問題を議論する。このタスクにおけるユーザ個人の嗜好は、どのような状況において、どのような行動をするのか、その判断基準の違いに現れて来る。例えば、障害物を避ける際に、なるべく障害物との距離が短くならないように、速くに障害物が見えたらすかさず回避行動を取るユーザもいるだろう。逆に、障害物として見えているのは人間で、自然と避けるはずだ、という予想から、なるべく回避行動は取らずに、ぎりぎりまで直進をするのが自然と考えるユーザもいるであろう。

第3章で扱った自律移動行動の獲得では、ロボットはユーザからの指示に従うマニュアル行動と、自分自身の判断で行動を行なう自律行動を混在させた状況で行動を行なう事を説明した。このような行動を取るロボットに対して、ユーザは通常は自律行動でロボットを行動させ、自分の取らせたい行動とは違う行動をロボットが取った場合、教示を行なってマニュアル行動に切替える。しかし、上で説明したように、とるべき行動の判断基準がユーザ個人によって異なる場合、あるユーザにとってはロボットの取る行動が自分の意思とほぼ同じに感じる事もあれば、あるユーザにとっては、自分の意思とは全く違う行動をロボットが取っている、と感じる場合もある。

そこで、センサと行動との関係をユーザによって獲得し直す事が要求されるが、それだけでは、先ほど説明した運転の戦略の異なるユーザに対応する事はできない。問題となるのは、距離センサを離散化して Bayesian Network に入力する際に、どのような離散化戦略を取るのか、という事である。この問題を解決する際にも、ユーザとロボットとのインタラクションを活用する事ができる。

これらのユーザへの適応問題は、ユーザが注目の対象としている問題空間にあるパラメータなどの基準で状態空間に切り分け、ユーザの嗜好や特性をその空間の中で表現していると言える。根本的な問題となって来るのが、その問題空間や状態空間の設定であり、この問題はロボットの行動とも深く関係している。強化学習の枠組では、この状態空間の形成のために自律的な状態空間の形成の研究が進められている[浅田 97, 高橋 99]。しかしながらこれらの状態空間の形成は、行動を獲得するためのトライ&エラーの過程と同じように膨大な行動の反復を必要とする。これらの研究の中では、ロボットの行動が環境とのインタラクションのみを前提としているため、ユーザとのインタラクションを前提とした状態空間の形成については考慮されていない。

そこで、本節では、後天的に行動を獲得する手法と同様に問題となってくる、状態空間の形成問題に対して、ユーザとロボットとのインタラクションの経験を利用する手法を提案す

る。この手法は強化学習のように状態空間の形成のためにロボットが行動をやり直す必要がなく、オフラインでの形成が可能である。このように、ロボットの行動獲得のための状態空間形成の側面からも、ユーザとロボットのインタラクション経験を利用する事は意義が高いアプローチと言える。

4.2.1 過去の経験の内省による行動決定モデルの最適化

センサデータが連続値の場合は、あらかじめ定められた閾値を用いて連続値のセンサデータを離散的な状態値に変換する必要がある。この閾値は環境によって決まるものであり、ユーザの教示の仕方によっても適切な値が変動する。すなわち、これはあらかじめ設定できるパラメータではなく、CPTの計算と同様、蓄積された経験に応じて適応的に変動させるべきパラメータである。

過去に行なわれた教示行動の際に、人間から与えられた教示行動と、その瞬間にロボットが推論した行動の相違を行動決定モデルのエラーを表す指標として注目する。ある時刻 t においてロボットが推論した行動の確信度を $BEL_t(B)$ とし、その時に人間が行なった教示動作を T_t とする。これらをベクトルとして扱い、この時刻における行動決定モデルのエラー値を、二つのベクトルの各成分の差の絶対値の和

$$e_t = \|BEL_t(B) - T_t\| \quad (4.1)$$

で表現する[稲色 99a]。このエラー値を教示が行なわれた全履歴に対して平均を取ったものを、行動決定モデルのエラー値

$$E = \frac{\sum_{t=1}^N e_t}{N} \quad (4.2)$$

とする。 N は履歴データの総数である。この値が小さければ、ユーザの教示を良く反映している行動決定モデルであると判断する事ができる。

この行動決定モデルのエラー値はセンサノードの閾値の値、取り得る状態の数などによって決まる。これらのパラメータ空間の中で最小のエラー値を求める事になるこの状態空間の構成法は、ユーザの対話的教示の履歴に基づいている。そのため、異なる判断基準を持つユーザに対して、個人別に適応した行動決定モデルを獲得する事ができる。

この状態空間形成手法を用いた場合の処理の流れを Figure 4.1 に示す。

4.2.2 推論のエラー値の有効性の検証

まず、単純な例で説明する。8個のセンサノードすべてがNear,Farの二つの状態を取るとし、その閾値 T もすべてのノードで共通であるとする。環境A,B,C,それぞれで走行した教示

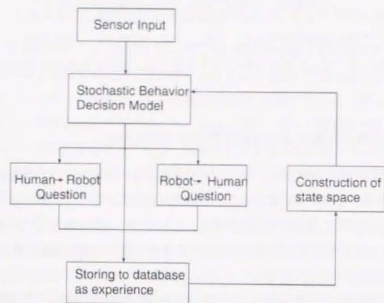


Figure 4.1: Abstract of behavior acquisition with state space construction

データに対する、閾値 T とエラー値 E の関係を Figure 4.2 に示す。このグラフから、 $T = 79$ の時にエラー値が最小値 0.87 となっている。グラフは単純な凹型をしており、この値から T が遠ざかるほど、エラー値 E は増大している。エラー値が最小となる $T = 79$ を選んだ場合と、エラー値が大きい $T = 29$ および $T = 130$ のそれぞれ場合に、未知の環境 D において自律走行させた結果を Figure 4.3 に示す。エラー値が最小となる閾値 $T = 79$ の場合は確かに障害物を回避しているが、 $T = 29$ の場合は障害物に衝突し、 $T = 130$ の場合はゴール地点で停止できていない。このことからこのエラー値が、行動決定モデルの評価基準として適している事がわかる。

4.2.3 GA を用いた状態空間の最適化

以上に述べた、推論のエラー値の計算量は非常に大きいものである。

1. 閾値に従って経験生データを離散化
2. 離散化された経験データから Bayesian Network の確率値を求める
3. 経験データの各サンプルデータに対して Bayesian Network による行動決定を行なう
4. 経験データにおけるユーザの指示との差分を計算する




Figure 4.2: Relation between distance threshold and error value




Figure 4.3: Running result for each threshold value

一つの閾値の取り方、すなわち一つの状態空間に対して、この一連の処理が行なわれる。計算量のオーダーは、Bayesian Network のセンサノード数が N 、行動ノードの取り得る状態数が B 、センサノードの取り得る状態数が S 、経験データのサンプル数を E とすると、過程1が $O(E)$ 、過程2が $O(EBSN)$ 、過程3が $O(EBSN)$ 、過程4が $O(EB)$ 、となり、経験データのサンプル数 E に依存する。さらに、変数となる閾値の数が D だった場合、 D 次元空間での検索となり、 $O(En^D)$ の計算量を必要とする。

前節の例では、一つの閾値 ($D = 1$) を決定するのに、1580 個のサンプルデータを用いていたが、推論のエラー値を計算するのに、PentiumII 450MHz のマシンを用いて、約 2.38[sec] を要する。一つの状態空間の候補に対してこれだけの時間がかかるので、前節で説明したグラフを生成するのに、256 回の計算を繰り返して、合計約 10[min] を要する事となる。前節の場合は、 $D = 1$ の場合の状態空間の検索であったが、各ノード別に閾値を設定したり、各ノード内部に複数の閾値を配置させる場合、 n^D が非常に大きな値となり、有効な時間内で状態空間の全空間を探索を行なうことが困難になってしまう。

そこで、GA を用いて最小のエラー値を探索することとする。Figure 4.4 のように、距離センサの状態値を Near, Middle, Far の3つの状態に離散化する事を考え、そのために必要な2つの閾値を2つの遺伝子で表現する。すなわち8個のノードで計16個の遺伝子を使用する。




Figure 4.4: Gene expression of distance sensor

GA の遺伝子の適合度として、先に説明した推論のエラー値を用い、この値が小さくなる遺伝子を生き残らせる GA を行なった。個体数 100、一点交差で交差率 0.6、突然変異率 0.95%、エリート戦略の条件下において、第 62 世代目で Figure 4.5 のような状態空間を形成した。この際の行動決定モデルのエラー値は 0.39 で、先の単純な例に比べてエラー値が非常に小さい事がわかる。

この状態空間の構成法がユーザ個人に適応可能であることを確認するために、ゆるやかに回避するように教示を行なった場合と、障害物の直前まで回避しない教示を行なった場合の二つの場合の実験を行なった。それぞれの場合に獲得したモデルで自律走行を行なった結果を Fig-




Figure 4.5: Result of sensor space construction using GA

ure 4.6 に示す。図からわかる通り同じ環境においてもユーザの教示を反映するような行動が生成されている事がわかる。

Figure 4.5 の状態空間は、一見すると閾値にばらつきがあるように見える。画面中央のセンサ (S_4, S_5 など) は状態 Middle が高い値に存在するのにに対して、画面端のセンサ (S_1, S_8 など) は状態 Middle が低い値に存在している。これは Figure 3.4 のセンサ配置に起因するもので、中央のセンサが端のセンサに比べて距離の値が大きい観測値を得るからである。その事実を踏まえると、中央と端のセンサに図のような偏りが生じるのはむしろ正常であり、推論のエラー値による状態空間の形成が有効である事がうかがえる。

この手法はユーザの教示に基づいて行動決定モデルを獲得するため、ユーザの教示の仕方に応じたモデルが獲得される。これは強化学習の場合と比較すると、報酬がユーザの教示に相当している。しかしながらユーザは必ずしも毎回の試行時に教示をする必要はない。ロボットは自律行動を行ないながら、自分自身の推論の確信度を、自分自身への報酬として使用する事になる。すなわち、ユーザの教示を基本的な報酬として使用し、報酬が存在しない場合は、自分自身の確信度を使用して報酬を生成する。というようにとらえる事ができる。




Figure 4.6: Acquisition result for gentle operation and rough operation

4.3 相互情報量規準に基づく状態空間の最適化

Bayesian Network で事象を表現するには、これまで説明して来た通り、確率変数を使用する。ある二つの確率変数の間には、相互情報量 (mutual information) を求める事ができるが、この相互情報量が、二つの事象の間に存在する因果関係を表現しているとも解釈できる。

確率変数 $\{a_1, a_2, \dots, a_n\}$ を持つ事象 A と確率変数 $\{b_1, b_2, \dots, b_m\}$ を持つ事象 B との間の相互情報量 $I(A; B)$ は次のように計算される。

$$\begin{aligned} I(A; B) &= H(A) - H(A|B) \\ &= \sum_{i=1}^n \sum_{j=1}^m p(a_i, b_j) \log_2 \frac{p(a_i, b_j)}{p(a_i)p(b_j)} \end{aligned} \quad (4.3)$$

ただし、 $H(A)$ は事前エントロピー (a priori entropy)

$$H(A) = - \sum_{i=1}^n p(a_i) \log p(a_i) \quad (4.4)$$

$H(A|B)$ は事後エントロピー (a posteriori entropy)

$$H(A|B) = - \sum_{i=1}^n \sum_{j=1}^m p(a_i, b_j) \log p(a_i|b_j) \quad (4.5)$$

である。

ここで、先に登場した、障害物回避タスクにおける各センサノードと、行動ノードの間の相互情報量について考える。相互情報量の定義より、センサノードと行動ノードの相互情報量が意味するものは、

「センサ情報の入力、行動決定に寄与する情報の貢献度」

- ＝ センサ情報が入力される前の、行動決定の不確かさ
- － センサ情報が入力された後の、行動決定の不確かさ

と解釈できる。つまり、この値が大きければ大きい程、そのセンサノードは行動決定に対して重要な役割を示している事になる。この相互情報量を、センサノードの設計のための規準として用いる事ができる。

4.3.1 障害物回避タスクでの状態空間の最適化

障害物回避タスクにおいて、センサノードを設計する際に、決定すべき自由度としては、次のような要素が存在する。

- 画面全体に分布している距離画像のうち、どの部分をセンサノードに対応させるか
- センサノードの個数をいくつにするか
- 連続値であるセンサノードを離散化する時に、いくつの個数の状態に切り分けるか
- 同様に、分割する閾値をどのように決定するか

これら、決定すべきパラメータを相互情報量を用いて決定するために、いくつかの検証を行った。

分割する閾値の決定

まず、閾値の決定問題を取り上げるため、その他の要素は固定とし、

- 画面水平方向に一行に8個のセンサノードを設ける
- 各センサノードは一つの閾値で二値化するものとする

という仮定を設定した。Figure 4.3 の環境 D における走行結果を用いて、各センサノードの閾値を変数とした時の、相互情報量の変化を Figure 4.7 に示す。この図では後の考察のために、ノード1からノード4までの並び順と、ノード5からノード8までの並び順が逆になっている事に注意されたい。ここでそれぞれのノードにおいて、最大の相互情報量を取る閾値の値を見ると、ノード1からノード8に向かって順に、60.77, 34.39, 69.69, 73.72 となっており、4.2.1節の「推論のエラー値」の場合の $T=79$ という値に非常に近い値が観測されている。また、Figure 4.2 では、最適な閾値から離れると評価値が悪くなる傾向が見られたが、それと同様な現象が Figure 4.7 に見られる。これらのことから、相互情報量に基づく閾値の決定方法は、先の「推論のエラー値」と同様に適切な閾値を選択する能力があると言える。

ここで、Figure 4.7 の結果を考察すると、左右対称の結果が得られるべきであるにもかかわらず、直感的に違和感の生じる結果を得ている。(図中の上下の並びが左右対象であるはずの二つのノードに対応している) これは左右対称ではない環境 (Figure 4.3) で行動しているためと考えられる。そこで、環境 D を左右反転させた環境 E (Figure 4.8) を用意し、それぞれの環境で5回づつ、計10回走行させた時の相互情報量の変化を Figure 4.9 に示す

この図では、左右対称であるはずの二つのノードに関するグラフがほぼ同じ形状を示しており、問題は無い事が示されている。




Figure 4.7: Relation between threshold value and mutual information for each node




Figure 4.8: Virtual environment E

分割する状態の個数の決定

次に、一つのセンサノードに対して、いくつの個数の状態に分割すれば良いか、という問題を扱う。単純に考えれば一つの閾値で二値化を行なうよりも、より多くの閾値を設けて多値化を行なう方が、よりきめの細かい推論を行なう事ができる。しかしながら、やみくもに状態の数を増やしても、ある個数以上では効果が頭打ちになる事は容易に想像できる。また状態の数が増えるという事は、条件つき確率テーブル (CPT) の状態空間が広がる事となり、なかなか学習が収束しなくなるデメリットもある。

まず、基本的な検証として、閾値を一つから二つに増やす、すなわち、状態の個数を二つから三つに増やす事を考える。評価規準となる相互情報量は二つの閾値の関数となる。

前節で説明した条件のうち、左右対称の環境でそれぞれ5回づつ走行させた場合に、相互情報量と二つの閾値との関係を図示したものが、Figure 4.10 である。底面の二つの軸が




Figure 4.9: Relation between threshold value and mutual information (at symmetrical environment)

二つの閾値を示しており、縦軸が相互情報量を示している。それぞれのノードにおいて相互情報量が最高となる地点は Table 4.1 のようになり、センサの状態空間を図示すると、Figure 4.11 のようになる。

Figure 4.5 と見比べて分かるように、推論のエラー値を評価基準に用いた場合と、相互情報量を評価基準に用いた場合とで、大きな差異はなく、ほぼ同じ状態空間が形成されている。

このようにして、一つのノードに対応する状態の数を3つ、4つと増やして行っても良いが、先に説明した通り、条件付き確率テーブルの次元数が増加する。このため、すべての状態が観測されるまで学習が収束せず、ユーザは何度もロボットの質問に答えなければならない状況となる。経験的に、一つのセンサに対する状態数の限界は3であった。そのため、最適な閾値の個数は2となり Figure 4.10 のようなグラフから適切な2つの閾値を求める作業のみで十分である事が分かった。

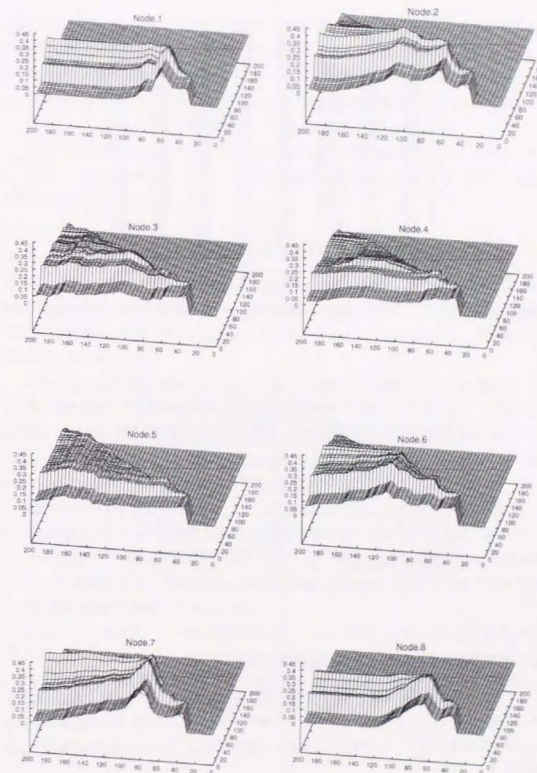


Figure 4.10: Relation between two threshold values and mutual information (at symmetrical environment)




Figure 4.11: Result of sensor space construction using mutual information criterion

Table 4.1: Highest mutual information for each node

ノード番号	第一閾値	第二閾値	相互情報量の最高値
Node 1	33	61	0.338
Node 2	61	109	0.331
Node 3	65	109	0.257
Node 4	61	137	0.203
Node 5	33	165	0.269
Node 6	33	109	0.348
Node 7	33	77	0.430
Node 8	33	65	0.327

4.3.2 相互情報量を用いたセンサの重要度の評価

ここで導入した相互情報量は、単に状態空間構成のための指針だけにとどまらず、センサが生み出す情報の持っている価値としても捉える事ができる。すなわち、相互情報量の低いセンサには情報の価値がなく、センサとしてもあまり価値がない、という評価基準に転用する事が可能である。

障害物回避タスクにおける Bayesian Network では、8 個のセンサノードがロボットの視野角に合わせて Figure 3.2 のように均等に分布していた。しかしながらこの均等に分布させ

る事に必然性はなく、より注視する必要がある場所にセンサを密にならべ、それほど監視する必要のない個所にはセンサを粗に配置するのが効率的である。このセンサの配置を設計する際に相互情報量を用いる事が可能である。Table 4.1 の結果からすると、画面中央のセンサはそれほど重要ではなく、逆に画面の端のセンサの法が重要である事がわかる。これによって、センサはなるべく画面の端の方に密に配置すれば良い事がわかる。

また、同一種類のセンサだけでなく、多種類のセンサを統合するようなシステムにおいては、重要なセンサの種類とそうでないセンサを分別する事が可能となり、システムの設計をする際の有効な指針となる。

4.3.3 推論のエラー値と相互情報量の双方を用いた状態空間の評価法

ここまでで、相互情報量規準を用いた状態空間の評価法を述べてきたが、ここで、4.2節で述べた推論のエラー値との比較を行う。相互情報量規準は特定の二つのノード間の、局所的な状態空間を評価する手段であり、推論のエラー値はネットワーク構造全体の、大局的な状態空間を評価する手段である。

局所的な状態空間の評価ができるという事は、状態空間の探索に必要な計算量を、ノードの数や、確率変数の状態数のオーダーで抑える事が可能であるという事になる。推論のエラー値を使用した場合には、4.2.3節で述べたように探索すべき状態空間の規模が確率変数の状態数に対して指数関数的に大きくなるため、適切な状態空間を探索するのに非常に多くの時間を要する。この点が相互情報量規準を用いる利点となる。

逆に、大局的な状態空間の評価ができるという事は、ネットワークの構造を変化させながら、最適な構造がどのような構造なのかを探索する事ができるという事になる。例えばセンサノードの数をいくつにするのが最適であるのか、という問題は相互情報量規準だけでは解くことのできない問題である。しかしながら局所的な評価ができないため、4.3.2節で述べたようなセンサの重要度を評価する事には応用できない。

このように、推論のエラー値と相互情報量は、互いに長所と短所を補完的に持ち合わせている。ネットワーク構造やノードの数の決定のような大局的な評価の際には、推論のエラー値を用いて探索を行い、ノードの持っている重要性などの局所的な評価の際には、相互情報量規準を用いて探索を行う、という手法が有効である事が分かる。

4.4 個人に適応した語彙の獲得

前節までは、ロボットの行動を個人に適応させる手法について述べたが、本節ではロボットに対する指示を行なう時に使用する語彙を個人に適応させる手法について述べる。

ユーザが「その赤い本を取って」などと、実際の物理世界での動作や作業を表現する際には、色の表現を使った言葉が多い。ロボットに指示を出す時にも同じような事は考えられるが、この色の表現を使用する際には問題が多い。例えば交通信号の「青信号」は、緑と表現する人もいる。このように色の名前と実際の色の物理パラメータの間には、固定的な一対一の関係はない。文化の違いや環境によって色の感じ方は違うし、使用する色名の種類も個人差がある。また、青と紫の中間のような微妙な色の場合、人間は周辺に存在する色から影響を受けて、同じ色でも条件によっては異なる色に感じる場合もある。本節では、このような問題に対応するために、ユーザが指示する色の名前と、実際の物理的色パラメータの関係を獲得する手法について述べる。

4.4.1 色名と色パラメータの結合関係の表現

実験で使用している Bayesian Network は非常にシンプルなもの、Figure 4.12 のような二つのノードから成る構成である。このノードは他のノードと組合わせて複雑な Bayesian Network に使用することが可能になっているため、本節で獲得した経験は、他のタスクでも使用可能になっている。実際に第6章での実験で使用されている。

色の名前を表すノード CN(Color Name)は、移動ロボットの行動制御に使用されていた Bayesian Network 内の行動ノードと同じように、離散的な状態値を持つノードで、状態が「赤」や「青」などの色名に相当している。色の視覚特徴パラメータを表すノード CP(Color Parameter)は、センサノードと同じように、数値データを表示するノードである。移動ロボットの場合は距離センサを示すスカラー情報であったが、色の視覚特徴パラメータを表現するために、色相(Hue)と彩度(Saturation)の2次元ベクトルに対応するノードとした。Hue と Saturation の2次元ベクトルで表現された色パラメータは、Figure 4.12 右のような離散化を行なう事で、 $\{cp0, cp1, \dots, cp12\}$ のように13種類の状態値を持つ確率変数に変換される。すなわち、この Bayesian Network によって、シンボル情報と数値パラメータ情報を確率的にバインドさせる事を狙うものである。

物理パラメータから色名を推定する場合には、観測データ cp から条件付き確率を使用し、

$$BEL(CN) \stackrel{\text{def}}{=} P(CN|CP = cp)$$




Figure 4.12: Bayesian Network for relation between color name and parameter

$$= \frac{P(CN) \cdot P(CP|CN)}{P(CP = cp)} \quad (4.6)$$

で定義される確信度 $BEL(CN)$ を使用する。この確信度はベクトルであり、その成分は CN の確率変数の成分と対応している。

4.4.2 対話経験の蓄積に基づくモデルの更新

次に、ユーザとのインタラクション経験から事前確率 $P(CN)$ や事後確率 $P(CP|CN)$ を求める基本的な手法について説明する。ロボットは観測されたセンサ情報 cp とユーザが使用した色の名前 cn の組を経験として蓄積する。 N 回の経験の中で、ユーザから色名 cn_j が教示された回数が N_j 回であり、その教示が行なわれたうちで、色のセンサ情報として cp_i が観測された回数が n_{ij} だったとする。単純に累積頻度度数を用いて、事後確率、事前確率を計算する方法は以下ようになる。

$$P(cp_i|cn_j) = P(CP = cp_i|CN = cn_j) = \frac{n_{ij}}{N_j} \quad (4.7)$$

$$P(cn_j) = P(CN = cn_j) = \frac{N_j}{N} \quad (4.8)$$

4.4.3 推論のエラー値に基づく状態空間の形成

ここで、4.2.1節で述べた、推論のエラー値を用いて色の名前と視覚特徴パラメータの間の状態空間を最適化する事を考える。ある時刻 t における経験データにおいて、ロボットが推論した色の名前の確信度を $BEL_t(CN)$ とし、その際に人間が使用した色の名前を T_t と表現する。 T_t はベクトルであり、各成分が色の名前ノードの確率変数の状態に対応している。すなわち、 $CN = \{Red, Blue, Yellow,$

Green} という確率変数だった場合に、赤という教示情報が与えられていれば $T_t = \{1, 0, 0, 0\}$ という具合である。この時刻における色の名前の推論のエラー値を、二つのベクトルの各成分の差の絶対値の和

$$e_t = ||BEL_t(CN) - T_t|| \quad (4.9)$$

で表現する。このエラー値を対話が行なわれた全経験履歴に対して平均を取ったものを、確率モデルの推論のエラー値

$$E = \frac{\sum_{i=1}^N e_i}{N} \quad (4.10)$$

とする。N は履歴データの総数である。この値が小さければ、ユーザの教示を良く反映しているモデルであると判断する事ができる。

このモデルの推論のエラー値は色の物理パラメータノードの閾値の値、取り得る状態の数などによって変化する。これらのパラメータ空間の中で推論のエラー値が最小となる状態を求める事になるが、探索空間が膨大になるため、4.2.3節と同じく遺伝的アルゴリズム (GA) を用いて探索を行なう。

12個の遺伝子を用意し、それぞれを Figure 4.12 の CP のパラメータ空間を形成するための閾値に対応させ、パラメータ空間を13の区間に区切る。初期状態として、 $CN = \{\text{Red, Blue, Yellow, Green}\}$ に設定した状態から、二人の被験者に自由に色の名前を使用して良い条件のもとで、ロボットとのインタラクションを行なってもらった。

この結果、得られた色の名前の状態空間を Figure 4.13 に、その場合の色のパラメータノード CP の空間を Figure 4.14 に示す。被験者1は38回のインタラクションを行ない、「赤」「オレンジ」「黄色」「緑」「水色」「青」「紫」「該当色なし」の8種類の色の表現を用いた。またこの際、推論のエラー値は最適値 $E = 0.0968$ を示した。

同様に被験者2における CN と CV の状態空間をそれぞれ Figure 4.15、Figure 4.16 に示す。被験者2では、約200回のインタラクションを行ない、「赤」「オレンジ」「黄色」「緑」「水色」「青」「紫」「黄緑」「赤紫」「該当色なし」の10種類の色の表現を用いた。またこの際、推論のエラー値は最適値 $E = 0.376$ を示した。

図から分かる通り、Hue のパラメータ空間の中で色の名前は均一に分布しているわけではなく、ある程度違う Hue の値でも同じ色の名前で表現する領域もあれば、わずかな Hue の差で名前が変わる領域も存在する。例えば「緑」の区間は広いのに対して、「オレンジ」や「黄色」の区間は非常に短く、密度の高い状態空間が形成されている事が分かる。この事からも、推論のエラー値によって状態空間を生成する手法の有効性が確認できる。




Figure 4.13: Color name space built by testee 1




Figure 4.14: Color value space built by testee 1

Table 4.2: Result of color name acquisition

被験者1	対話データ数	38
	Sat の閾値	19
	Hue の遺伝子	5,39,50,53,58,65,92,148,215,315,325
被験者2	対話データ数	199
	Sat の閾値	33
	Hue の遺伝子	30,56,69,99,121,172,199,256,277,299,342




Figure 4.15: Color name space built by testee 2




Figure 4.16: Color value space built by testee 2

4.4.4 新しい色名の追加

日常生活の会話の中で登場する色の名前は、前節で述べたように少なくはない。しかも表現の中で使用する色の名前は個人によって偏っている。色の名前とパラメータの関係だけではなく、どのような色名を使用するか、という事についても個人への適応を考慮する必要が生じる。

新しい色名を登録する事は、Figure 4.12 の Bayesian Network のノード CN を変更する事になる。ノードは確率変数と対応しているので、新しい色名に対応した確率変数の状態を増設する事になる。この増設に伴う変更は、ノード間の CPT のみであるが、ただ色名の追加が行なわれただけではノード CP のどの確率変数に対応するか、が分からず、新しい色名に対応する CPT の要素は 0 のままとなってしまう。このままでも特に問題はないが、色名からパラメータを推論したり、逆にパラメータから色名を推論する事はできない。なんらかの形でパラメータとの関係を獲得しなければならぬ。

ここで、新しい色名が追加される対話の状況を分類すると、次の3つが存在すると考えられる。

1. 「紫色という色を覚えて」と、単に色名だけの情報が与えられた場合
2. 「これは紫色です」と、ユーザが特定の物体を指さして発話した場合
3. 「その紫色の箱を取って」と、完全にパラメータ情報を特定できないが、参考になる情報が得られた場合

そこで、この3つの場合別に、ロボットは新しく登録された色名と、色パラメータの関係を獲得する行動を取る。

1. の、単に色名だけの情報が与えられた場合は、ユーザに対して「どれが紫色なのか」教えて下さい、などと教示の依頼をする。しかしながら会話が進んでいる状況において、紫色の物体がなければこのような依頼は無意味に終わってしまう。3. のように、その場に「紫色」の物体が存在する確証がないので、Figure 4.17 のようなインタフェースを提示して、教示の依頼をする。

2. の、ユーザが特定の物体を指さして発話した場合、その物体の色のパラメータを観測し、前節で述べたように経験データベースに登録すれば良い。

3. の、「その紫色の箱を取って」と、完全にパラメータ情報を特定できないが、参考になる情報が得られた場合は、ロボットがそのパラメータ情報を特定するために「箱」が示している物体を探索する事になる。箱が一つしかない場合には簡単に特定できるため、その箱の色



Figure 4.17: Experiment on interaction for color naming

パラメータを登録すれば良い。箱が二つ以上ある場合など、複雑な状況な場合には、第6章で述べる、視覚探索タスクを行ってから、色パラメータの登録を行なう事になる。

この新しい色名の獲得の流れを Figure 4.18 に示す。

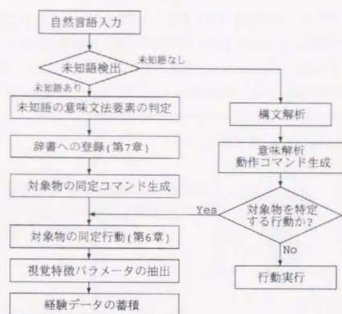


Figure 4.18: Flowchart of for word acquisition for color name

4.4.5 ユーザへの負荷軽減への展望

今まで説明したような手法では、色名の発話と色パラメータの関係を獲得するために何回もの対話を重ねる必要があった。少々色パラメータが変動しても、ユーザは同じ色であると認識し続ける。しかしながらロボットにとっては、少しの色パラメータの変動でも、違う色として判定してしまう可能性が高い。例えば暗い部屋に移動した場合、色パラメータは変動するが、人間には色の変動はあまり感じられない。このように照明条件が異なる状況で色名を用いた指示を行なうと、ロボットはそのパラメータを同一の色名として認識し続けるために、「この物体は赤いですか？」など何回も質問してくる事になる。そこで、ユーザへの負担を軽減するために、照明条件が変動している条件下でも同じ色名に対して自動的に色パラメータを対応させる手法について述べる。

日常生活内で考えられる照明条件の変動としては、照明の明るさの変動、また、窓から差し込む光による逆光効果などがある。このような照明条件の変動に対しても、特定の対象物体を追従し続け、色パラメータを採取する手法を ZDF (Zero Disparity Filter) 法 [Coombs 93] を改良して実現した。ZDF 法を用いた物体の追従行動については、喜多らが拡張 ZDF を提案し [喜多 95, Kita 94, Rougeaux 94]、それを色画像に使用するための提案を栗田ら [栗田 96a] が行なっている。しかしながらこれらの手法では、色相と彩度のスレシールドは固定的な値を用いていたため、照明条件の変動による色パラメータの変動に対応する事ができなかった。

そこで、照明条件の変動に対応して色画像を抽出する際、色相と彩度の色パラメータ値を変化させる事で、ロバストな追従を目指す事とした[稲邑 98c]。具体的には、適切な色抽出が行なわれた際にその画像に含まれる色相と彩度の平均値 / 分散値を計算し、次のステップにおける色抽出に使用する新しいスレシールドを算出する。この処理により、照明変動に対して動的に適應する色抽出が可能となる。処理時間は66[ms]であり、人間を追従するには十分なりアルタイム性がある。

この処理の流れを Figure 4.19 に示す。

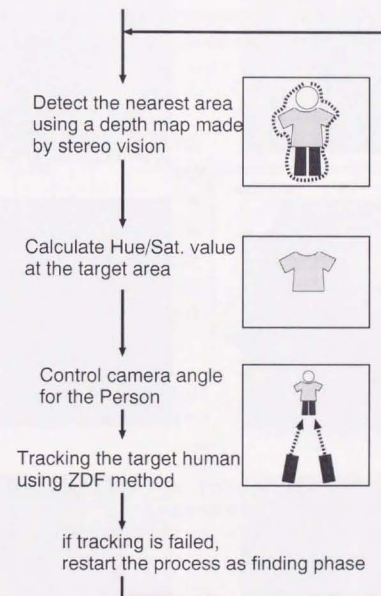


Figure 4.19: Abstract of human following processing

逆光状態で人間の追従

Figure 4.20 のような部屋環境において、A 点から B 点を經由して C 点まで移動し、また同じ経路をたどって A 点まで歩く人間を追跡する実験を行なった。人間は赤い服を着ており、ロボットはその場で回転しながら赤色を追跡する。Figure 4.21 のグラフは観測された色相と彩度の変化の様子である。図中の縦軸の値は、色相に対しては [deg]、彩度に対しては 0 ~ 181 までの値で彩度を表現した時の値を示している。この際の画像処理の様子を Figure 4.22 に示す。




Figure 4.20: An environment where the robot follow users against sunlight

Figure 4.21: Result of hue and saturation parameter for the environment

グラフから分かる通り、A,B,C 点それぞれで、ターゲットの彩度が大きく変化している。特に B 点においては、逆光となっており、彩度が急激に落ち込んでいる。色画像を抽出する際に彩度の変化を考慮してスレシールドを決める事により、逆行状態でもロボバストにターゲットの追跡を行なう事ができた。

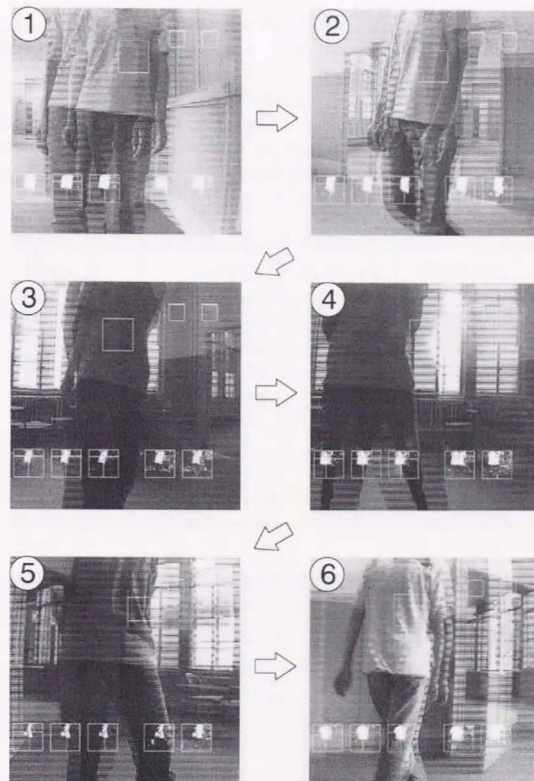


Figure 4.22: Image processing sequence during color following task

明暗の差がある環境での人間の追従

次に、Figure 4.23 のような明るい部屋と暗い部屋が連続するような環境で、明るい部屋から暗い部屋に向かって歩く人間を追従させた。この場合も前と同様にロボットは赤色を追跡する。

Figure 4.24 が追従行動を行なった際の色相と彩度の変化である。暗い部屋に移動するにつれ、彩度の値が低くなるのが読みとれる。また彩度の変動と共に色相の値も影響を受け変動している事がわかる。この実験は夜に行なわれており、暗い部屋は照明を全て消した状態であるが、適切な色相と彩度の値を選択し、追従行動をロボットに持続させている事がわかる。実際の画像処理の様子を Figure 4.25 に示す。




Figure 4.23: An environment where the robot follow users against sunlight

このように、同じ色に対して複数の状況での色パラメータの変動を観測し、そのデータを経験データベースに蓄積する事によって、ユーザへの対話量を減らし、負荷をかけない学習を行なう事が可能となる。




Figure 4.25: Image processing sequence during moving into dark room

4.5 本章のまとめ

本章では、ユーザの個人的な嗜好や習慣に応じてロボットが行動を適応させるための手法について述べた。このパーソナリ化の問題は、第3章における Bayesian Network による行動決定モデルの構成問題に帰着できる事を示し、状態空間の構成を行なう評価基準を導入した。一つ目の評価基準として、ネットワークの構造の変動が過去の対話経緯に与える矛盾性に注目し、推論のエラー値という基準を設けた。この基準により過去のユーザとの対話経緯を再利用し、オフラインでユーザに適応したネットワークの状態空間を構成した。二つ目の評価基準として、確率モデルが持つ相互情報量に注目し、事象間の相関関係を相互情報量で評価する手法を提案した。この手法により、必要十分な量のネットワーク構造を構成し、状態空間を形成可能である事を示した。これらの手法はネットワーク構造の変化に際して学習行動をやり直す必要は無く、経験データを用いた数値計算のみでユーザへの適応を行なう事ができる利点を持つ事を示した。

Bayesian Network の構造の決定法に関する従来研究としては、リンクを張るべきノード関係を求めるものが多い [植野 96, Larranaga 96]。これらの手法では、何らかの評価基準を元にノード間に存在する因果関係を求めているが、ノードに割り振られる確率変数の状態を設計する指針については述べられていない。本章で提案した推論のエラー値に基づく状態空間の構成法は、ノードに対応する確率変数の構成を求める手法として、従来研究とは違う側面を持ち合わせている。

第5章

対話と自律行動に基づく環境知識の獲得

5.1 はじめに

第3章では、ロボットが全く知識を持たない状態から、ユーザの指示に合わせて行動を後天的に獲得し、環境の変動やノイズに対してロボストに行動決定を行なう手法について述べた。パーソナルロボットは後天的に知識や行動を獲得する必要があるが、第3章ではそのうちの行動獲得について考察を行なった位置付けであった。

本章は、行動に関する知識と同様に、環境に関する知識を開発者があらかじめロボットに埋め込む事なく、後天的に獲得する手法について述べる。この環境はオフィスや病院などの環境を想定しており、具体的には部屋の配置関係や部屋の名前、またその環境の中で活動する複数のユーザの情報を獲得する。

このような環境におけるロボットの行動を支援する研究として、ユーベキタスコンピューティング [Welser 93] と呼ばれる研究領域が存在する。例えば、藤井らは IDC と呼ばれる情報キャリアデバイスを廊下環境に配置し、個々のロボットが局所的な情報をキャリアデバイスに通信する事によって、群ロボットののための大局的な環境知識を構築する手法を提案している [藤井 99a]。また、佐藤らはロボティックルームと呼ばれる、ロボットエージェントに囲まれた人間の生活を支援する知的なエージェント空間を提案している [Satoh 96]。

これらのインフラストラクチャを前提としたロボットは、環境情報を獲得する事のできるエージェントが環境の至る所に分散されているので、情報が不足する事が少なく、ロボストに行動する事ができる。しかしながらパーソナルロボットの定義、前提から考えると、必ずしもインフラストラクチャが整備されている環境を期待する事はできない。本章ではロボットが自分自身の能力で、未知の環境の知識を獲得収集し、後天的にその環境に適応するための手法について述べる。そして、インフラストラクチャを期待するのではなく、その環境で共に活動している人間を最大限に活用する。すなわちユーベキタスコンピューティングではなく、ユーベキタスユーザ、とも言えよう。

まず、部屋の配置と名前を獲得するために、ロボットは自律的に環境内を走行し、ビューシーケンスと呼ばれる視覚に基づく環境地図を作成する。部屋の名前の獲得には近くにいるユーザに質問を投げかける。次の段階として、どの部屋に、いつ、誰がいるか、という情報を収集する。これらの情報はロボット自ら、視覚を用いて観察したり、不足している情報をユーザに質問して補ったりして経験に蓄える。これらの経験から、人間が日常生活においてごく普通に使用している、「たぶんあの部屋にいる」というような確率的な表現で環境の知識を表現する事を目的とする。

5.2 対話に基づく環境地図の獲得

5.2.1 ビューシーケンスによる環境地図の表現とナビゲーション

オフィスのような環境において、荷物を配達したり、道案内をするサービスロボットは数多く存在するが、その多くは動作する環境の地図情報をあらかじめ与えられた上で動作しているものがほとんどである [Nourbakhsh 95, Horswill 93]。また、自ら環境地図情報を獲得できたとしても、ユーザとロボットとの対話を考えると、ナビゲーションのためのセンサ情報に基づく地図だけでなく、ユーザに理解できる形で意味を持った環境地図が必要となってくる。この問題の具体的な例は、部屋の名前と物理的な位置の関係の獲得であろう。

この部屋と物理的な位置の関係を記述し、ロボットの目的地への移動行動を実現するために、ビューシーケンスによるナビゲーション [松本 97c, 松本 97d, Matsumoto 97] を採用した。このビューシーケンスによるナビゲーションは Figure 5.1 のように、記憶画像と現在の画像とのマッチングを取る事によって、現在位置の認識と行動決定を行なうアルゴリズムである。記憶画像は、一度走行した場所に対して特別な画像処理を行わず、見えた画像をそのまま記録する。これにより、ランドマークなどが存在しない空間においてもロボットのナビゲーションが実現可能となる。また、同時に記憶画像と現在画像の差分が障害物の検出モジュールとして使用できるため、一回のマッチング処理を行なうだけで、ナビゲーション情報と、障害物の検出情報を得られる事も利点の一つとなっている。

この画像列データベースには、その場その場での画像の見え方 (ビュー) だけでなく、スタート地点からの相対距離、および、その場所に関する情報タグが付加されている。(Table 5.1) このような情報を記録する事によって、コーナーを曲がったり、行き止まり地点において U ターンする行動などを実現している。本研究では、この情報タグにさらに部屋の情報を付け加える事によって、先に問題となったシンボルレベルの知識表現を物理世界レベルの情報とバインドする。

5.2.2 自律的な環境地図の獲得

この画像列に基づくナビゲーション手法は、ステレオカメラによって生成される距離情報を用いて、自律的に地図を獲得する事が可能である [Matsumoto 99, 松本 98b]。この場合、エンコーダの距離情報などを元に、廊下の形状情報を構築する事が可能であるが、部屋の名前を自律的には獲得できない。そこで、ロボットが初めて走行する環境において自律地図獲得を行っている際に、ユーザが音声による発話を行ない、部屋の名前を教示する事も可能である。

この教示行動はロボットが行動している最中でも、オンラインで行う事が可能であり、オ

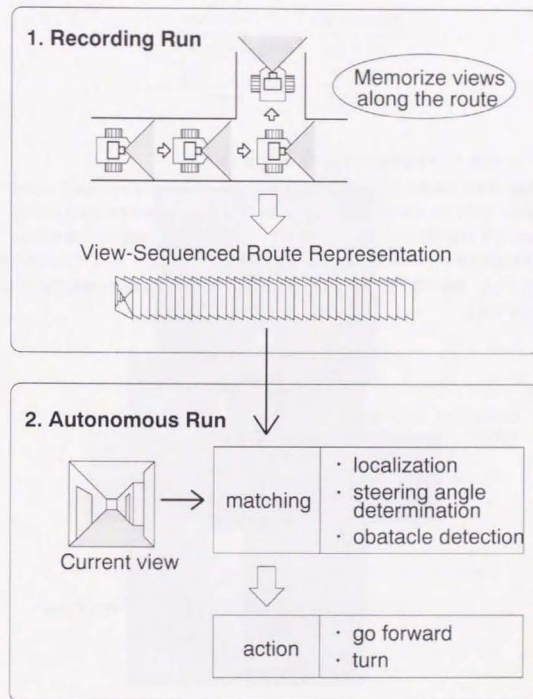


Figure 5.1: Abstract processing of view sequence

Table 5.1: A table of information tag for the view sequence data structure

情報タグの種類	データの実体
廊下の形状	Straight, Corner, End
相対距離	エンコーダの値
場所の名前	部屋名

ラインで画像データを視覚化して教示する事も可能である。

実際に保存する画像は Figure 5.2 のような全方位カメラ (Omni-Directional Camera) と呼ばれる、ロボットの周囲 360 度をすべて写す事ができるカメラで撮影された映像を用いる。Figure 5.3 のように、全方位ミラーで撮影された画像を円筒面に投影した画像を用いる。これを展開する事で、ロボットの向いている方向に依存することなくマッチング処理を行う事が可能となる。実際の廊下環境において作成したビューシーケンスに基づく環境地図を Figure 5.4 に示す。




Figure 5.2: Omni-directional camera

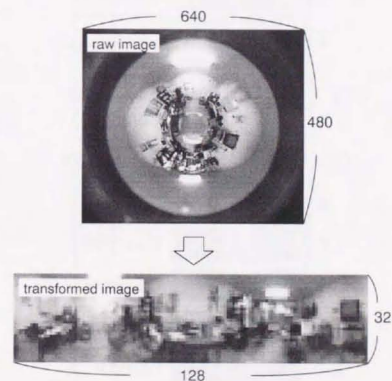


Figure 5.3: A raw omni-directional image and transformed image




Figure 5.4: Environment map based on the View Sequence

5.2.3 ユーザとの対話に基づく環境地図の更新

この環境地図は全方位画像部と、タグ部に分けられる。タグ部には基本的に「corridor」というタグが埋め込まれる。ロボットが部屋の前にいる場合に、必要に応じてユーザが部屋の名前を教示することにより、部屋の名前のタグが埋め込まれる。

まず、ロボットは部屋が存在する場所を認識する必要があるが、実験に使用した廊下環境では、ドアがうすい緑色をしており、その色を用いて部屋を検出する事とした。




Figure 5.5: A example situation for room detection



Figure 5.6: Raw image of Hyper-Omni view

Figure 5.6 は、ロボットの右側に両開きのドアがあり、左側には半分開いた状態のドアがある状況 (Figure 5.5) での全方位画像である。この画像に対して色抽出を行なった結果が Figure 5.7 である。さらに膨張収縮処理によるノイズ除去を行ないラベリングを行なった結果が Figure 5.8 である。図から分かる通り、ロボットは右側と左側にドアがある事を検出し



Figure 5.7: Binarized image by color extraction



Figure 5.8: Labeled image for detecting doors

ている。

ドアの検出が行なわれた後は、その場所には部屋の名前を登録する必要があるので、その部屋にいるユーザに対して部屋の名前を質問する行動を行なう。この際の会話結果を Table 5.2, Table 5.3 に示す。

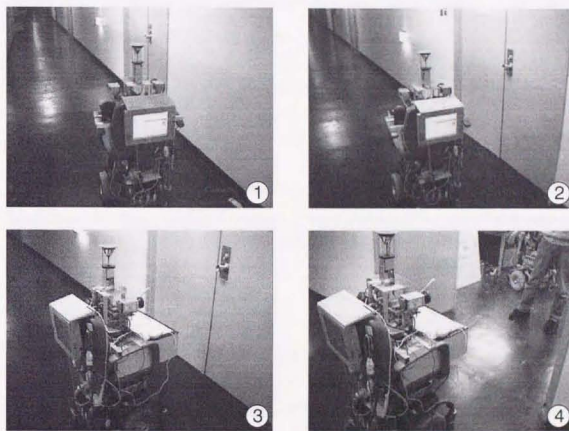


Figure 5.9: Room searching and name querying (1)

Table 5.2: Dialogue at room searching

- ロボット「進みます」(写真1)
- ロボット「右側にドアを発見しました」(写真2)
- ロボット「ドアを開けて下さい」(写真3)
- ロボット「部屋に入ります」(写真4)




Figure 5.10: Room searching and name querying (2)

Table 5.3: Dialogue at room's name querying

ロボット「この部屋の名前を教えてください」(写真5)
 ユーザ「ここは709です」(写真6)
 ロボット「ありがとうございました」(写真7)
 ロボット「廊下に戻ります」(写真8)

5.2.4 ビューシーケンスを用いた環境変動への対応

従来までのビューシーケンスによるナビゲーションでは、人間がいない、環境の変化が無い条件を前提としていた[松本 97d]。その原因ともなっているのが、環境の変動への対応が難しいという点である。ナビゲーションのための行動は経路に沿って進むか、障害物などを検出して止まるか、の二つだけであった。このままでは、記憶の中の画像と、実際の環境の画像が一致するまで、すなわち障害物が無くなる限り、先に進むことはできなかった。しかも照明変動などで局所的に明るくなった場所に関しては、対応する手段が全くなかった。

しかしながら、パーソナルロボットのコンセプトでは、人間が大勢いるような環境での走行も行う必要がある。そこで従来のビューシーケンスによるナビゲーション機能を拡張し、環境が変動する場合や人間が歩き回るような環境におけるナビゲーションの可能性について検証する。

障害物への対応

ビューシーケンスによるナビゲーションでは、各時刻における現画像と記憶している参照画像とをマッチングし、操舵角を決定していた。しかし第3章で述べたような障害物回避を行うと、ロボットは記憶画像を採取した際に走行した経路とは大きく異なる経路を通る事となり、ビューシーケンスによるナビゲーションが正しく行われる保証はない、という問題がある。そこで、ビューシーケンスによるナビゲーションに、第3章で述べたような障害物回避行動のモジュールを追加し、障害物を回避する必要がある場合には、ビューシーケンスによる操舵角の出力よりも障害物回避のための操舵角を優先するような走行を行った。

Figure 5.11 に人間が廊下の壁際に立っていた際に、その横をビューシーケンスを用いて走行した場合の、記憶画像と現画像の差分値を記録したグラフを示す。横軸はいずれも距離をエンコーダーのカウンタ数で表したものであり、1カウンタは約4.3[cm]である。縦軸は、現画像と参照画像を比較した時のマッチングエラーである。図中波線のReference Image 0は今いる場所と対応する記憶画像を参照画像とした場合のマッチングエラーを示し、実線のReference Image 1は、次に進むべき個所に対応する記憶画像を参照画像とした場合のマッチングエラーを示している。

人間付近でのReference Image 0のマッチングエラーはおおよそ50000を中心にのこぎり状に推移し、Reference Image 1のマッチングエラーは、人間付近ではおおよそ40000を中心にのこぎり状に推移している。通常の廊下を走行している時のグラフをFigure 5.12に示したが、この場合と比べマッチングエラーの値が逸脱しているとは言えない。以上のことから、障害物などがあつた場合、マッチングエラーは平均的に高くなるが、参照画像の切替は問題なく行

なえることが分かる。次に、切替える位置が障害物がない場合とどのくらい違うかを見てみると、エンコーダーの値から計算するとドアが開いていた場合には平均で 8.66[cm]、人間が立っていた場合には平均で 6.50[cm] ずれている。画像列をとる時の間隔は経験的におよそ 50[cm] から 100[cm] 程度であるので、このずれの値は画像列の間隔を越えてはいない。すなわち、このずれは蓄積される性質のものではなく、毎回参照画像を更新する際にクリアされるので、問題なくナビゲーションを行う事が可能であると言える。




Figure 5.11: Matching error when the door opens

照明変動への対応

次に、照明変動などに対して対応する手法を追加する。具体的には、部屋のドアを閉めた状態で記憶した画像を用いて、ドアが空いている状態での走行を目標とし、その実現のための条件を明確にする。ドアが閉まった状況での記憶画像を用いて、ドアから差し込む部屋の光がある状況で走行した時のグラフを Figure 5.13 に示す。通常の廊下の場合、参照画像 0 はおよそ 35000 を中心に推移し、参照画像 1 はおよそ 19000 を中心に推移している。これを踏まえてドアが開いている状況でのグラフを見ると、ドア付近での参照画像 0 のマッチングエ

ラーは、およそ 49000 を中心にのこぎり状に推移し、参照画像 1 のマッチングエラーもおよそ 40000 を中心にのこぎり状に推移している。

これらの実験結果から、人間が頻繁に行動する環境や、ドアの開け閉めが頻繁に起こるような実環境においても、ビュースーケンスによるナビゲーションを維持する事が可能である事が確かめられた。




Figure 5.12: Matching error during running in normal corridor environment




Figure 5.13: Matching error during running in normal corridor environment

5.3 視覚情報に基づく人間の行動の観察

コンピュータビジョンの応用として、人間画像を観察し、動作の意味や行動意思などの理解を行なう研究が数多くなされてきた[森 95]。人間を観察するために、顔画像を認識するもの[Rowley 96]、輪郭線を抽出するもの[Kass 88, Baumberg 94]、人の動きを利用するもの[Liu 98, Shi 98]、人間の体の形状に特化したモデルを用いるもの[Wren 97]。あるいは、それらの融合に関するもの[Okada 96, Mae 96]。など人間を観察するための画像処理アプリケーションは数限りない。本節で注目する画像処理は、ロボットと人間との対話行動を補助する処理である。

5.3.1 フレンドリーアーティファクトによる人間行動の観察

実際の対話行動を前提とした、人物の観察については、ペンギン型のフレンドリーアーティファクト[星野 98, Hoshino 99, Shirai 99]において実験を行なった。フレンドリーアーティファクトとは、日常空間において人間とロボットが共存し、親しみを感じながら共存できる事をコンセプトとしたロボットである。Figure 5.14 に示すペンギン型ロボットは、そのコンセプトに従って作成されたプロトタイプのロボットである。全長が560[mm]、体重が4.7[kg]と卓上で動くことを目的とした大きさ、重さになっている。全身は布で覆われており、さらにその内側には針金を編んだ殻を持っている。この構造はセンサスーツ[稲葉 98a]と呼ばれユーザとの触れ合いによるコミュニケーションのために使用される。また足先のパーツとして、ラバー素材を使うなど、柔らかな外観をつくり出している。

両眼のカメラを持っており、その結果はPCに入力され画像処理される。Figure 5.16 に示されるように、近距離ではデプスマップ情報[加賀美 99]を主に用い、遠距離ではオブティカルフローを用いることで人物像の発見・追跡を行なう[宮本 98]。

近距離においては、人の肌の色が多く見える可能性が高いため、肌色領域に着目して人と判別する。遠距離における移動物体の発見は、オブティカルフローベクトルのクラスタリングにより行なう。物体が静止している場合には情報は得られないので、これまでの履歴情報を用いて追跡を行なう。ある程度の時間、移動する領域が得られた場合に、その部分に移動する物体が存在するとみなし、注目する。遠距離における追跡の様子をFigure 5.17 に示す。近距離における人物領域の発見の様子をFigure 5.18 に示す。

服の画像領域の検出の後、その領域に含まれる色のスペクトルを算出する。この実験では簡単なために色のスペクトルがその人物が着ている服の配色であると仮定して、人物を認識する。

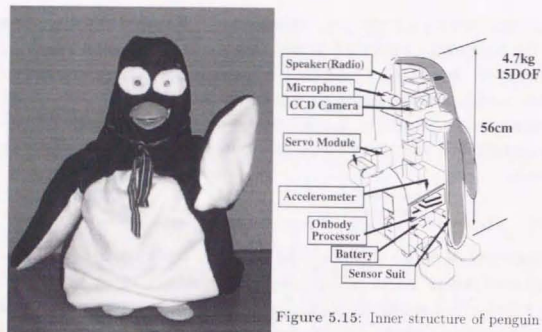


Figure 5.15: Inner structure of penguin type robot

Figure 5.14: Friendly Artifact: Penguin




Figure 5.16: Outline of vision process for finding and following human



Figure 5.17: Tracking with optical flow



Figure 5.18: Detecting clothes area (left:raw image, center:depth image, right:observing area)

5.4 対話に基づく人間の行動の把握

以上に述べた、部屋の名前の獲得、環境地図の獲得、人間の行動の観察の要素を統合し、日常生活における知識獲得の例として、誰が、いつ、どの部屋にいるかという知識を後天的に獲得する例について述べる。この知識を表現するために、Figure 5.19 のような Bayesian Network を用いて、部屋と人物と時刻の関係を表現、獲得する。

人物、部屋、時刻の関係は二通りの方法で観測される。ロボットが視覚を使って人間を観察する場合と、ユーザとの対話から知識を得る場合である。

前節の視覚による人間の観察では、ある部屋に入ってくる人々を観察し、いつ、誰が入ってきたのか、を管理していた。すなわちその場で起こった出来事を記録しておく意味合いが強い。このような記録を蓄えるシステムではユーザからの質問に対して、ロボットが実際に観察した事だけにしか反応する事ができない。エージェントロボットの例で言えば、ある人物を観察した事がなければ、「その人は今日はまだ見ていません」という応答ができない。

このような短期的な記憶だけを用いては、柔軟な対話とは言えない。その日に見た事がないとしても、毎日の観察の結果からいる部屋を推測する事は可能である。特に本研究が目標としているロボットの動作環境はオフィスや病院、家庭などで、このような環境では、人間が社会的に行動している以上、ある人物がある場所に定期的にいる、という状況が生まれて来る。

そこで本節では、短期的な情報ではなく、対話経験を用いて、誰がどの部屋にいるか、という長期的な情報、別の言葉で言えばある環境内での人間の習慣情報を獲得する手法について説明する。

5.4.1 Bayesian Network による環境情報の表現

ここでは、Table 5.4 のような確率変数が使われ、複数のユーザとの長時間の対話経験から、各ノード間の条件付き確率値を求めて行く。




Figure 5.19: Bayesian Network for environment knowledge management

Table 5.4: Random variables for room, person and time

ノード名	確率変数	意味
Room	{作業室, 会議室, ...}	部屋の名前
Person	{稲邑, 稲葉, 井上, ...}	人物の名前
Time	{朝, 昼, 夜, ...}	時刻の名前

Table 5.5: Command structure for question "Where is Mr.A?"

```

:target-node room
:evidence :node-name person :value A
:evidence :node-name time :value nil

```

視覚情報や、ユーザが発話する宣言的会話文から、人物、部屋名、時刻、を抽出し、得られた情報を経験データとしてまとめ、経験データベースに記録する。各ノードの条件付き確率は経験データベースから計算され、常に最新の確率値が Bayesian Network 部に送られる。すなわち、視覚情報が得られた時、およびユーザが宣言的発話を行なった後に、Bayesian Network は新しい確率値に更新される。

5.4.2 Bayesian Network による環境情報の推定

一方、ユーザが「Aさんは何処にいますか?」というような疑問文を発話した場合の挙動は、質問の対象となっている概念を発話文から抽出し、その概念に対応するノードに対して推論を行なう。この発話文から対象概念を抽出する方法については、第7章で詳しく述べる事にして、ここではその推論方法について述べる。

Bayesian Network は第3章でも述べたように、ネットワーク上部分的な観測値のみで推論が可能であり、全てのノードの観測値を必要としない。「Aさんは何処にいますか?」という疑問文は次のような表現に変換され、推論部に送られる。ここで、:evidence が示すのは現在得られている情報であり、人物に関しては人物名である「Aさん」が入力され、時刻に関しては質問の中に特に指定がないので、nil が指定されている。この状態での推論は、時刻ノードの情報を無視して、人物が何処にいるか、という推論を行なう事になる。逆に、時刻が指定されていた場合には、指定された時刻においてどの部屋にいるか、という推論を行なう事になる。

計算の目的となるのは、部屋ノード $Room$ の各状態に対する確信度 $BEL(Room)$ で、これは部屋ノード $Room$ の尤度および事前確率の積

$$BEL(Room) = \alpha \lambda(Room) \pi(Room) \quad (5.1)$$

で表現される。ここで α は正規化係数である。また、 $\lambda(Room)$ は対象となっている人物と、対象となっている時間、それぞれに関する尤度ベクトルの積

$$\lambda(Room) = \lambda_{Person}(Room) \lambda_{Time}(Room) \quad (5.2)$$

である。これらの尤度ベクトルはそれぞれ

$$\lambda_{Person}(Room) = CPT_{Person|Room} \cdot \lambda(Person) \quad (5.3)$$

$$\lambda_{Time}(Room) = CPT_{Time|Room} \cdot \lambda(Time) \quad (5.4)$$

で表される。 CPT は第2章で述べた通り、対話に基づいて蓄積された経験データを用いて、累積頻度度数から算出される。 $\lambda(Person)$ および $\lambda(Time)$ は観測された証拠データによって決定される変数で、証拠データが存在している場合は、その状態に対応する成分を1、その状態以外の成分を0とするベクトルを意味し、証拠データが存在していない場合はすべての成分が1のベクトルを意味する。すなわち、Table 5.5 の場合には

$$\lambda(Room) = (0, 0, 1, 0) \quad (5.5)$$

$$\lambda(Time) = (1, 1, 1) \quad (5.6)$$

などになる。計算の詳細については巻末の付録を参照されたい。

5.4.3 新しい状態の追加

第5.2.2節で述べた通り、ロボットは行動を開始する当初は環境内に存在する部屋に関する知識を持っておらず、環境内を自律的に走行しながら部屋に関する知識を増やしていく。そのため前節で述べたネットワーク構造を構築する際の部屋ノード ($Room$) の状態が逐次的に変更される事になる。第3章、第4章で使用していたノードは状態値が離散的なもので、実際に扱うデータは連続的なものであったため、新しい状態を付け加える場合には、連続値データと離散の状態値との間の対応関係を再構築する必要があった。

例として、新しい部屋を発見し、その部屋名を追加する場合だと、部屋の確率変数

$$Room = \{r_1, r_2, \dots, r_n\} \quad (5.7)$$

に、新しい状態 r_{n+1} を追加して

$$Room = \{r_1, r_2, \dots, r_n, r_{n+1}\} \quad (5.8)$$

とする。同様にノード間の関係を表現する CPT (条件付き確率テーブル) も

$$CPT_{Person|Room} = \begin{pmatrix} P(p_1|r_1) & P(p_2|r_1) & \dots & P(p_m|r_1) \\ P(p_1|r_2) & P(p_2|r_2) & \dots & P(p_m|r_2) \\ \vdots & \vdots & \ddots & \vdots \\ P(p_1|r_n) & P(p_2|r_n) & \dots & P(p_m|r_n) \end{pmatrix} \quad (5.9)$$

から、

$$CPT_{Person|Room} = \begin{pmatrix} P(p_1|r_1) & P(p_2|r_1) & \dots & P(p_m|r_1) \\ P(p_1|r_2) & P(p_2|r_2) & \dots & P(p_m|r_2) \\ \vdots & \vdots & \ddots & \vdots \\ P(p_1|r_n) & P(p_2|r_n) & \dots & P(p_m|r_n) \\ P(p_1|r_{n+1}) & P(p_2|r_{n+1}) & \dots & P(p_m|r_{n+1}) \end{pmatrix} \quad (5.10)$$

に変更する。

5.5 対話と自律行動に基づく環境知識の獲得実験

5.5.1 日常空間における人間活動の把握

まず、5.3.1節で説明したフレンドリアーティファクトにおける実験例について述べる。認識した結果はロボットがいた場所、時刻とともに、Figure 5.19 のネットワークに入力される。これにより、誰が何色の服を着ていて、いつ部屋に入って、いつ部屋から出ていったか、またどの部屋に行ったか、などの知識を獲得する。

Figure 5.20, Figure 5.22 に示す二人のユーザがエージェントロボットと交わした対話の様子を Table 5.6 に示す。

Table 5.6: An example dialogue on agent robot

ユーザA「私の名前はAです」
 ロボット「分かりました。Aさんですね。」
 ユーザA「Bさんは見ませんでしたか？」
 ロボット「Bさんは朝いきましたよ」
 ユーザA「伝言をお願いします。」
 ロボット「分かりました。伝言をお願いします」
 (ユーザが伝言を録音する)
 ユーザA「さようなら」
 (ユーザBが現れる)
 ロボット「こんにちは、あなたはBさんですね」
 ユーザB「Aさんは見なかった？」
 ロボット「さっきまでここにいましたよ」
 ユーザB「伝言はありますか？」
 ロボット「Aさんからの伝言があります」
 (伝言を再生する)



Figure 5.20: Outer image of User A

input images
(Right) (Left)

Depth Map


Face & body
detection

Figure 5.21: Inner image of User A



Figure 5.22: Outer image of User B

input images
(Right) (Left)

Depth Map

Face & body
detection

Figure 5.23: Inner image of User B

ロボットに対して発話行動を行なっているかどうかの判断は、顔の色を検出する事によって行なっている。デプスマップによる検出が成功した場合においても、顔画像の発見が行なわれていない場合には、人間が話しかけていると判断せずに観察を続ける。Figure 5.24 はそのような状況の一例として、ロボットの前を人間が通り過ぎた場合の処理内容を示している。入力画像には人間の胴体部分しか写っておらず、顔画像は検出されていない。よってこの場合にはロボットは人間に話しかける事はしない状態にある。



Outer Image



Depth Map



Input Image



Body Detection

Figure 5.24: Behavior against a passer-by

5.5.2 移動ロボットにおける荷物配達行動への応用

獲得された環境知識を移動ロボットに応用する例として、荷物の配達行動を行った。移動ロボットは配達をするべき目的の人の名前を聞き、その人がどの部屋にいるかを推論して移動行動を始める。目的の人物がいる部屋の知識がなかった場合には、ロボットのそばにいる人物に対して「その人はどの部屋にいますか？」などと質問を行う。一方、二つの部屋の確信度が同等の値となるような推論結果が得られる場合には、「その人は〇〇と××のどちらにいますか？」という質問を行う。

Figure 5.25, Figure 5.26, Figure 5.27 に実際の荷物配達タスクの様子を示す。また、その時に交わされた会話の内容を Table 5.7, Table 5.8, Table 5.9 に示す。Figure 5.26 では障害物回避行動を行っているが、この段階では部屋と人物の関係を表す Bayesian Network と、第3章で述べた障害物回避行動に関する Bayesian Network の双方を同時に使用している。ロボットシステムはこのように同時に複数の Bayesian Network を使用する事が可能であり、必要に応じて適宜使用するネットワークを選択する。

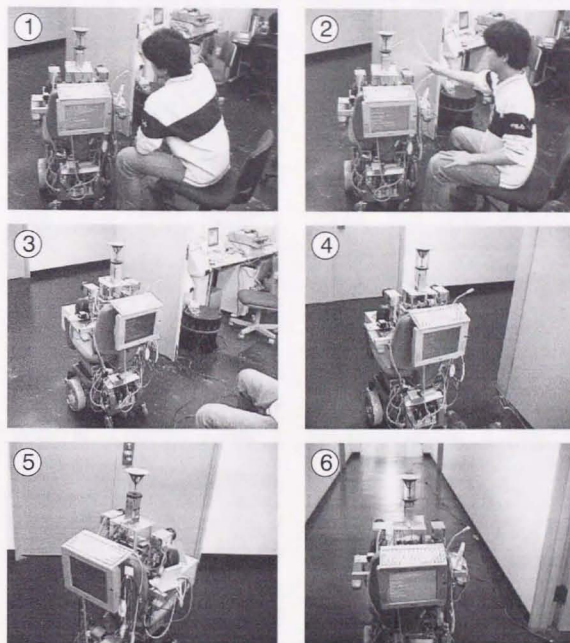


Figure 5.25: Delivery task for the mobile robot (1)

Table 5.7: Dialogue between the mobile robot and a user

ユーザ 「香山君の所まで配達をお願いします」 写真 (1)
 ロボット 「分かりました。荷物を置いて下さい」 写真 (2)
 ロボット 「香山さんのいる 709 に行きます」 写真 (3)




Figure 5.26: Delivery task for the mobile robot (2)

Table 5.8: Dialogue between the mobile robot and a walking user

- ロボット「障害物を発見しました」写真(8)
- ロボット「障害物を回避します」写真(9)
- ロボット「障害物を回避し終わりました」写真(11)




Figure 5.27: Delivery task for the mobile robot (3)

Table 5.9: Dialogue between the mobile robot and a target user

- ロボット「ドアを開けて下さい」写真(14)
- ロボット「709に入ります」写真(15)
- ロボット「香山さんに届けものがあります」写真(17)
- ユーザ「どうもありがとうございます」写真(18)

5.6 本章のまとめ

本章では、ロボットのための行動知能の一部として、オフィスや家庭などの日常空間でユーザと共に活動する事を前提とした、環境知識の表現方法および獲得方法について述べた。環境知識は主に地図情報と人間の活動情報の二つから構成される。

前者の地図情報に関しては、ビューシーケンスによる地図の表現手法を述べ、移動ロボットにおける自律的な地図の獲得、対話に基づく部屋の名前の獲得、などの環境知識の獲得行動を実現した。

後者の人間の活動情報に関しては、まず、視覚情報による人間像の観察処理について述べ、次に Bayesian Network による人物と場所と時刻に関する知識表現を提案した。固定的な表現では実環境の変動を表現する事が難しかったが、本手法の統計的な知識表現では、確率を用いて環境の情報を表現する事が可能であり、完全に正しい情報ではなく、実際の行動に十分適用可能な程度の環境知識を扱う事が可能である事を確かめた。

また、ユーザとの対話の結果を経験として蓄積し、Bayesian Network を学習させる事により、全く無知の状態から徐々に環境知識を獲得する手法について述べた。このような対話に基づく環境知識の獲得手法は、あらかじめ使用される環境についての知識を埋め込む事のできないパーソナルロボットにとって必要不可欠な機能であり、実験を通じてその有効性を示した。

第6章

対象の局在性に基づく適切な対話の生成

6.1 はじめに

発話行為は、speech act と表現されるように、行為としての一部である。単なるメッセージを表示するのと同じように、音声を合成して発話するだけでは、発話行為とは大きく異なるものとなる。第3章では、パーソナルロボットの行動を生成する場合、単に外界のセンサ情報だけを用いて行動する事は不適切であり、ロボットを使用するユーザがどのような希望を持っているのか、を考えて行動することが重要である事を述べた。

発話という行動はこのような要素が顕著に影響する行動である。外界の環境情報を単に収集獲得し、その結果を発話しているだけではパターンから言語への情報変換を行なっているに過ぎない。ユーザとの円滑なコミュニケーションを成立させるためには、ロボットは自分自身と環境との相互関係だけでなく、ユーザと環境との相互関係がどのようになっているかを把握し、またロボットとユーザとの関係を考慮した上で発話を行なう必要がある。

本章では、このような問題背景を踏まえて、ユーザがロボットに対して曖昧な指示を出した場合に、ロボットが行なうべき適切な対応行動を発話行為を介して決定する方法を提案する。そして、これを実現するアプローチとして対象の局在性という概念を導入する。対象の局在性とは、対話の文脈の中で言葉や行動を介して参照されている対象が、他の対象と混同されずに唯一つのものとなっているかどうかを評価する基準である。この局在性が満たされるように発話や行動を制御する事によって、文脈に存在する曖昧な要素を取り除き、自然な対話を成立させる手法について述べる。

具体的に、視覚処理による対象物の参照同定行動に焦点を絞り、対象物を同定しにくい状況において、ユーザの曖昧な指示に対応する事を目標とする。このような曖昧な指示を取り扱うAIの研究分野は広いが、そのほとんどはシステムが過去の文脈を用いたり、背景知識を活用して曖昧性を解消させている。しかしながら物理世界で活動するロボットでは、そのような手法だけではなく、実際の環境に働きかける行動を取る事が重要なポイントとなる。そこで、(1) 言語的発話による曖昧性の解消、(2) 行動と発話を統合した曖昧性の解消、(3) ユーザへの提案を行なう事による曖昧性の解消、の3種類の対話制御の例を通じて、本手法の有効性を示す。

6.2 対象の局在性に基づく発話生成

6.2.1 対話生成の適切さの評価基準

発話行為に対する考察を行なった研究としては、Grice の協働的会話の原則 (cooperative principle) [Grice 75] が有名である。彼はこの理論の中で、対話が行なわれる際に話し手と聞き手は暗黙のうちに相手が協力的に対話を行なう事を期待している、とした。この協力を期待することが意思疎通のための大原則となっているという主張である。この協力的な対話によって生成される情報には、次の公準が成立している。

- 「量の公準」 必要十分なだけの情報を発話する
- 「質の公準」 真であると思うことを発話する
- 「関係の公準」 会話の内容に関係のあることを発話する
- 「様態の公準」 曖昧な分を避け、はっきりと意味が分かるように発話する

の4種類の公準が定義されている。これらのそれぞれの公準の必要性は、会話が行なわれる状況に依存するが、通常のロボットと人間との対話を考えた時には、これら全ての公準は必要としない事はない。

そもそもこの公準はロボットや機械との対話などとは関係なく、人間同士の会話プロトコルを解析した際に、必要となってくる要素を整理したものであり、「質の公準」「関係の公準」については通常のシステムにおいては問題とはならないであろう。

このため、本節では、特に「量の公準」「様態の公準」に特に注目し、対話している状況に合わせて、必要十分な量の対話、曖昧な表現の回避などを実現するための方法について述べる。

ロボットと人間との対話を考えた場合、人間同士での対話に比べて性質は大きく異なる。その対話の性質はおおよそ次のような種類に分類されるであろう。

人間からロボットへの発話

命令 「物を取る」「荷物を配達する」などの動作を指示する。

質問 さっきまで机の上にあった物をどこに運んだか？など、ロボットが持っている知識について尋ねる。

教示 ロボットが知識を持っていない場合に、知識を教える

ロボットから人間への発話

確認 人間からの指示や、教示に対して、その発話内容を受理した事を報告する。

質問 自分がある行動を実行しようとした際に、知識の不足によって行動が実行できない場合に不足を補うために質問する。

提案 人間の指示に対してより良いプランがあった場合に、ロボット側の判断で提案を行なう

報告 行動が終了した場合や、逆に失敗した時などに、現在の状況について人間に報告する。

ここに挙げた例はほんの一例で、ロボットが活動する条件によって、その種類は増加して行く。例えば会話が成立している事を暗黙のうちに相手に伝えるための、「あいつち」[Ward 98] や「うなずき」[Hirasawa 98] などもあるだろう。また、明確な目的をもったパーソナルロボットではなく、対話する事自体が目的となっているエンターテインメント性が高いシステムでは、いわゆる「会話の間」を埋めるために、特に意味がない発話を行なう事があるかもしれない。しかし、本章での議論は、このような発話は扱わず、上記に挙げた種類の発話に注目する。

ここで上に挙げたいくつかの種類の発話をさらに分解すると、最終的に「報告」と「質問」という二つの要素になる。例えば、「命令」は人間側の依頼の意思を「報告」する事であるし、「教示」は、ロボットが保有する知識に欠けている部分がある事を人間が推測し、その欠けている知識を「報告」する事になる。

この報告すべき事柄の選択、および質問表現の選択を行う際に、「量の公準」と「様態の公準」を考慮する必要がある、という事になる。

6.2.2 対象の局在性に基づく発話

さて、具体的にどのように量の公準、様態の公準を満たす対話を生成するのかについて、さらに考察を行なう。

まず、考察を行なう際の具体的な状況として、「机の上にある箱を取ってこれ」という指示をロボットに対して与えた場合を考える。机の上には2個の箱があった場合、ロボットはどちらの箱を取れば良いのかが分からない。すなわち、この人間の発話には、「様態の公準」の観点から情報が不足している。ここで曖昧さを除去するためには、机の上にある二つの箱のうち、どちらか一方を特定すれば良い。そのためには「右の箱を取って」とか、「赤い色の箱を取って」という具合に、他の箱と区別できる表現を使用すればよい。しかしながら、この区別を行なうための表現は、二つの箱の置かれている状況によって、大きく左右されてしまう。例

えば二つの箱が上下に重ねておいてある場合には、「右の箱」などという左右の概念は使用できない。また、二つとも同じ色の箱の場合には、色に関する表現は使用できない。

この問題は、柴田が提案している局在性規準 [柴田 95b] に基づく注視点の決定問題や、菅沼が提案している対象の相対関係による属性の重要度 [菅沼 92]、Appelt が指摘している参照物体の活性化 [Appelt 85] などの問題と非常に関係が深い。Figure 6.1 は柴田が提案した局在性規準に基づいて、人間が指定した領域を自動的に抽出するための、視覚処理パラメータの決定のプロセスをモデル化したものである。ロボットは人間が指定した領域を局在化するために、複数の並列に存在している視覚特徴抽出モジュールのパラメータを調整し、それらの論理和が人間の指定領域と同等になるように、パラメータを最適化する。局在性が満たされた場合、各視覚特徴抽出モジュールが持つパラメータは、人間の注視戦略を表現する事となる。




Figure 6.1: A localization model proposed by Shibata (quoted from [柴田 95b])

この考え方を、机の上の箱を取る問題に当てはめてみる。箱が複数ある場合、その箱を特定するために、箱が持っている大きさや色などの特性を並列に並べる。これは先の特徴抽出モジュールに対応する。そしてそれらの特性の値、すなわち具体的な大きさの値や、色の名前などをパラメータと対応させる。

複数の箱の中から目的の箱を特定するためには、その目的となっている箱が局在化するようなパラメータを選ばば良い。画像処理の領域において、パラメータが視覚探索戦略を表現したように、この場合は、パラメータが発話表現を意味する事となる。Figure 6.2 では「右の赤い」という表現が人間が指示した物体を局在化している。これにより曖昧性を取り除くための発話戦略の第一段階が終了した事になる。




Figure 6.2: Application of localization model to object designation tasks

6.2.3 必要十分な量の発話生成

しかしながら、このモデルをそのまま適用しただけでは、先に挙げた「量の公準」を満たす事はできない。なぜならば、もし Figure 6.2 の表現モジュールの数が膨大だった場合に、

意味もない冗長な発話が生成されてしまうからである。例えば色、大きさ、配置、に加えて、物体の名称、重さ、材質、その物体を所有している人物など、物体が持っている特性は無限にあると言っても過言ではない。「その右の赤い、大きくて光っていて、重くて、木でできている、私の箱を取って」などという会話が日常生活で現れないのと同じように、量の公準を満たすように、使用する表現モジュールの数を抑える事も重要になって来る。

すなわち、局在性を満たすのに必要十分な表現モジュールを選択する事になる。Figure 6.2 では、色表現モジュールと、配置表現モジュールは重複しており、どちらか一方の表現を行なうだけで、局在性を満たす事が可能である。この場合は「右の赤い箱を取って」ではなく、「右の箱を取って」あるいは、「赤い箱を取って」だけで十分なのである。





				
Color blue	○	○	×	○
Size big	×	○	○	○
Name box	○	○	○	×
blue big box		○		

Figure 6.3: Sufficient condition for target reference

中野らは発話内容を生成する戦略として、聞き手の理解度に注目し、既に対話の中で用いられた表現を再び使うかどうか、という判断基準を提案し、発話における情報量の調節を行っている [中野 95b]。彼女らの研究では、十分知識を持っている専門家が、初心者に対して教示を行なうという問題領域での対話を扱っており、ロボットがユーザに対して発話を行なう状況とは異なる。ロボットの発話の場合、ユーザになるべく負荷をかけずに理解可能となる発話が要求され、「聞き手の理解度」というパラメータよりも、「理解に必要な最小限の発話」を可能とするパラメータが必要となる。対象の局在性は「ユーザが理解をするのに十分である」事を保証する判断基準として用いられることとなる。

6.3 曖昧性解消のための発話生成

6.3.1 対象物体指示における曖昧性解消行動

例えば、いくつか複数の箱があるような状況において、「その箱を取って」という発話を行なったとすると、どの箱を参照しているのが決定できず、曖昧性の解消ができない。もし、このような文が発話される前に、「一番左の箱には、この間お菓子が入っていたんだ」という発話がなされていれば、「その箱」とは間違いなく左の箱を意味する。このような処理は自然言語処理の分野における、文脈の追従によって実現される事が多い。しかしながら、会話が開始されてしばらく時間が経過した状況での発話だった場合は、一意にどの箱を参照しているのかを決定する事は困難である。

日常生活で人間がこのような状況に遭遇した場合、会話の状況だけでなく、その場の状況も考慮して曖昧性を解消しようと試みる。たとえば「その」という言葉は、会話の時系列的な参照だけでなく、話し手と聞き手と対象物の物理的配置関係も表現する事もある。また、タバコを吸う習慣のある人が「その箱を取って」と発話すれば、それはマッチ箱やタバコを意味している可能性が高い。このように、自然言語処理のレベルでの曖昧性の解消だけでなく、物理的な外界情報を活用して曖昧性を解消するアプローチは、ロボットと人間との対話にとって、非常に重要な要素となって来る。

本節では、物理的に実在する対象物の参照行動を例として取り上げ、曖昧な指示による不確実な状況へ対応するための手法について述べる。そして、その不確実な状況に対応するための手段として、Bayesian Network を用いて対象の局在性を評価する手法を提案し、局在性が満たされるようにロボットが適切な質問や確認行動を行う事を目的とする。

6.3.2 Bayesian Network を用いた対象の同定確信度の算出

まず、タスク達成の確信度を定義する前段階として、ユーザの指示した物体と、ロボットが目ざしている物体が同一のものであるかどうかを判定するパラメータ「同定確信度」を導入する。

同定確信度を求めるには、Figure 6.4 のような Bayesian Network を用いる。各ノードは Table 6.1 のように、視覚処理に用いられる視覚特徴に対応しており、ユーザの指示物体とロボットの注目している物体の間の、視覚特徴パラメータの違いを評価する。双方の視覚特徴パラメータの差は Difference ノードに入力され、親ノードの方向に向かって推論を行ない、Target ノードに対する確信度を、同定確信度として利用する。

Figure 6.4 は主に、ユーザが視覚特徴に関する表現を用いた指示を出した場合に用いられ




Figure 6.4: Bayesian Network for visual parameter inference




Figure 6.5: Bayesian Network for target distinction

Table 6.1: Nodes of Bayesian Network for object reference

ノード名	ノードの意味	確率変数
User's Designation of Color	ユーザの使用した色表現	Red, Blue, Yellow, Green
Target's Color Parameter	対象物体の色パラメータ	(Hue, Sat)
User's Designation of Depth	ユーザの使用した距離表現	This, It, That
Target's Depth Parameter	対象物体の距離パラメータ	(Depth)
User's Designation of Size	大きさの表現	Small, Middle, Large
Target's Size Parameter	対象物体のサイズパラメータ	(Size)
User's Designation of Position	左右位置の表現	Right, Center, Left
Target's Position Parameter	対象物体の左右位置パラメータ	(X)

Table 6.2: Nodes of Bayesian Network for calculating certainty of factor

ノード名	ノードの意味	確率変数
Target	注目している物体は指示された物体である	Yes, No
Target Color	注目している物体の色は指示された色である	Yes, No
Target Size	注目している物体の大きさは指示された大きさである	Yes, No
Target Depth	注目している物体の位置 (奥行き方向) は指示された位置 (奥行き方向) である	Yes, No
Target Position	注目している物体の位置 (左右方向) は指示された位置 (左右方向) である	Yes, No
Difference of Color	注目している物体の色と指示された色の違い	(Hue, Sat)
Difference of Size	注目している物体の大きさと指示された大きさの違い	Size
Difference of Depth	注目している物体の位置 (奥行き方向) と指示された位置 (奥行き方向) の違い	Depth
Difference of Position	注目している物体の位置 (左右方向) と指示された位置 (左右方向) の違い	Position

る。視覚特徴に関する表現というのは、具体的に「赤い」や、「右の方の」や、「手前の」などの表現である。これらの表現は「視覚特徴の表現ノード」に入力され、Bayesian Networkの推論処理により、実際の視覚特徴パラメータに変換される。この処理は第4章で述べた手法と同一であり、使用されているネットワーク構造も第4章で登場したネットワーク構造を用いて構成されている。

Figure 6.5のネットワークは主に、視覚処理の結果抽出された領域がユーザの指定している物体であるかどうかを判定するために使用される。領域分割の結果抽出された物体の色、サイズ、奥行きなどの視覚特徴パラメータに対して、前段階で決定された「ユーザの指定した物体のパラメータ」との差を計算する。計算されたパラメータの差はFigure 6.5の差分ノードに入力され、ターゲットであるかどうかを表現する二値の確率変数を持った一番上のノードに対する推論が行なわれる。この結果によってロボットは「今参照している物体がユーザの指定している物体かどうか」に関する判定を確率値による表現で求める事ができる。

この確率値は、第3章で述べた確信度と同じように扱う事が可能である。ロボットは視野画像内のすべての物体に対してこの確信度を求め、最も確信度の高い物体をユーザの指定した物体として認識する。この確信度の計算アルゴリズムをTable 6.3に示す。確信度が低い場合や、複数の物体に対して似たような確信度が算出された場合、第3章で述べたようにユーザに対する質問や確認などの対話行動を開始する。

Table 6.3: Algorithm for calculating certain factor of target

```

global variables: Bayesian-Network BN_V /* 視覚特徴パラメータと言語表現の関係 */
global variables: Bayesian-Network BN_CF /* 対象の局在性ベクトルの算出用 */
global variables: Camera-Image Image
global variables: Probability CF

function Calculate-Target-CF(cond) returns a vector of Certainty-Factor
{
  local variables: Object-Pointer t /* 対象物を示す構造体 */
  local variables: Visual-Parameter vp /* 対象物の視覚特徴量を示す変数 */

  Exec-3D-Segmentation(Image)
  for each target t in Image {
    for each visual-condition vc in cond do {
      Input-Evidence-into-Bayesian-Network(BN_V, Node(User's Designation), vc)
      vp ← Exec-Inference(BN_V, Node(Visual-Parameter))
      Input-Evidence-into-Bayesian-Network(BN_CF, Node(Difference-of-Parameter),
                                           vp - t → vc)
    }
    CF[t] ← Exec-Inference(BN_CF, Node(Target))
  }
  return CF
}

```

6.3.3 対象の局在性に基づく対話制御

次に、タスク達成の可能性を評価するパラメータとして、対象の局在性を導入する。ここで対象の局在性を定義するが、この際前節で述べた「同定確信度」を用いる。

ロボットの視界に入っている n 個の対象に対するそれぞれの同定確信度を CF_i とする。局在性が成立するためには、同定確信度が高い対象が唯一存在する必要がある。ここで、

$$L = \frac{\max(CF)}{\text{second_max}(CF)} \quad (6.1)$$

というパラメータを導入し、以下の式

$$L > 1.5 \quad (6.2)$$

をもって、局在性の成立を判断する基準とする。ここで $\max(CF)$ は存在する対象内で最大の同定確信度、 $\text{second_max}(CF)$ は2番目に大きい同定確信度の値である。つまり、最大の同定確信度が、次点の確信度の1.5倍以上あれば、それが突出して高い同定確信度を持っていると判断する事にする。

ユーザがきめ細かく指示を行い、曖昧性がほとんど存在しない場合には、ユーザが指示する対象物体は唯一つ決定するはずで、局在性基準も満たされる。逆にユーザが曖昧な指示を行い、不完全な情報が多い場合には、対象が唯一つのものとして区別できないので、局在性基準は満たされない事になる。

ユーザが曖昧な指示を出した場合、ロボットは何らかの方法で曖昧になってしまっている情報を補う必要がある。本節の対象物を同定する行動の場合は、ロボットが注目している物体と、ユーザが指示している物体が同一のものであると判断するための情報、すなわち言語による指示に曖昧性がある。そこでロボットは、局在性の評価基準 L がなるべく高くなるような視覚特徴の言語表現の組み合わせを算出する。その表現とユーザの指示表現との差分を取り、その差分の表現を用いてユーザに質問あるいは確認を行えば、ユーザが指示し忘れた表現をロボットが補う形となり、有効な対話が生成される事となる。

Table 6.4 に対話を制御するアルゴリズムの一部を示す。また、Figure 6.6 に、対話制御アルゴリズムの全体をフローチャートで表現した図を示す。

6.3.4 仮想環境における発話生成実験

上記の戦略に基づいて、状況に応じた適切な発話が生成される事を確認するために、仮想環境のロボットシステムにおいて、ユーザとの対話を行なった。

視覚処理部には、Sensor Data Pool と呼ばれるロボットのためのセンサ情報管理システム[香山 99]を使用している。この視覚処理部では視野全体の画像を領域分割し、それぞれ

Table 6.4: Algorithm for dissolution of ambiguity in target reference task

```

function Generate-Utterance
{
  local variables: double      CF[MAX] /* 各対象物に対する確信度 */
                  int          Ncond /* 使用する条件の数 */
                  Visual-Parameter cond /* ユーザの発話に含まれる条件 */

  CF ← Calculate-Target-CF(cond)
  if( Check-Localization(CF)=True ) then {
    Speak-to-user("はい、その物体を取ります")
    exit
  }
  target ← MaxNo(CF)
  for( Ncond=0; Ncond<MAXNODE; Ncond++, Ncond≠cond ) {
    for each s in Node(n) {
      CF ← Calculate-Target-CF( cond ∩ s )
      if( Check-Localization(CF)=True ) then goto :success
    }
  }
  :fail
  Speak-to-user("そのような物体はありません")
  exit

  :success
  Speak-to-user("それは" + s + "の事ですか? ")
  exit
}

```

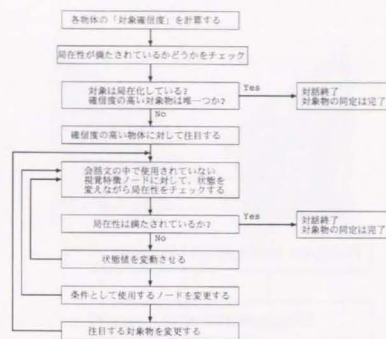


Figure 6.6: Flowchart for dissolution of ambiguity in target reference task

の領域を物体対象とみなして、色、大きさ、3次元での絶対位置、幅、高さ、などの視覚特徴パラメータを随時更新して管理する働きを持つ。また、仮想環境、実環境を問わず使用できるモジュール構造となっており、後に説明する実機ロボットのシステムにおいても使用されている。全体的なシステム構成は Figure 6.7 のようになっている。

本実験では、ユーザから物体の参照行動が指示された場合に、対話マネージャを使用するものとする。処理の流れは以下の通りである。

1. 行動知能管理部がユーザの発話を自然言語処理し、対話マネージャに送信する。
2. 対話マネージャが対象物体を探索し、局在性が満たされているかどうかを判定する。
3. 局在性が満たされていない場合には、ユーザが参照していると思われる対象物体に着目する。
4. 着目した物体がユーザの着目している物体と同一であるかどうかを対話を介して確認する。
5. ユーザの指示した行動を実行する。
6. 対話の結果を経験として蓄える。

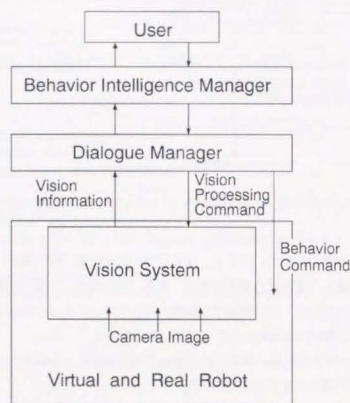


Figure 6.7: Dialogue managing system on a virtual robot system




Figure 6.8: An example scene 1

まず、第1段階の自然言語処理については第7章で詳しく述べる。第2段階の局在性については、6.3.2節で述べた「対象同定の確信度」と6.3.3節で述べた「タスク達成の確信度」を用いる。第3段階の着目する物体の選択については、局在性を評価した際の確信度によって決定する。第4段階の対話生成については、6.2.3節で述べた、必要十分な量の発話で、ユーザとの間に共通の対象認識を成立させる手法を用いる。

まずユーザがFigure 6.8のような状況で、「赤い箱を取って」と指示を行なう。しかしながら、双方の箱とも赤い色をしているので、この指示だけでは対象を正しく局在化する事ができない。そこで対話マネージャーは「赤い箱」の候補となる対象を順番に選択し、対象が局在化するような表現でその対象を説明する。この場合、双方とも同じ確信度であるので、対話マネージャーはランダムに対象を絞り、その対象がユーザの指示している対象と同一のものであるかどうか、を発話を通じて確認する。この実験例の場合、右の箱(対象B)に注目した。

この時点での二つの対象の視覚特徴パラメータはTable 6.5の通りであった。ここで、Table 6.4のアルゴリズムにそって、まず一つの視覚特徴を使って発話文を生成し、対象の同定確信度を求める。それぞれの視覚特徴表現と、対象物の同定確信度の関係はTable 6.6のようになった。Table 6.5を見て分かるように、この二つの対象の「奥行き」と「色」のパラメータには大きな違いがなく¹、面積が大きく異なっている。このため、「近い」という表現

¹色相の値が大きく異なっているように見えるが、色相は色相環の角度に相当しており、0と64は同一の値である。




Figure 6.9: An example scene 2

や、「赤い」という表現を用いただけでは、二つの対象の同定確信度が等しい値(91)となり、対象を局在化させる事ができていない。しかしながら「大きい」という表現を用いる事により同定確信度は84と43という組合せになり、 $L = 1.95$ を示しているため式(6.2)を満たす。これにより対象Bが対象Aに比べてユーザの指定した対象により近い、という判断を下す事が可能になり、「それは大きい方ですか?」という発話文を生成することとなる。

Figure 6.9のような、もう一つの状況2においても発話生成実験を行なった。状況1に比べて赤い箱Cが増えており、さらに対象の同定が困難な状況になっている。この際の各対象の視覚特徴パラメータはTable 6.7の通りであった。

この場合に対象Bを局在化させるための条件は以下のTable 6.8の通りとなる。

奥行きと、色情報を用いた場合は、三つの対象に対する同定確信度が同値であり、対象を局在化する事ができていない。また、「ちゅうくらいの大きさ」という面積に関する表現を用いた場合にも、対象Bの確信度が76、対象Cの確信度が89、 $L = 1.17$ となり、これも局在化する事ができていない。唯一局在化可能であるのは「右」という左右の位置に関する表現を行なった場合で、この際に確信度が12,88,12という組合せになっており、 $L = 7.3$ を示している。これは式(6.2)を満たしており、この時点で「右の方ですか?」と発話する。

Table 6.5: Visual feature parameters on scene 1

対象	X座標	Y座標	視差	面積	色相	彩度
A	68	79	72	2759	63	74
B	195	106	64	5579	3	90

Table 6.6: Certainty factor of target identity for each visual feature expression

使用する視覚特徴	奥行き(近い)	面積(大きい)	色(赤)
対象A	91	43	91
対象B	91	84	91
L	1.00	1.95	1.00

Table 6.7: Visual feature parameters on scene 2

対象	X座標	Y座標	視差	大きさ	色相	彩度
A	68	79	72	2759	63	74
B	195	106	64	5579	3	90
C	75	148	63	6607	64	77

Table 6.8: Certainty factor of target B for each visual feature expression

視覚特徴	奥行き(近い)	面積(大きい)	色(赤)	左右の位置(右)
対象A	58	15	85	12
対象B	58	76	85	88
対象C	58	89	85	12
L	1.00	1.17	1.00	7.30

一方、システムが物体Aに注目していた場合、確信度は次のTable 6.9のようになる。つまり、一つの視覚特徴パラメータの表現を使っただけでは局在化できていない事がわかる。その場合は次の段階として、一つづつ使用する視覚特徴表現を増やして行く。2つの視覚特徴表現使った場合の確信度はTable 6.10のようになった。

Table 6.9: Certainty factor of target A (using one visual feature)

視覚特徴	奥行き (近い)	面積 (中くらい)	色 (赤)	左右の位置 (左)
対象 A	58	89	85	88
対象 B	58	76	85	12
対象 C	58	17	85	88
L	1.00	1.17	1.00	1.00

Table 6.10: Certainty factor of target A (using two visual features)

色 (赤)	○	○	○			
奥行き (近い)	○			○	○	
面積 (中くらい)		○		○		○
左右の位置 (左)			○		○	○
対象 A	89	97	97	91	91	98
対象 B	89	95	44	81	16	30
対象 C	89	54	97	22	91	60
L	1.00	1.02	1.00	1.12	1.00	1.63

ここで、「中くらいの大きさ」という面積に関する表現と、「左」という左右の位置に関する表現を同時に使用した場合に限り、 $L = 1.63$ と局在性を満たす事になるので、ロボットは「それは左の、中くらいの大きさのですか？」と質問を生成する事になる。

同様に、対象Cを局在化させる場合には次のTable 6.11の通りになる。この場合には、「それは左の大きいのですか？」と質問を生成する事になる。

これらいずれの場合にも、人間同士で会話を行う場合に自然に発話するようなせりふを生成する事ができており、対象の局在性に基づく発話の生成手法が有効である事が確認された。

Table 6.11: Certainty factor of target C

色 (赤)	○				○	○	○			
奥行き (近い)		○			○			○	○	
面積 (大きい)			○			○		○		○
左右の位置 (左)				○			○		○	○
対象 A	85	58	15	88	89	52	97	20	91	58
対象 B	85	58	76	12	89	95	44	81	16	30
対象 C	85	58	89	88	89	97	97	91	91	98
L	1.00	1.00	1.17	1.00	1.00	1.02	1.00	1.12	1.00	1.69

6.4 発話行為と実世界への行動を伴う曖昧性の解消

前節までに述べてきた手法は、言葉の発話だけによって曖昧性を解消させるための手法であった。しかし実際の物理世界で行動するロボットにおいて、発話のみによって対象を同定する事は必ずしも適切な行動であるとは言えない。人間同士の会話でも「それを取って」という発話を行なう場合には、対象を指し示しながら発話する事は頻繁に行なわれる。すなわち、発話だけでは対象の同定が困難な場合には、積極的に物理的な行動を伴う対話を制御する事が望まれる。

本節では、実際の物理環境で動作するヒューマノイド型のロボットで、前節で述べた対象物の同定行動を行なわせる。そして発話行為だけでは対象物の同定が困難な状況において、指さし行動と発話行為の双方を活用して曖昧性の解消を行なう手法について述べる。

6.4.1 発話行為と物理行動の統合

まずここで、発話による参照物の同定が困難な状況に陥る原因について、整理する。

登録されている語彙が不足している場合

前節の例では、同じ色、同じ形、同じ大きさ、のように視覚特徴パラメータが似通っている物体が複数あった場合、特定の参照物体を同定させるために、候補に準がっている複数の物体の中で異なる視覚特徴パラメータを探しだし、その視覚特徴に対応した発話を生成していた。全く同じ視覚特徴パラメータを持つ物体でも、左右に並べて置いてあったり、上下に重ねて置いてあったりするので、双方の配置関係から「右のボール」「下の箱」などと同定する事が可能であった。しかしながら、これは対象を局在化するために必要な視覚特徴の種類をロボットが把握していた場合にのみ、有効となる手法である。今の例で言えば、左右の概念をまだ持ち合わせていないロボットにおいては、全く同じ物体が左右に並べて置いてある場合、局在化するための発話を生成する事ができない。

本論文におけるロボットとの対話の役割は、不完全な行動知能しか持ち合わせていない場合には、その行動知能を段階的に形成する事である。そのため、不完全な行動知能のために、語彙の不足から候補対象の物体を局在化させる事ができないシチュエーションは容易に想像できる。このような場合には、言葉による発話だけでは対象の局在化問題を解決できないので、実際に指さし行動などを介して問題解決を図る必要が生じる。

参照物を同定するのに必要な言語情報が膨大になる場合

言葉によって、対象物を同定することができたととしても、日常生活では到底使用しな

ような表現を必要とする可能性がある。6.2.3節で説明したように、物体が持っている視覚特徴パラメータは無数に存在し、ある状況においては、膨大な量の視覚特徴パラメータを指示しなければ対象物を同定する事ができない場合がある。例えば、Figure 6.10のような状況で、図中矢印の物体を言葉を用いて参照したい場合、「手前の方の、やや左の、白くて、光っていて、小さいボール」というように、かなり複雑な表現を用いなければ対象を局在化する事ができない。このような場合には、Figure 6.10で実際に矢印で示しているように、明示的に対象を局在化できるように環境にアクティブに働きかけられるのが最も効率の良い方法である。




Figure 6.10: A situation where a target is hard to be localized

以上に述べたように、状況に応じて、発話だけでなく実際の環境に直接働きかけながら対話を継続する事が重要である。また逆に、以上に述べたような要因をチェックする事によって、発話では解決できない状況を認識し、実際の行動を実行する判断を下す事ができる。

6.4.2 上半身ヒューマノイド型ロボット

対象物の同定実験に使用するヒューマノイド型ロボット:H4のシステム構成をTable 6.12に、全体図をFigure 6.11に、自由度配置図をFigure 6.12に示す。

このロボットも、第3章で述べた移動ロボット:Hyper Mouseと同様に、PC/AT互換機をベースに構築されたハイパーマシンの一つである。Figure 6.12のように、車輪で移動を行ない、上半身でヒューマノイドの動作を行なう構成となっており、頭部4自由度、片腕6自由度、腰3自由度、車輪2自由度の合計21自由度を持つ[加賀美 98, Kagami 99]。

Table 6.12: Specification of humanoid robot system

ヒューマノイドロボットシステムの仕様	
PC/AT 互換機	Pentium MMX 266MHz + Memory(128MB)
視覚処理システム	富士通 カラー-trackingビジョン TRV-CPW5 + 日立 汎用画像処理ボード IP5000
ビデオカメラ	ステレオ視覚 (SONY EVI-370 + 広角レンズ) × 2
制御システム	富士通 ロボット用インターフェースボード RIF-01 × 2 + Titech Robot Driver × 7
頭部	ステレオカメラ用バンデルト (3 自由度) + 首 (1 自由度)
腕	上腕 4 自由度 + 前腕 2 自由度
腰	3 自由度
車輪	PWS(Power Wheeled Steering) 式 2 自由度




Figure 6.11: Humanoid Robot H4

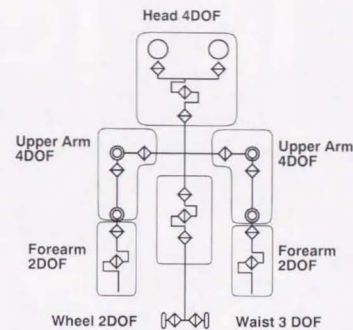


Figure 6.12: Degree of freedom of the H4

6.4.3 実環境における対象物の同定実験

まず、基本的な実験として、ロボットが注目している対象物を言語によって説明しながら、指さし行動を同時に行わせた。処理の大きな流れは以下の通りである。

1. ユーザが「その箱を取って」と発話する
2. 「箱」をキーにして探索を行なう
3. 箱が複数存在しているので、過去の経験から箱の色や大きさなどを推測する
4. 最も可能性の高い箱を選び、ユーザに「これですか？」と指をさしながら確認を行なう

対象物の3次元位置は、視覚処理部によって算出される。ロボットはインバースキネマティクスを解き、指をさし出す位置を決定する。この場合のインタラクションの例を Table 6.13 に、実験風景を Figure 6.13 に示す。



Figure 6.13: Pointing behavior based on uniqueness criterion

Table 6.13: Example of interaction

ユーザ 「その箱を取って」
 ロボット 「それはこの右の箱の事ですか？」
 ユーザ 「いいえ違いますよ」
 ロボット 「では、この左の箱の事ですか？」
 ユーザ 「はい、そうです」
 ロボット 「分かりました。これを取ります」

6.4.4 使用可能な言語表現が限定されている場合の対象物同定実験

この実験では、左右に関する表現をロボットにインプリメントしていない状況を想定する。先の6.3節の例ではロボットは物体の色、大きさ、奥行き、左右の位置の4種類の表現を使って発話を生成していたが、ここでは3種類しか使う事ができない状況である。このような状況でFigure 6.14に示すような環境において、ユーザが「その箱を取って」と指示した場合の発話生成実験を行った。この状況で視覚処理部が算出した視覚特徴パラメータをTable 6.14に示す。

まず、ユーザが「その箱を取って」と発話し、ロボットは同定確信度を各物体に対して計算する。この場合は「その」という代名詞が距離に対する表現であるので、ユーザの使用した距離表現ノードに「その」という指示が使用された証拠データを入力する。その結果、各物体の同定確信度はすべて14となり、まったく判断がつかない状態となった。そのためロボットは次の段階として、一つづつ適当な順番で物体を注目し、それを局在化するように発話を生成する。実際にユーザが希望する物体は、Cであり、ロボットはCに注目する事ができれば、タスクが達成される。




Figure 6.14: Experiment situation for pointing behavior

Table 6.14: Visual feature parameters on real environment

対象	X座標	Y座標	Z座標	大きさ	色相	彩度
A	273	944	625	4258	63	50
B	-278	1158	394	6157	63	47
C	-220	1018	786	2443	18	29
D	245	882	393	3379	17	28

ここでは、ロボットはまず物体 A に注目した。

Table 6.15: Certainty factor of target A

色 (赤)	○			○	○
奥行き (中くらい)		○		○	
面積 (中くらい)			○		○
対象 A	65	14	67	65	95
対象 B	65	14	6	65	43
対象 C	14	14	14	14	14
対象 D	14	14	67	14	62
L	1.00	1.00	1.00	1.00	1.53

Table 6.15 のように、「それは赤い中くらいの大きさの箱ですか？」という二つの視覚特徴表現を使ってロボットは発話を行った。しかしながらユーザの指示物体 C ではないのでユーザは「いいえ違います」と返事をし、次にロボットは物体 B に注目を移した。

Table 6.16: Certainty factor of target B

色 (赤)	○		
奥行き (中くらい)		○	
面積 (大きい)			○
対象 A	65	14	6
対象 B	65	14	14
対象 C	14	14	6
対象 D	14	14	6
L	1.00	1.00	2.23

Table 6.16 のように、4つの物体のうちサイズの大きい物体が一つだけ存在していたので、ロボットは「それは大きい箱の事ですか？」と発話した。しかし、これも対象を同定する事ができず、ロボットは注目を物体 C に移した。

ここでは、Table 6.17 のように、すべての視覚特徴表現を用いても対象を局在化する事ができなかった。そこでロボットは言語表現による局在化をあきらめて、Figure 6.15 のように指さし行動を行いながら、「それはこの箱の事ですか？」と発話を行った。これによって、ユーザの指示物体とロボットの注目物体が一致し、タスクが遂行された。

Table 6.17: Certainty factor of target C

色 (緑)	○			○	○		○
奥行き (中くらい)		○		○		○	○
面積 (小さい)			○		○	○	○
対象 A	14	14	6	14	6	6	6
対象 B	14	14	6	14	6	6	6
対象 C	5	14	67	5	41	67	41
対象 D	5	14	58	5	33	58	33
L	1.00	1.00	1.16	1.00	1.24	1.16	1.24




Figure 6.15: Pointing behavior for target identification

6.5 実環境における人間発見タスクへの応用

画像のセグメンテーションに基づく画像理解の分野 [平田 90] においては、対象となる物体を画面全体から切り出し、抽出する際、どのような視覚特徴を用いて、どのように統合処理を行なうか、が状況やタスクに依存しており、一般的な解が決定できない問題点がある。

この問題に対して、柴田 [柴田 95a] はロボットが見ている画像を人間も共有し、その画面上で人間が判断した特徴領域をヒントとして与え、教示された領域の持つ局在性に基づいて、ロボットが自動的に領域を切り出すための最適解を獲得する手法が提案した。しかし、局在性原理の展開の際、単一の特徴検出器のパラメータ変更の手法としては Coarse to Fine 戦略のみが取り上げられているだけで、複数の検出器の統合戦略についても概念を示しながらも具体例については述べていない。また、一方的に人間が教示している、教示された情報に最適解を求めるアルゴリズムが十分に一般化されていない、などの欠点も持ち合わせる。

本節では、この問題点解決のアプローチとして、6.2節で述べたような、ロボットと人間との協調行動に基づいて、対象領域の切り出し、すなわち人間の発見を行なう、ユーザ発見というタスクは、前にも述べた通り、ロボットが視覚探索しようとしている対象と、対話を行なう対象が同一の存在であり、対話による言語的な結び付きと、視覚探索行動による、視覚的な結び付きの双方によって、ロボットと人間とがカップリングされているため、協調的な対話例として非常に良いテストベッドとなる実験である。

6.5.1 屋外移動ロボットによる人間発見行動

このタスクではパーソナルロボットが、数メートル程度離れた場所にいる自分のユーザから、音声によって呼ばれた時に、複数存在している人間の中から特定ユーザを視覚を用いて区別し、ユーザのもとに移動する。しかしながらユーザから呼ばれた時の状況によって、人間の見え方、背景などの環境の見え方は大きく変動する。顔が見えない場合は顔認識は使用できず、似たような体形をしている場合、似た色の服を着ている場合など、視覚探索を行なう際の戦略を前もって決定する事はできない。状況が変動する事ある程度予想し、取り得る状況の数の分だけ戦略を用意する手法も考えられるが、不確実性、曖昧性は非常に高いままである。このような場合において、人間とロボットが協調的に対話を行なう事で視覚探索戦略を補助し、複雑な状況下においてもロバストな発見を行なう事を目的としている [稲邑 96, 稲邑 95]。

ロボットに搭載されている視覚処理部には、Figure 6.16 のように、色検出モジュール、動き検出モジュール、などがあらかじめ搭載されている。Figure 6.17 のような状況で、目的の人物に向かって移動する場合、その人物の位置する座標が分かれば良いのだが、実際の画像には多くのノイズが含まれているために、どのような視覚特徴に注目すれば良いのかが簡単に

に決定できていない。

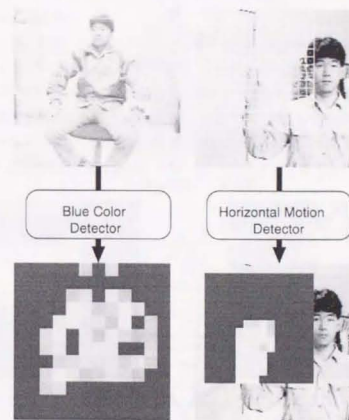


Figure 6.16: Visual feature detectors

Figure 6.17 の場合、色検出モジュールの抽出領域は天井の蛍光灯のノイズを含んでおり、動き検出モジュールは関係ないエリアのノイズに反応してしまっている。この時、局在性規準を満たすように二つの抽出モジュールを同時に処理し、結果の論理和を取る事によって、対象領域を唯一つのものとして検出する事に成功している。

6.5.2 対話による協調行動を前提とした人間の発見処理

前節でも述べたように、対話を行なう主体は、ある目的を持っていて、相手の心的状態を推測しながらコミュニケーションを行なう。この協調を行なうためのモデルは、発話のタイミング、発話の内容、確認すべき事項などを決定している。ここでは、画像処理を補助するために、どのようなタイミングで、どのような内容の情報を発話するか、という問題に対するモデルを提案する。




Figure 6.17: Integration of color detector and motion detector

ここで実現させようとしている対話モデルは、人間の発見という視覚探索タスクにおける対話モデルである。この事を考慮し、使用する視覚特徴検出器の種類に関して対話を行なう [Inamura 98a, Inamura 98b]。

従来の発見手法に見られた線分の検出、エッジの検出、運動領域との融合など、固定されたヒューリスティクスを前提とした手法に比べ、ユーザは使用する視覚特徴検出器に関する言葉を用いる事によって、動的に処理を変更する事ができる。視覚処理の状況を決めるパラメータとして、使用候補となる視覚特徴検出器の種類、同時に使用する個数、使用する優先度などがある。これらのパラメータを対話文章から抽出し、視覚処理の内容を更新する。

この実験での処理の流れを図 Figure 6.18 に、対話モデルの模式図を Figure 6.19 に示す。

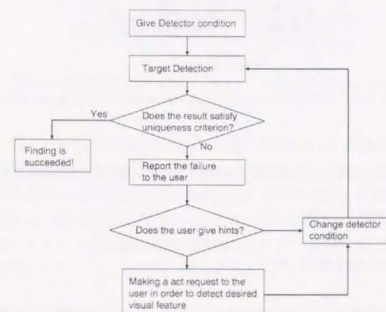


Figure 6.18: Flow chart of human finding processing using cooperation

6.5.3 対話による協調行動を前提とした人間の発見実験

以上に説明した視覚処理と音声対話処理の統合による発見処理を実環境内で実行する例として、状況が以下のような場合の対話の様子を示す。

- 青色の服を着て歩くユーザを発見する。
- となりで青色の荷物を運ぶ別の人間が存在する。

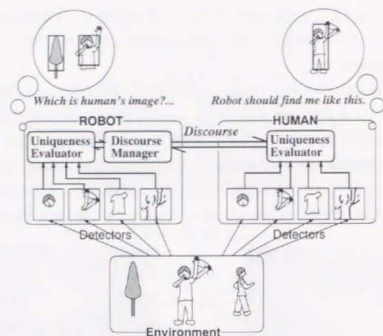


Figure 6.19: Utterance generation process based on uniqueness criterion

まず、ロボットはユーザに対して検出器の使用優先度と最大使用数の教示を求める。

ロボット「特徴を教えてください」
 ユーザ「青い、右、動く」
 ロボット「青色の検出を開始します」
 ロボット「青い領域が左右に二つあります」

このユーザの発話により検出器の使用優先度が、1. 青色検出器、2. 水平運動検出器、の順序となり、検出器の最大使用数が2個に設定された。処理の負担をなるべく軽くするため、まず使用優先度が一番高い検出器を用いて処理を開始し、唯一の特徴的領域を抽出できない場合は、使用優先度に従って並列に処理を行なう検出器の数を増加させる。

ロボット「水平運動の検出を行いません」
 ロボット「青く、水平運動する領域が二つあります」
 ロボット「発見できません」




Figure 6.20: In case where the robot fails to find the user

Figure 6.20 では使用可能な最大数の検出器を用いているが、水平運動検出器と青色検出器では唯一の領域を特定することができず、対象ユーザの特定、発見に成功していない。画面下の矩形表示は左から、水平運動検出器、青色検出器、これらの統合、の結果である。

この場は状況は、青色の服を着ているユーザと青い荷物を運んでいる別の人間の動きが同じ水平運動であったので、垂直運動検出器の使用優先度を上げ、再処理を行なうことになる。使用優先度の変更はロボットとユーザの双方で変更可能とする。

ユーザが使用優先度を変更する場合

ユーザ「上下、動く」
 ロボット「垂直運動する領域を発見しました」

ロボットが使用優先度を変更する場合

ロボット「ジャンプしてくれませんか？」
 (ユーザはジャンプする)
 ロボット「垂直運動する領域を発見しました」

Figure 6.21 は使用優先度を変更し、1. 青色検出器、2. 垂直運動検出器、の使用優先度で検出を行なった処理画像である。垂直運動検出器がジャンプをするユーザを捉え、青色検出器だけでは特定することができないユーザの発見に成功している。画面下の表示は左から、垂直運動検出器、青色検出器、これらの統合、の結果である。




Figure 6.21: Success to find the user

6.6 本章のまとめ

本章では、ユーザの曖昧な指示や、センサ能力の不足、視覚処理における不良設定問題など、実世界で行動するロボットにとって生じる数々の情報の不足を、ユーザとの対話で解決するアプローチの重要性を示し、そのアプローチを実現するためのキーとして対象の局在性という概念を提案した。この局在性を利用して、ユーザが指示を出した参照物体と、ロボットが注目している物体の同一性を検証する手法と、ユーザの使用する視覚特徴表現によって局在性を評価する手法を導入した。これらの評価基準を用いて、局在性を満たすような視覚特徴表現を逆に求める事によって、適切な発話を生成する事を可能とした。さらに、言語による表現だけでは曖昧性が解決できない場合に、実際にロボットが指さし行動を行なう事で問題解決する手法、ロボットがユーザに提案や依頼を行なう手法を実現した。

本章で主に議論した点は、視覚探索タスクにおける状況に応じた適切な発話の生成であったが、この他にも視覚情報と言語情報の結合関係が本章で述べた対話実験を通じて獲得されて行く効果も持つ。この詳細については第7章で述べる。

従来研究としては、自然言語インタフェースを持つ部品組み立てロボット KAMRO [Lueth 94] において、ユーザの指示した部品とロボットが視覚で注目している部品とを一致させるために、自然言語による協調行動が実現されている [Stopp 94]。この研究の中では二つの部品の位置関係に着目して、位置に関する言語情報を扱っているが、本論文における手法であれば位置情報だけでなく、色やサイズ、形などの情報も含める事が可能である。また、本論文の手法の大きな特徴としては、言語表現と視覚特徴パラメータの関係がシステムに組み込まれた一定のものではなく、インタラクションの結果によって動的にユーザに適応する点である。このような機能も KAMRO では実現されていない。

今後の課題点として残されている事は、ユーザの指さし行動の認識などである。現在は視覚特徴として、色や大きさなどの静的な特徴だけをを用いているが、ユーザが指をさして参照を行なう状況はロボットとの自然なインタラクションを考えた場合には重要である [高橋 98, Takahashi 98]。この動作についても、対象の局在性という概念から、対象を同定させるための情報の一つとして有効に活用する事が望まれる。

第7章

言語情報と行動知能との結合関係の獲得

7.1 はじめに

パーソナルロボットは一般の日常生活空間に進出する事を目的としたロボットであり、使用するユーザは専門的知識を持つ人に限らず、ロボットの知識を持たない初心者がユーザとなる。このような場合は特に、ユーザとの自然な対話が重要となり、GUIやキーボード入力など、特定の制限を設ける事は不適当であり、自然言語による対話は欠かせない手段となる。

通常の自然言語処理研究が対象としている問題は、例えば機械翻訳や、内容の要約など、シンボルレベルのみの閉じた世界での言語理解であった。本論文における自然言語処理は、ロボットとの対話のためのものであり、自然言語処理の目標や、使用される環境の条件や形態などは、従来研究と大きく異なる点が多い。ここで、本論文における自然言語処理の位置付け、キーポイントをまとめると、以下の通りとなる。

1. 自然言語処理は、パーソナルロボットのためのインタフェースである。
2. 自然言語処理の実行は、ロボットの行動を生成する事と同値である。
3. シンボルレベルの処理ではなく、物理世界の情報を扱えるような処理形態 [Herzog 94]。
4. 入力された言語を完全に理解するアプローチではなく、知らない未知語に柔軟に対応できる能力が必要である。
5. あらかじめ開発者が語彙を埋め込むのではなく、後天的にユーザとのインタラクションや、環境とのインタラクションを通じて語彙を増やせる事
6. 実世界における言語の意味は、環境の変動やユーザによって変動する可能性がある事で、個人に適応可能な柔軟な表現手法である事

ユーザが完全に制約のない状態で自然言語を使用すると、ロボットが想定している文法規則から外れた表現や、辞書に登録されていない未知語を使用する事が十分考えられる。このような場合、ただ単に「理解できません」と入力を拒絶してしまうのではロボットのためのインタフェースとして不適切である。このような問題に対応するには、上記に挙げた性質を活用して、ロボットは後天的に語彙を獲得する事が必要となる。

Fryらは事情通口ロボットプロジェクトの中で、音声対話を前提とした自然言語によるロボットの行動制御手法 [Fry 98] を提案しているが、Torrance [Torrance 94] と同様にあらかじめ埋め込まれた語彙に従って対話を行なっているのみであり、新しい語彙を獲得する手法については述べられていない。

藤江ら [藤江 99b] は、ロボットにおける未知の言葉によって行動の指示を出した場合に、ロボットとの行動を介した対話によって、その言葉が意味する行動を獲得する手法を提案している。また同様に Hwang ら [Hwang 98, Hwang 96] も、ヒューマノイド型ロボットにおいて、新しい動作に関する語彙を獲得する際に、実際に人間が行動をデモンストレーションして見せ、動作と言語の結び付きを獲得している。この獲得機構は Learning User Interface (LUI) と呼ばれ、人間の動作と言語の結合関係を学習するが、物体の上下関係などの位置に関する情報を扱うものである [Chen 94]。いずれも個人への適応や、行動以外の言葉への対応については述べられていない。

本章では、このようなパーソナルロボットにおける背景を踏まえ、実世界に対する言語を用いたインタフェースを実現する。また、ユーザが新しく使用する未知の単語を検出し、その新しい意味を推測し、実世界における情報と統計的に結び付ける表現手法を提案する。




Figure 7.1: Natural Language Communication with Robots

7.2 自律行動の生成を伴う統語解析

本文における自然言語処理の流れは Figure 7.2 のようになっている。第一段階で統語解析を行ない、第二段階で意味解析、第三段階でシンボルの情報を物理世界における情報にバインドする、という具合である。

従来の自然言語処理研究の目標は、入力された言語情報を要約したり、他言語に翻訳する事であるが、本研究での処理は、最終的に出力されるものがロボットの行動を制御するための指令情報である事が従来研究と大きく異なる点である。




Figure 7.2: Concept of natural language processing in this thesis

統語解析は構文解析とも呼ばれ、言語処理の前段階とも言える処理である。与えられた発話に対して単語の並びを解析し、句構造を抽出するのが主な働きである。この解析には単語に関する知識と、文法に関する知識が必要とされる。これらの情報はあらかじめデータベースに蓄積されており、解析処理の間に参照される。この解析処理では、言語が文法的にどのような構造を持っているか、という情報のみが出力される。

意味解析は、統語解析によって生成された句構造、および文法構造、に従ってそれぞれの単語の意味を解析し、文全体の意味を解釈する部分である。この部分で文法構造に意味が付加される。

最終的な段階として、シンボル情報とパターン情報を変換するためのシンボルグラウンディングが行われ、物理世界におけるロボットの行動を表現するような指令が出力される。

7.2.1 構文解析部

まず、文の意味を理解するためには、構文解析と呼ばれる処理を必要とする。統語解析とは、形態素解析のように文を単語の集合として表現するだけでなく、句構造の集まりとして構造化する処理の事である。この構造により、各単語が持つ意味を適切に組み合わせて文全体の意味を構成する事が可能となる。句構造を表現する方法として有名なものに、BNF(Backus Normal Form) 記法がある。これは、種類の書き換え規則に従って句構造の取り得る状態を記述するものである。Table 7.1 にBNFによる文法規則表現の例を示す。

Table 7.1: Example of BNF representation

Sentence	→ Declarative-Sentence Terminal-Symbol (平叙文)
Sentence	→ Interrogative-Sentence Terminal-Symbol (疑問文)
Sentence	→ Imperative-Sentence Terminal-Symbol (命令文)
Imperative-Sentence	→ Subject Verb
Subject	→ NP P
NP	→ Adjective NP
NP	→ Noun
NP	→ NP Particle
NP	→ Dem. NP
Noun	→ hako tsukue
Adjective	→ akai aoi ookii tiisai

このBNFによる統語解析は、NP(名詞句:Noun Phrase)やAdjective(形容詞)など、句の種類があらかじめ分かっている事が前提で、これらの情報は単語データベースに登録されている事が前提となっている。よって、入力された文章に沿って一単語ごとに辞書を引き、品詞の種類を参照する事が必要となる。言語が英語の場合、単語間に必ずスペースが挿入されるため、単語要素に分割するのは容易であるが、日本語の場合は単語間に挿入されるシンボルはないので、同時に単語要素に分割する必要も生じる。このため、予測ボトムアップ法[田中 83]と呼ばれる手法を用いて単語要素への分割を行なっている。予測ボトムアップ法とは、構文解析を行なう途中段階で、部分的な構文解析の目標をサブゴールとして登録し、効率の良い解析を行なう手法である。

例として、sonoakaihakowototte (その赤い箱を取って) という依頼文を発話した時の解析の流れを以下に示す。なお、ここではシステムのインプリメントに合わせてローマ字表現で処理の流れを説明するが、実際には漢字混じりの日本語においても同様の処理は可能である。

まず、文章の初めの単語からなるべく長い単語を探索するように辞書を引く。すると、sono が該当し、指示代名詞 (Demonstrative-pronoun. 以下 Dem. とする) である事が分か

る。ここで構文解析の目標とする構造は Sentence であるので Sentence をサブゴールとして登録し、残りの文章を解析する。Figure 7.3 はこの段階での構文解析の結果を木構造で示したものである。点線はゴール関係である事を示し、残りの解析候補となる文字列も点線で囲んである。




Figure 7.3: syntactics analysis step 1

次に、Dem. を構成する文法規則を、Table 7.1 のBNF記法のルールベースから検索すると、

NP → Dem. NP

がある。そこで Figure 7.4 のようにボトムアップに展開を進める。




Figure 7.4: syntactics analysis step 2

この段階で辞書を引くと、akai (形容詞:Adjective) が該当する。この Adjective が先頭に来る文法規則としては

NP → Adjective NP

が存在しており、Adjective は NP をサブゴールとしているので、次の段階へと進む。この段階の構文解析の結果は Figure 7.5 のようになる。




Figure 7.5: syntactics analysis step 3

ここでのサブゴールは NP となり、辞書を引くと hako(名詞:Noun) が残りの候補文章に存在する。

NP → Noun

の規則が存在するので、Noun は NP をゴールとしている。ここで Figure 7.5 の*印の NP を頭とする部分木の下に点線枠で囲まれた残り文字列がからなくなるので、サブゴールは Sentence に戻る。この結果、解析木は Figure 7.6 のようになる。ここで辞書を引くと wo(助詞:Particle. 以下 P とする) が存在し、P に関する文法規則としては

Subject → NP P

が存在するので、Figure 7.7 のように展開される。




Figure 7.6: syntactics analysis step 4

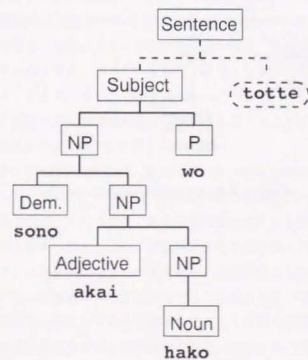


Figure 7.7: syntactics analysis step 5

最終的に

Imperative-Sentence → Subject Order-Verb
Sentence → Imperative-Sentence Terminal-Symbol

という規則を用いて、Figure 7.8 のような構文解析木が完成する。

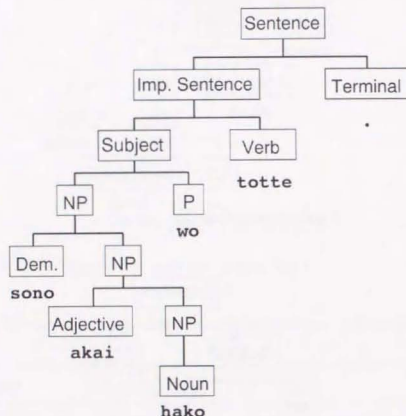


Figure 7.8: syntactics analysis step 6

7.2.2 意味文法を用いた意味解析

次の意味解析の段階に入ると、物体や時間の概念、属性の種類と値、事象、因果関係など、非常に複雑な知識モデルが必要となって来る。統語解析と意味解析の違いを明確にする有名な例として次のような文章がある。

色の無い緑の概念達が猛烈に眠る
Colorless green ideas sleep furiously.

この文は統語解析的には、正しい文法に従って書かれている文として解析される。しかしながらまったく意味をなさない文となっている。このように統語解析部では処理できない意味の解釈を行ない、次段階への処理につなげる事が意味解析部の役割である。

統語解析におけるBNFの書き替え規則を使用しているだけでは、意味の解釈を行なう事ができない。BNFは意味を伴わない構文解析を行なうための規則であるので、何らかの拡張を行なう必要がある。このために従来の研究で良く取られていた解決手法は、BNF規則に意味を解釈するための論理式を対応させるものである。これによって構文解析の結果を使った論理式を生成する事が可能となり、それに基づいて意味を解釈する事が可能になる。

しかしながら、ここで生じる問題は、このような意味の解析に必要な意味構造を文法に埋め込む作業は、言語が持つ多様性を十分考慮して埋め込む必要がある事である。意味構造は環境や使用する主体などの、文脈に大きく依存するものであり、最適な意味構造を設計するには非常に大きな労力を必要とする。ここで、本論文で必要となる自然言語処理の性質を振り返ると、パーソナルロボットとユーザとのインタフェースの一つという位置付けがある。すなわち、すべての文脈に必要な一般的な意味構造は必ずしも必要とはされず、ロボットが行動を行なう中で必要となる自然言語の意味が含まれていれば良い。

このような考え方で生み出されたのが、意味文法 (semantic grammar) という文法表現のアプローチである。このアプローチの中では、対話の内容は制限され、意味解析部が持つ意味構造の数が大きく制限される。その代わり、ある問題領域に特化した意味を埋め込む事が可能であり、その性能は向上する。例としては、航空機チケットの予約システムなどの特定の分野に使用されており、文法規則に与えられる意味が、直接対象となっている問題空間の表現に対応している。このように領域やタスクを限定することによって、曖昧性の解消などが効果的になる。本研究において対象としている対話はロボットと人間との間で交わされる対話であり、日常生活で人間同士が行なう会話とは性質が異なる。ロボットに対する発話は完全に自由な文章である必要はなく、そのロボットが持っている機能に応じた文章であれば良い。夕食の時、誰も「もう食べられないから、代わりに食べて」などとロボットに話しかける人はいないだろう。意味文法はこのような観点から、ロボットと人間との対話に適した文法表現であると

言える。

このようなアプローチに反対する意見として、領域を限定し、使用できる文法を限定する事は、使用できる語彙や表現に制約ができてしまい、自然言語インタフェースとしての利点が失われてしまう、というものがある。しかしながら、ケーリーとチャバーニスは、コンピュータと人間のインタラクションにおいて自然言語処理に必要な語彙数に制限を受けても発話の自由度には影響がない事を主張している[Eberts 91]。彼らは、二人からなるチームを作り、ある問題解決を行なう際に、互いに自然言語で交流するように指示をし、問題解決を行なわせた。この際、二人が良く使用する単語を記録し、最も良く使う単語 300 語を選別した。まったく別の二人のチームに、同じ問題を提示し、先のチームが使用した 300 単語のみを使って交流をし、問題解決をせよ、と指示を与えたところ、前後二つのチームによって、問題解決能力にほとんど差がないことが示された。この事から、状況に応じて適切な単語や文法などを選択すれば、その数を制限されていたとしても自然な対話が成立する事がわかる。

そこで本論文においても、意味文法の構造を導入する事とした。意味文法では、例えば形容詞 (Adjective) をさらに細分化し、色彩形容詞、サイズ形容詞、距離形容詞、などのサブクラスを生成する。このような細分化により、単なる形容詞が持つ文法的な意味から拡張した、実際の物理世界に見合った意味構造を埋め込む事が可能となる。

この意味解析を終えた段階で、曖昧な情報が含まれていなければロボットに行動を発行する事になる。この行動には、実際にロボットに取らせる行動、疑問文に回答するための発話、提案を提案する、などの行動が含まれている。

7.2.3 シンボル情報と物理パターン情報の変換

意味解析を終えた後でも、いくつかの問題点が残る。曖昧性の解消や、文脈に依存した解釈、談話コンテキストによる意味の多重性などである。日本語に多く見られる同音異義語は文脈によって事なる意味を持ち得る。また、「その箱は大きい」という文にしても、「その」が指し示している物体は具体的にどれなのか、大きいという表現は具体的にどのくらい大きいのか、という、参照に関する曖昧性と漠然とした情報の曖昧性、という複数の曖昧性が存在している。

自然言語処理において最も複雑で困難な問題がこの曖昧性の解消である。特に、従来研究と本研究の相違点として、実際の物理世界で行動するロボットのための自然言語処理である、という事がある。例えば「赤い箱」というシンボルが持つ意味は、従来研究では、(IS-a color red) などのシンボルレベルでの意味解釈が中心であったが、本研究では実世界での視覚パラメータとのバインディング、すなわちシンボルグラウンディングの問題が密接に絡んでくる。通常の曖昧性に加え、このような実世界に対する曖昧性が加わるのが大きな問題点である。

近年、この曖昧性解消のためのアプローチとして、統計的処理に基づく確率的判断が研究対象として注目されて来ている。このアプローチは、対話コーパスなどの大規模のデータベースを利用して、複数の概念間の接続関係を求めるものである。

そのようなアプローチの研究の一つとして、Charniak は自然言語で表記された物語をシステムに入力し、Bayesian Network を用いてその文脈を理解するシステムを構築している[Charniak 93]。このシステムでは、取り得る文脈の候補を意味解析部で絞り込んだ後に、物語が進行して行く上で現れた事象を手がかりにして候補となる文脈の尤度を算出する。また、Wu らは、Bayesian Network によって意味解析に生じる曖昧性を回避する方法を提案しており[Wu 93b, Wu 93a]。Eizirik らは語彙に含まれる曖昧性を Bayesian Network によって解決するアプローチ[Eizirik 93]を取っている。

このように自然言語処理を行う上で問題となってくる、曖昧性や不完全な情報を扱う際には、Bayesian Network を始めとする統計的処理は非常に強力な手段となる。そこで、本研究においても、実世界の視覚パラメータと、意味解析部でのシンボルのバインディングを行なうために、第4章で述べたような、シンボル-パラメータ間の表現を Bayesian Network によって行なう事アプローチを取る。また、意味解析が終了後の曖昧性の解消についても同様の事が言える。従来研究では、シンボルレベルでの文脈を用いて意味の曖昧性の解消を試みていたが、本研究では第6章において述べたように、実際の物理世界に対するインタラクションを通じて、対象物の参照行動に関する曖昧性解消を行なう。すなわち、意味解析部におけるシンボルバインディング問題、および曖昧性解消部における物理世界へのインタラクション、を追加するアプローチが本研究の自然言語処理のキーポイントとなる。

7.3 統語解析部の実装

以上のように、構文解析だけでなく、意味解析を伴う処理を行なうためのシステムとして、カーネギーメロン大学の Tom Moran らが作成した、MILISY (Mini-Linguistic System) がある。このシステムは英語での対話を対象としており、構文解析を行ない、その意味を解析しながら知識を蓄えたり、ユーザからの発話が質問であれば、その質問に対応した応答文を生成する事ができる。田中ら [田中 83] はこの MILISY を日本語に対応できるように拡張を行ない、TQAS (Tiny Question Answering System) というシステムを開発した。この自然言語理解サブシステムは、ユーザから発せられたロボットへの命令、要求に関する対話に対応する事ができ、ロボットが経験した事を背景知識として曖昧性の解消を行なう事ができる。

この TQAS を原型として、ロボットと人間との対話を背景にして改良された自然言語理解機能を EusLisp [Matsui 94] 上に搭載した。EusLisp はオブジェクト指向型の Lisp であり、ロボットのモデルの記述、行動の生成など、またソケット通信などの UNIX コマンドの実行環境など、ロボットに特化した機能を豊富に持つインタプリタ言語である。自然言語処理の場合、オブジェクト指向で句構造を表現する事の利点と、従来開発されてきたロボットのソフトウェアを再利用できる利点を考慮し、この EusLisp を採用した。

Figure 7.9 はロボットのための自然言語処理の流れを示したものである。

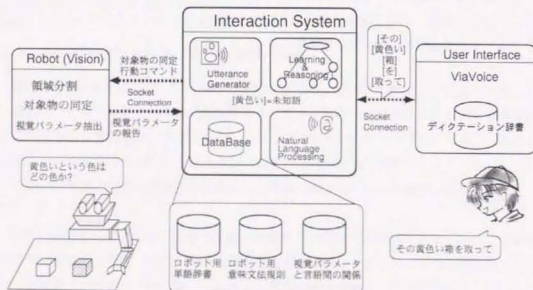


Figure 7.9: System diagram of natural language processing for robots

7.3.1 単語辞書の定義

構文解析において基本となる情報は単語辞書の情報である。Table 7.3 に辞書の構造の例を示す。

それぞれの意味は、二つ目の要素が単語のシンボル、三つ目の要素が 7.2.1 節で述べた、意味文法要素の種類、四つ目の要素が意味文法要素の意味解釈を行なうための評価式、五つ目の要素が日本語表現をする場合の文字列である。

この辞書情報は EusLisp 上で、Table 7.2 のようなクラス (syntactic-tree) で表現される。スロット変数 kind に意味文法要素の種類が、meaning に意味解釈を行うための評価式が、japanese に日本語表現文字列が格納される。スロット変数 treeeq は、自分自身と同じクラスのインスタンスの配列へのポインタである。この treeeq を用いて 7.2.1 節で説明したような構文解析木を表現する。すなわち syntactic-tree クラスは単語を表現するだけでなく、文の構造を表現するためのクラスである。

Table 7.2: Definition of tree class for parsing

```
(defclass syntactic-tree
  :super syntactic
  :slots (kind ;; 意味文法要素の種類
         treeeq ;; syntactic-tree インスタンス (子 tree) のリスト列
         meaning ;;
         japanese ;; 発話する時の日本語表現)
)
```

例えば、意味文法要素 Subject (主語) は、二つの意味文法要素 NP (名詞句) と Particle (助詞) から構成される。この場合には、NP と Particle を表現するインスタンスが生成され、そのインスタンス列が、Subject のインスタンスに存在するスロット変数 treeeq に代入される。

7.3.2 意味文法の定義

意味文法要素は、品詞をさらに細かく分類するような構成になっている。例えば名詞をさらに分類して、固有名詞 (proper-noun)、場所名詞 (location-noun)、属性値名詞 (attribution-value-noun) などを用意する。形容詞、の場合には、色形容詞、サイズ形容詞、位置形容詞、などを用意する。本システムに登録されている意味文法要素の一覧を Table 7.4 に示す。

ここで例として、色形容詞と固有名詞のそれぞれの意味文法要素の表現方法を説明する。

Table 7.3: Example of dictionary data structure

(beya noun (noun 'room) "部屋")	
(hito noun (noun 'person) "人")	
(watashi noun (iam-noun) "私")	
(sono demonstrative-pronoun 'sono "その")	
(hidari location-noun 'hidari "左")	
(migi location-noun 'migi "右")	
(inoue attribution-value-noun (attribution-value-noun 'inaba) "井上")	
(inaba attribution-value-noun (attribution-value-noun 'inaba) "稲場")	
(tanaka attribution-value-noun (attribution-value-noun 'tanaka) "田中")	
(suzuki attribution-value-noun (attribution-value-noun 'suzuki) "鈴木")	
(iru verb 'iru "いる")	
(imasu verb 'imasu "います")	
(ita past-verb 'ita "いた")	
(mita past-verb 'mita "見た")	
(imasita past-verb 'imasita "いました")	
(itte order-verb (order-verb 'gote) "行って")	
(totte order-verb (order-verb 'take) "取って")	
(todokete order-verb (order-verb 'bring) "届けて")	
(kikasete order-verb (order-verb 'play-dengen) "聞かせて")	
(mite order-verb (order-verb 'look) "見て")	
(desu aux-verb 'desu "です")	
(nani what 'nani "何")	
(ikutu howmany 'ikutu "いくつ")	
(itu when 'itu "いつ")	
(dare who 'dare "誰")	
(ga particle 'ga "が")	
(no particle 'no "の")	
(ni particle 'ni "に")	
(ha particle 'ha "は")	
(wo particle 'wo "を")	
(ka whend 'ka "か")	
(kana whend 'ka "かな")	
(inoue proper-noun (proper-noun 'inoue 'person) "井上")	
(inaba proper-noun (proper-noun 'inaba 'person) "稲場")	
(tanaka proper-noun (proper-noun 'tanaka 'person) "田中")	
(suzuki proper-noun (proper-noun 'suzuki 'person) "鈴木")	
(conference proper-noun (proper-noun 'conference 'room) "会議室")	
(construction proper-noun (proper-noun 'construction 'room) "工作室")	
(rest-room proper-noun (proper-noun 'rest-room 'room) "休息室")	
(kyou time-noun (time-noun '((identity * * *))) "今日")	
(kinou time-noun (time-noun '((- * * *))) "昨日")	
(asa time-noun (time-noun '((* 8 * *) (* 11 * *))) "朝")	
(yoru time-noun (time-noun '((* 17 * *) (* 19 * *))) "夜")	
(hai special-word (yes-word) "はい")	
(iie special-word (no-word) "いいえ")	

Table 7.4: Example of semantic grammar

品詞名	意味文法要素名	インプリメント時のシンボル	作用
名詞	場所名詞	location-noun	場所に関する名前
	物体名詞	noun	物体の名前
	人称代名詞	iam-noun	人称別の表現に対応
	属性値名詞	attribute-value-noun	各種属性の値の表現
	ボディ名詞	body-part-noun	ロボット自身の体の部分の名前
	時刻名詞	time-noun	時刻の名前
形容詞	色形容詞	adjective	色による形容
	サイズ形容詞	adjective	大きさによる形容
	場所形容詞	adjective	場所に関する形容
	数形容詞	number-adjective	数による形容
動詞	状態動詞	verb	英語の be 動詞に相当
	過去状態動詞	past-verb	上の過去型
	命令動詞	order-verb	ロボットへの指令
	疑問動詞	when	時間に関する疑問文
疑問詞	人物疑問詞	who	人物に関する疑問文
	場所疑問詞	where	場所に関する疑問文
	数疑問詞	howmany	数に関する疑問文

色形容詞の定義

まず単語レベルで、Table 7.5 のように色形容詞として単語登録を行なう。

Table 7.5: Definition of semantic grammar for color adjective

(akai adjective (adjective 'color 'red) "赤い")	
(aoi adjective (adjective 'color 'blue) "青い")	
(kiroi adjective (adjective 'color 'yellow) "黄色い")	
(midorino adjective (adjective 'color 'green) "緑色の")	

この形容詞が評価される場合、3 つ目の要素である、

(adjective 'color 'red)

という関数が呼び出される事になり、その関数は Table 7.6 のように定義されている。

この定義が、各意味文法要素ごとに用意されており、この関数の中で記述される内容に

よって、意味文法の意味を細かく記述する事になる。この中では、adjective-class という名前の形容詞を管理するクラスを使用しているが、これは Table 7.7 のように定義されている。

すなわち、形容詞に関して、その単語を評価する事は、形容詞の種類 (この場合は色形容詞) と、その属性値 (例えば 'red') を対とした形容詞管理クラスを生成する事と同値になる。

Table 7.6: Definition of semantic grammar function for adjective

```
(defun adjective (attribution value)
  (instance adjective-class :init
    :attribution-list
    '(:attribution (quote ,attribution) :value (quote ,value))
    :interpret-code
    '(:attribution ,attribution :value ,value)
  ))
```

Table 7.7: Definition of adjective class

```
(defclass adjective-class
  :super hinshi
  :slots
  (attribution-list
   interpret-code)
  )
```

固有名詞の定義

固有名詞はさらに細かく分類すると、人物の名前や、部屋の名前、に分けられる。それぞれを表現するために、Table 7.8 のような単語登録を行う。

この固有名詞が評価される時、3つ目の要素である

```
(proper-noun 'room710 'room)
```

という関数が呼び出される。この関数 proper-noun は Table 7.9 のように定義され、pexis-object という概念を表すクラスのインスタンスを生成するコードが作られる。この pexis-object については第8章で詳しく述べる。

Table 7.8: Definition of semantic grammar for proper noun

```
(inoue proper-noun (proper-noun 'inoue 'person))
(inaba proper-noun (proper-noun 'inaba 'person))
(710 proper-noun (proper-noun 'room710 'room))
(701 proper-noun (proper-noun 'room701 'room))
```

Table 7.9: Definition of semantic grammar function for proper noun

```
(defun proper-noun (name is-a)
  (instance noun-class :init
    :object-list (send *system* :mtm-reference :name name)
    :new-evaluation
    '(instance pexis-object :init
      :name (quote ,name)
      :is-a (quote ,is-a))))
```

このようなシステムの挙動を示すコードは、名詞を表すクラスで表現される。Table 7.10 に名詞を表現するクラスの定義を示す。

Table 7.10: Definition of noun class

```
(defclass noun-class
  :super hinshi
  :slots
  (object-list
   new-evaluation)
  )
```

7.3.3 文法規則と意味文法コードの定義

Table 7.4 で説明したような意味文法要素を複数組み合わせる事で、より上位概念の意味文法を形成するアプローチを取る。この文法規則はBNF記法をベースに Figure 7.10 のように表現され、親の意味文法要素 (parent-semantic-factor) と、それを構成する子の意味文法要素 (child-semantic-factor) のリストを記述する。すなわち、意味文法要素は再帰的に親の意味文法要素の構成要素となる。また、その意味文法要素展開リストと合わせて、その親の意味文法を解釈する評価式 (evaluation-list) の3つの部分で、一つの文法規則を表現する。




Figure 7.10: Definition form of semantic grammar

図中の @マークは省略可能を意味しており、ある親の意味文法要素を構成する子の意味文法要素の組み合わせ方法は何通りでも存在する。この表現形式による文法の規則の例を Table 7.11 に示す。

名詞、名詞句、形容詞句など、統語解析を行なう上で必要となる文法の要素に対して、以下のようなクラス表現を準備し、統語解析を実行しながらそのインスタンスを生成する構成になっている。

7.3.4 意味解釈の実行

意味文法要素は、Figure 7.10 に示すように、意味を解釈するための評価式を保持している。意味解釈はこの評価式を Lisp レベルで評価する事によって行う。

例として、「その赤い箱を取って」という依頼文を統語解析した場合の結果を Figure 7.11 に示す。この時、ユーザから与えられた文章の意味は、構文解析木のトップノードである、Subject の評価式に内在する。システムはこの Subject の評価式

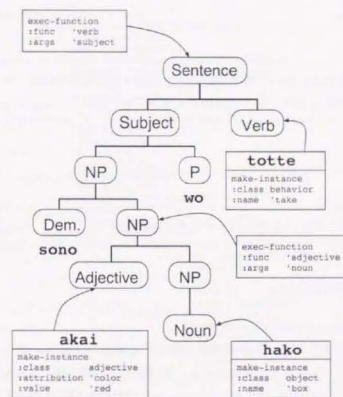


Figure 7.11: Result of syntactic analysis

```

exec-function
:func 'verb
:args 'subject

```

を評価する事によって、意味を解釈する。ここでバッククォートで示される部分は子ノードの意味解釈結果に対応しており、構文解析木の親ノードから子ノードへ伝播させながら再帰的に意味解釈を行って行く。この場合は Verb の意味解釈を行うために

```

make-instance
:class behavior
:name 'take

```

が評価され、「物体を取る」という基本行動のインスタンスが生成される。一方で Subject を評価すると、その2段下の NP ノードを評価する事と同等になり、Noun の意味解釈結果の

```

make-instance
:class object
:name 'box

```

という物体のインスタンスと、Adjective での意味解釈結果

```

make-instance
:class adjective
:name 'red

```

という形容詞のインスタンスが、物体の修飾を評価する関数 adjective に入力され、「赤い箱」を意味する物体インスタンスが生成される。最終的に、「赤い箱」を意味する物体を「取る」という行動が生成され、それがロボットに対して送信される。

このような意味解釈法を用いる事によって、自然言語の入力をロボットシステムの動作に変換する。この例ではロボットへの命令文であり、行動を実行する中間コードが生成されたが、肯定文の場合には第3章で述べたような経験の蓄積を行う中間コードが生成され、疑問文の場合には、質問に答えるために過去の経験から推論するための中間コードが生成されたりする。

Table 7.11: Definition of grammar rule

```

(sentence ( (declarative-sentence nil)
              (terminal-symbol nil) )
           (meaning 'declarative-sentence))

(sentence ( (interrogative-sentence nil)
              (terminal-symbol nil) )
           (meaning 'interrogative-sentence))

(sentence ( (imperative-sentence nil)
              (terminal-symbol nil) )
           (meaning 'imperative-sentence))

(declarative-sentence ( (subject nil)
                        &(location-adverb-phrase nil)
                        &(time-phrase nil)
                        (verb (iru imasu)))
                      (report-robot-room-person-observation
                       (meaning 'location-adverb-phrase)
                       (meaning 'time-phrase)
                       (meaning 'subject))))

(interrogative-sentence ( (location-adverb-phrase nil)
                          &(particle ba)
                          (time-phrase nil)
                          (who nil)
                          (particle ga)
                          (verb (iru imasu))
                          (whqend nil))
                        (cast-reasoning-command
                         'person
                         (instance evidence-list :init
                          'e-list
                          (list (instance evidence :init
                                   :node-name 'room
                                   :symbol-data
                                   (send
                                    (meaning 'location-adverb-phrase)
                                    :interpret-symbol)))
                                (instance evidence :init
                                   :node-name 'time
                                   :symbol-data
                                   (send (meaning 'time-phrase)
                                    :interpret-symbol))))
                          )))

(imperative-sentence ( (subject nil)
                       (order-verb nil)
                       &(aux-verb nil))
                     (cast-behavior-command
                      (meaning 'order-verb)
                      (meaning 'subject)))

(subject ( (noun-phrase nil)
           &(particle (ga ha no wo o)))
         (let ((noun-phrase (meaning 'noun-phrase)))
           (only (send noun-phrase :pronoun)
                 (send noun-phrase :noun))))

(noun-phrase ( (proper-noun nil) )
              (instance noun-phrase-class :init
               :pronoun nil
               :noun (meaning 'proper-noun)))

(noun-phrase ( (adjective nil)
               (noun-phrase nil))
              (modify (meaning 'adjective)
                       (meaning 'noun-phrase)))

```


7.4 対話に基づく新しい単語の獲得

今までの段階で、ユーザの発話内容を解釈し、ロボットの行動を出力する手法について述べたが、パーソナルロボットにおける自然言語インタフェースを実現するには、もう一つ重要な機能が必要となる。それは自然言語処理システムに搭載されていない語彙や表現などをユーザが使用した場合への対応である。

今までもロボットにおける自然言語インタフェースの研究はいくつか進められてきたが[柴田 94, 川崎 99]、そのいずれも未知の表現や単語に対応する手段については述べられていない。また、Chapman のユーザと対話し、視覚を使って行動するエージェントの研究[Chapman 91]においても、ユーザからの指示を状況に応じて実行するだけであり、新しい表現への対応については述べられていない。

第2章で論じた、対話に基づく行動知能の形成という側面からも、ロボットが限定された知識しか持たない状態から活動を行ない、対話を重ねて行く課程で、新しく対話に登場した単語を獲得し、徐々にユーザに適応した言語の取り扱いを可能にする事は重要な行動知能形成行動の一部と見なすことができる。

未知の新しい単語を獲得し、その意味や概念などを理解するためには、以下の複数の段階に分けて考える事ができる。

1. 構文解析の段階での未知単語の検出
2. 意味解析の段階での、単語の概念の獲得
3. 概念の属性値の物理世界との対応付け

7.4.1 ディクテーション機能を用いた未知単語の検出

新しい単語を獲得するためには、未知の単語を「未知である」と認識する所から始める。文章中の未知単語を検出する方法としては、書き言葉における検出方法と、話し言葉における検出方法の大きく二つが存在する。前者は構文解析における検出アルゴリズムがメインとなり、後者の音声認識における検出では、音声認識を行なう際に未知である事を認識する手法として、A*探索アルゴリズム[佐藤 94]やフレズスポッティング[北岡 93]を用いる手法がある。しかしながら、文脈と切り離された単語要素レベルでの未知単語検出は難しい側面が多い。

近年の音声対話システムは、大量の概念データベースや、対話コーパスを持つ事を前提に作成されているものが多く、この大量のデータベースを利用して、未知の単語を類推する手法

も提案されている[荒木 94]。そこで、ディクテーションによる音声認識処理と、文法規則の比較による未知単語の検出について述べる[稲島 00b]。

ディクテーション機能を持つ音声認識システムとして、IBM 社の ViaVoice を採用した。実際に使用した音声認識システムは IBM の ViaVoice シリーズの最新版の製品である ViaVoice Pro Millennium であるが、これにはディクテーション辞書として 8 万語の語彙が搭載されており[宮崎 99]、その性能は群を抜いている。ディクテーションの結果は

その | 黄色い | 箱 | を | 取って

という具合に、単語間にスペースを挿入した形式で出力される。通常の自然言語であれば単語間のスペースが存在しないので、統語解析によって単語要素を切り分けと辞書参照を同時に行なっていたが、この場合は直接辞書を参照する事が可能となる。これにより、非常に簡単に未知単語を検出する事が可能となる。

これは一見、パーソナルロボットにおいて重要となる、後天的な語彙の獲得とは逆のアプローチのように見えるが、ロボットが所有する辞書と、ディクテーションの辞書は別に扱う。ロボットの所有する辞書を後天的に増加させるために、ディクテーション辞書を利用する、というアプローチである。

検出された単語は、二段階に分けてその意味を登録する必要がある。まず、その単語が持つ意味を、意味文法上の要素の種類として認識し、意味文法の辞書に登録する段階。そして次の段階として、その単語シンボルと物理世界とのバインディング情報を登録する段階である。以下にその二つの処理について説明して行く。

7.4.2 未知単語に対する意味文法要素の類推

未知語の検出が終了した時点で、「動詞」「名詞」「形容詞」などの意味文法要素の種類を判別する必要がある。この判定には先に述べた統語解析部の処理モジュールを使用する事ができる。

先ほどの例で、「黄色い」という単語が未知だった場合、ロボットの所有する辞書を参照し、意味文法要素に変換すると

Pronoun | UNKNOWN | Noun | Particle | Verb

のようになる。ここで UNKNOWN の部分の意味文法要素を確定させる事になるが、UNKNOWN の部分が取り得る意味文法要素の種類は有限であるので、候補となる文法要素を代入して構文解析が成立するかどうかを確認すれば良い。すなわち、UNKNOWN の部分に、

Noun, Pronoun, Particle, Adjective, Verb, など候補を一つづつ当てはめる。Noun の場合は、

```
pronoun | Noun | noun | particle | order-verb
```

となり、Noun が連続するような文法規則がなく、Verb の場合も、

```
pronoun | Verb | noun | particle | order-verb
```

のように、pronoun の直後に Verb が来る事はない。このように候補を絞って行くと、この場合最終的に adjective が残り、形容詞という意味文法要素である事が判定される。この意味文法要素の種類の判定アルゴリズムを Table 7.12 に示す。

この意味文法要素の種類の判定した段階で、未知語の情報が辞書データベースと、意味文法データベースに追加される。最終的な段階として、未知語のシンボルと物理世界のパラメータの関係を獲得する必要があるがそれについては次節で述べる。

Table 7.12: Algorithm for distinction of semantic grammar factor

```
global variables: Sentence s /* ユーザの発話した文章 */
function Distinction-of-Semantic-Grammar-Factor()
{
  local variables: Integer p /* 未知語の位置 */
  local variables: Words word[] /* 単語の配列 */
  local variables: Semantic-Grammar-Factor sgf /* 意味文法要素 */

  word[] = Add-Partition-using-Dictation(s)
  p = Detect-Unknown-Word(word[])
  for each Semantic-Grammar-Factor sgf in Grammar-DataBase do {
    word[p] ← sgf
    if (Parsing(word[]) == True) then return sgf
  }
  exit
}
```

7.4.3 単語の意味の獲得

単語の意味をシステムに登録するためには、品詞ごとにその処理が大きく異なる助詞や、疑問詞など、文法として基本的な要素である品詞に新しい単語を追加する事は無いと考えられ

る。ロボットと人間との対話である事を考慮すると、新しい単語はほぼ名詞と動詞、そして物を修飾する形容詞の種類だけであるので、この3つの意味文法に関して、シンボルと物理世界とのバインディングを獲得する方法について述べる。

新しい名詞の登録

これは、主に固有名詞の登録が考えられる。その他にも個人の生活空間に依存した新しい概念の名前が与えられる事が予想される。名詞の場合に必要な情報は、前者の場合には、ある概念に属する属性値としてのシンボルであり、後者の場合には、上位の概念、他の概念との関係などである。

ここで問題となるのは、新しく検出された名詞が、どのような意味文法要素に属するかを区別できない事である。例えば検出される名詞がすべて実際に視覚情報として見る事のできる物体の名前であれば、Knoll らのシステム [Knoll 97] のように、「これは何という名前ですか?」という発話や、「その名前の物体はどれですか?」という対話を行う事によって解決はできる。しかしながら、7.4.1節で述べた意味文法要素の判定の限界を超えると、人物を表す固有名詞なのか、部屋の名前を表す固有名詞なのか、によって、行うべき対話のパターンが異なってくる。

現在の段階では、二つの解決方法がある。一つ目は、判定する事のできなかった意味文法要素の候補集合をユーザに提示して、「この名詞は、人物の名前ですか、それとも部屋の名前ですか?」などと質問する方法。二つ目はユーザとのインタラクションの文脈を保持しておき、検出された未知名詞の種類を推測する方法である。

新しい形容詞の登録

未知語が形容詞だった場合、ある属性に関する属性値が形容詞の意味として登録されるべき情報となる。例えば物体の性質を表現する形容詞の場合は、大きさ、色、配置場所、などが挙げられる。

形容詞の意味に登録するには、これらの属性値を求めて言語情報とセットにして経験データに蓄える必要がある。このデータを獲得する行動には、物体の属性に関する形容詞の場合、第6章で述べた対象の局在性に基づく対象同定行動を利用する。この場合、未知語として使用された形容詞を使って質問確認行動を行なうのは不自然である。この形容詞に対応する視覚特徴を使用しない状態での発話行動を行なう事となる。これは6.4節で説明した、「登録されている語彙が不足している場合」に相当する発話行動となる。

対象物同定行動が成功した後に、ユーザが使用した形容詞と、物体の物理パラメータを対として、第4.4節で示したように Bayesian Network によるシンボルパラメータ間の表現に変

換する。

その時の対話風景を Figure 7.12 に、対話例を Table 7.13 に示す。




Figure 7.12: Pointing behavior in order to identify reference target using unknown word

Table 7.13: Example conversation when user instructs with unknown word

ユーザ	「黄色い箱を取って」(写真1)
ロボット	「黄色いという言葉は初めて聞きます」
	「赤い箱が見えます」
	「緑の箱が見えます」
	「名前の分からない色の箱が見えます」
	「黄色という色はこの事ですか？」(写真2)
ユーザ	「はいそうです」
ロボット	「分かりました。これが黄色という色ですね」

7.4.4 未知語への対応の限界点

以上に述べたような未知語への対応手法は、非常に対象領域が狭く、現在の時点では汎用的な自然言語処理への応用が難しい側面が残されている。

形容詞の場合には、単語が意味する物理世界での非言語情報は、視覚特徴パラメータ(数値)であった。これは単語シンボルと数値パターンの情報関係であるので、Bayesian Network による簡単な表現で記述する事ができたが、未知語が動詞だった場合には、問題は複雑にな

る。動詞が示すロボット行動は単なる数値データではなく、例えば関節角の時系列指令であったり、複数のプリミティブな行動の組合せであったりする。このようなロボットの行動を表現する手法はロボット言語の研究アプローチからも統一的な手法が提案されておらず、単なるロボットとの言語対話のみで、新しい動作を教示する事は難しい。

また、システムがまったく想定していなかった意味文法要素、すなわち対話に必要な新しい概念をユーザが使用した場合にも、対応する事ができていない。これは意味文法要素を導入した時点で抱えざるを得ない問題であり、新しい意味文法要素に必要な評価式(7.3.3節参照)は開発者サイドからシステムに追加する必要がある。しかしながら、意味文法要素をシステム追加する際に、よりユーザが分かりやすいインタフェースを実現する手法を生み出す事によって、この問題を回避する事が可能であると考えられる。

7.5 本章のまとめ

本章では、ユーザが与える自然言語を、実世界で行動するロボットの動作コマンドに変換するための手法について述べた。一般的な自然言語処理による対話システムを目指すのではなく、ロボットとの対話に限定した対話システムを目指し、ロボットに搭載されている機能、能力などに応じた意味文法要素を導入した。また、ユーザが使用する個人的な語彙に対応するために、ディクテーション機能を用いた未知語検出、構文解析部を利用した意味文法要素の種類の推定、を行ない、未知語と物理世界とのパラメータのバインディング問題を対話を通じて解決する手法について述べた。

本システムが対応できていない点としては、指示代名詞の使用ができない点、文法の構造や規則を獲得する事ができない点、が挙げられる。

「この」「その」「あの」などに代表される指示代名詞は日常会話で良く使用されており、ロボットとの自然なインタフェースを構築する上でも欠かせない言葉の一つである。しかしながら指示代名詞が参照している対象は、会話の文脈によって、時間的側面や空間的側面などが変化してしまう。それに加えて実際の物理的なボディを持つロボットにおいては、指示代名詞が使用された時のロボットの向きや人間とロボットの位置関係など、状況に応じて非常に複雑な解釈処理を必要とする場合が多い[今井 99]。

後者の文法規則の獲得については、自然言語研究の分野で精力的に研究が行われている問題ではあるが、実際の物理世界の情報とシンボルの情報を統一的に扱い、文法情報とセンサ情報の関連を同時に獲得する手法は、いまだ確立されていない問題である。中川らは視聴覚情報と言語情報を入力とする環境で、文法および概念を獲得するシステム[中川 95a]について研究を行っているが、この研究の中では視覚特徴パラメータが変動する事のない離散状態として扱われている。一方、本章で述べた手法では対話を通じて視覚特徴パラメータを表現する状態空間が変動する。対話を通じて概念や言語情報の獲得はこうに連続値の扱いが重要な問題を含むため、4.4節で述べたようなアプローチが重要なものになってくるものと考えられる。

第8章

ヒューマンロボットインタラクションシステム:PEXIS

8.1 はじめに

本章では、各章で論じた手法をソフトウェアシステムとして統合する手法について述べる。このシステムにより、各章で述べてきた、ロボットと人間との自然な対話の提供、対話経験からの学習、ユーザ個人への適応を行なうような、ヒューマンロボットインタラクションを実現する事を目的とする。

パーソナルロボットとして活動するロボットは、ヒューマノイド型のロボットや、移動ロボットなど、さまざまな種類、形態のロボットである。また、それらのロボットが行なうべき行動やタスクはロボットの形態や状況に応じて変動する。このような場合、それぞれのロボット、それぞれのタスクに対してユーザとのインタラクションを行なうシステムを個別に構築する事は非効率的である。このためロボットの形態、行なうべきタスクに依存しないインタラクションシステムを構築するためのAPI(Application Programming Interface)が必要となる。本章ではこのAPIを用いてユーザとのインタラクションを行なうロボットシステムを開発する手法について述べる。

8.2 人間とロボットとの対話を管理する機構

確率的経験表現に基づくヒューマンロボットインタラクションシステム: PEXIS (Probabilistic EXperience EXpression based human robot Interaction System) は家庭やオフィスなどの環境で、人間をサポート、サービスするロボットのための対話管理システムである [極色 99b]。

このシステムがもつ機能および特徴を以下に挙げる。

- 自然言語理解機能
- 知識管理機能
- 人間との対話機能
- データベース機能
- ロボットへの指令の生成

Figure 8.1 のように、このシステムはロボットとユーザの間に位置するインタフェースであり、ロボットの種類に依存しないソフトウェアの構造を持っている。

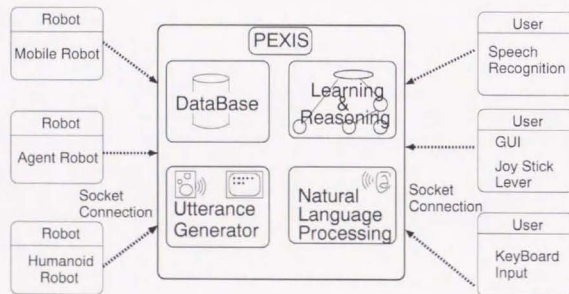


Figure 8.1: Configuration of PEXIS

8.2.1 自然言語処理

自然言語処理は、第7章で述べた通り、EusLisp上でインプリメントされており、PEXISとソケット通信を介して情報を交換する。ユーザから入力された言語情報は自然言語処理部に送信され、解析された結果、PEXISの挙動を決定する中間コードが生成され、PEXISはそのコードを元にロボットの行動を制御する。

8.2.2 短期的な記憶の管理

本節では、自然言語処理の結果、ユーザからの発話およびロボットからのセンサ情報に従って、現在の状況に関する知識を管理する行動について説明する。ここでの「知識」という表現が示しているものは、自然言語処理の結果得られた情報であり、文脈に依存する短期的な知識と、文脈に依存しない長期的な知識の二つを管理する。

短期的な知識管理サブシステムでは、

- 人物に関する知識
- 部屋に関する知識
- 配達をするものに関する知識
- 伝言に関する知識

を管理する事ができる。また、

- 時間に関する概念
- 場所に関する概念

の概念を管理する機能も持ち合わせているので、「いつ、誰が、何処で、何を、どうした」という知識を扱う事ができる。

これらの知識の基本構造は3つの要素からなるリストで構成されている。このリストの要素は、それぞれ属性名、オブジェクトID、属性値、からなっている。具体的には「人物」や「部屋」というそれぞれの知識概念を「オブジェクト」と呼ばれるもので表現し、そのオブジェクトの持っている属性値を管理する事によって、様々な概念や知識を管理する。

この概念は PEXIS Object と呼ばれ、第7章で述べた自然言語処理部において、Table 8.1 で示されるクラスで表現される。このクラスではその概念の種類 (is-a) と、オブジェクトに固有な名前 (name)、およびその属性を管理するサブクラスのインスタンスをスロットに持つ、Table 8.2 に使用している属性名とその属性値の組を示す。また、Table 8.3 に、ある人物 (inamura) からある人物 (hoshino) に対して荷物を運ぶ指令が出された場合の、タスク状況の内部表現を示す。

Table 8.1: Definition of PEXIS object class

```

(defclass pexis-object
  :super pexis-system
  :slots
    (
      (name :type symbol)
      (is-a :type symbol)
      location-object
      physical-object
    )
)

```

Table 8.2: Attribution list for PEXIS

属性名	属性値の例	作用
IS-A	person	人物を表す
	room	部屋を表す
	baggage	運ぶ物体を表す
NAME	room710	部屋の名前
	inamura	人物の名前

8.2.3 経験データベース機能

これらのリスト表現で管理されている知識を、時間の経過とともにすべて蓄積し、過去の状態における知識のデータベースを構築する機能も持ち合わせている。これは人間から過去に起こったできごとに関する質問を受けた場合や、情報が十分に得られていない状況において、過去の知識を用いて知識状態の曖昧性を解決する、という用途に使用される。

Table 8.3 で示した知識表現をその知識が得られた時刻とともにデータベースとして蓄積する。時刻の表現としては、日、時、分、秒、の4つの時刻を使用しており、数日間を渡って連続的に行動するロボットに対応する事ができる。

Table 8.3: Example of knowledge storage

```

#pexis-object998
  is-a = baggage
  from = #pexis-object1004
  to = #pexis-object1007
#pexis-object1007
  is-a = person
  name = hoshino
#pexis-object1004
  is-a = person
  name = inamura

```

Table 8.4: Example of interpreter code for PEXIS

コマンド名	引数	行動
GOTO	(部屋の名前)	指定の部屋まで移動する
LOOK	(方向)	指定の方向にカメラを向ける
TAKE	(指定の物体)	指定の物体を取る

8.2.4 ロボットへの指令の生成

実際にユーザからロボットに要求、指令が発行された場合、PEXIS はその自然言語をロボットが理解できる中間言語に翻訳し、その指令を伝える。中間言語は、各ロボットに共通の比較的上位レベルの行動を表現したものが使用されており、具体的には、以下のような中間言語が使用されている。

物を運ぶタスクにおいては、GOTO という中間言語のみが使用されている。ロボットはGOTO という中間言語によるコマンドを受けとった後に、そのコマンドの引数として、移動すべきゴールの部屋を名前を受けとる。ロボットは画像列によって管理されている地図表現から、この部屋の名前を検索し、指定の部屋に向かう。すなわち、この時点で PEXIS が管理している部屋の名前と画像列が管理している部屋の名前を一致させておく必要がある。理想的な形態としては、移動ロボットと PEXIS が通信を行ない、部屋名の自動管理を行なうべきであるが、現在はこの問題に対してはプログラミングのレベルで手動による名前の統制を取っている。

また、移動ロボットは部屋に到着すると PEXIS にその旨を報告し、PEXIS はその報告を

受けとった後に、次の行動をロボットに発行する。このように PEXIS と接続して行動するロボットは、中間言語を理解する機能とともに、PEXIS に報告を行ったり、PEXIS 内部に存在するデータベースの参照を行なうための中間言語を生成する機能を持ち合わせる必要がある。

8.2.5 Bayesian Network による推論部

蓄積された経験データの内部に存在する、概念間の因果関係を経験データから学習し、統計情報に基づく確率値を用いて表現する。この表現には Bayesian Network が用いられており、各概念はノードとして表現される。

ある程度の経験を積んだ後は、ネットワークの一部の情報（例えばロボットのセンサ情報）が得られただけで、残りのノードの状態（例えば取るべき行動）を推論する事ができる。この推論結果は確率変数として出力されるが、その確率値を推論の確信度として利用している。この結果、「その人物はどの部屋にいるか?」「このセンサ情報の場合どのような行動を行なうべきか?」などというロボットの行動決定を、確信の度合いを伴って出力する事ができる。十分確信の高い結論は接続されているロボットに送信され、ロボットが自律行動を行なうトリガとなる。

Bayesian Network の記述方法としては、Microsoft が提案している Bayesian Network 記述言語を採用している。この記述言語を用いると、Microsoft Belief Network と呼ばれるアプリケーションで容易に可視化を行ない、ユーザへの理解しやすい構造を提供する事ができる。また、条件付き確率テーブルや、確率変数の構成を GUI で簡単に変更する事が可能である。第3章での、障害物回避タスクにおけるこの記述言語の例を Table 8.5 に示す。また、Microsoft Belief Network による Bayesian Network の Edit 画面を Figure 8.2 に示す。




Figure 8.2: Visualization of Bayesian Network

Table 8.5: An example Bayesian Network representation in chapter 3

```

belief network "Avoidance Task with Parallax Information"
node Lever
{
  name: "Lever";
  type: discrete[4] =
  {
    "Forward",
    "Stop",
    "Left",
    "Right"
  };
  position = (150, 100);
}

node Parallax1
{
  name: "Parallax1";
  type: discrete[3] =
  {
    "Near",
    "Middle",
    "Far"
  };
  position = (50, 300);
}

.....
.....
node Parallax8
{
  name: "Parallax8";
  type: discrete[3] =
  {
    "Near",
    "Middle",
    "Far"
  };
  position = (400, 300);
}

probability(Lever)
{
  0.40, 0.10, 0.25, 0.25;
}

probability(Parallax1 | Lever)
{
  (0): 0.33, 0.33, 0.33;
  (1): 0.33, 0.33, 0.33;
  (2): 0.33, 0.33, 0.33;
  (3): 0.33, 0.33, 0.33;
}

.....
.....
probability(Parallax8 | Lever)
{
  (0): 0.00, 0.00, 0.00;
  (1): 0.33, 0.33, 0.33;
  (2): 0.33, 0.33, 0.33;
  (3): 0.33, 0.33, 0.33;
}

```

8.3 ユーザインタフェース

8.3.1 インタフェースデバイスのプラグイン機能

ロボットと対話するユーザは、インターネットを経由したネットワークロボティクスや、Webを通じてロボットをコントロールするなどに代表されるように、かならずしもロボットそのものに直接インタラクションするとは限らない。そのため、ユーザインタフェース部をロボットシステムに直接インプリメントせず、また、PEXISとも切り離してインプリメントする事とした。すなわち、ユーザインタフェース部はPEXISとは異なるマシン上で動作し、PEXISとソケットを用いて通信を行なう。これを PEXIS Terminal と呼ぶ。

PEXIS Terminal はユーザに自然なインタラクションを提供するために、音声認識や音声合成、キーボード入力、ジョイスティックレバーなど、数多くのモダリティ情報を扱う事を可能としている。しかしながらユーザが PEXIS Terminal を使用する状況は、そのユーザが使用するデバイスの種類や、ロボットとの対話の状況によって変化するものであり、すべてのインタフェースデバイスが必要であるとは限らない。そこで、各種のインタフェースデバイスをプラグインとして PEXIS Terminal に接続する形式を取った。

Figure 8.3 にユーザに提示される PEXIS Terminal の GUI を示す。




Figure 8.3: PEXIS Terminal

PEXIS Terminal は PEXIS に接続する際に、Terminal が起動しているマシン名、と PEXIS Terminal を使用しているユーザを報告する。PEXIS はこの情報を元にどのユーザがどのマシンを使用しているかを把握し、ある特定のユーザに対してメッセージを送る、などの機能を実現している。

以下では、各種のインタフェースデバイスについて説明する。

8.3.2 音声認識インタフェース

音声認識プラグインは、PEXIS Terminal から起動される一つのプロセスとして動作し、ソケット通信で PEXIS Terminal と情報を交換する。音声認識プラグインと PEXIS Terminal の通信にはプロトコルが定義されており、この手順に従ってさえいけば、マシンの OS や音声認識システムの種類によって使用制限が起こる事はない。実際には、電総研音声研究室で開発された音声認識システム (OS:Linux,Solaris), Entropic Cambridge Research Laboratory¹ の HTK(OS:Solaris), IBM の ViaVoice(OS:Windows)² などが使用可能になっている。音声認識によってユーザの発話がシンボルに変換されると、そのシンボルは第7章で説明した自然言語処理部に送られ、ロボットへの行動が生成される。

メインに使用しているシステムは電総研音声研究室で開発された音声認識システムである。この音声認識システムの仕様を Table 8.6 に示す。

Table 8.6: Specification of speech recognition system

標準化周波数	16[kHz]
分析区間長	25[ms]
分析周期	10[ms]
認識方法	離散分布型 HMM 方式
話者	男性の不定話者
HMM の単位	音韻単位 (43 音韻)
VQ コード	メルケプストラム係数
VQ コードブック	1024 コードワード
文法	無し
HMM 状態図	4 状態 6 ループ
単語認識率	98%
応答速度	100[ms] 以下
使用可能単語数	500 単語

¹<http://www.entropic.com/>, ついで先日 Microsoft に買収された

²<http://www.ibm.co.jp/voiceland/>, 英語版であれば Linux にも対応している

8.3.3 音声合成インタフェース

本システムでは、音声合成として、クリエイトシステム開発 (株)³製の、Linux 版音声合成ライブラリを使用している。このシステムは漢字混じりの日本語文章を表音文字に変換する辞書を約 14 万語搭載しており、自然なイントネーションで生成した日本語文章を音声として出力可能である。PEXIS から発話された文章は、このシステムで音声に変換され、PEXIS Terminal に送信される。

8.3.4 キーボードインタフェース

ユーザは音声による入出力だけでなく、キーボードによるタイピングでロボットと対話することができる。システムは双方の入力を区別なく同時に受け付ける事が可能であるので、ユーザは状況に応じてキーボードを使用したり、音声を用いたりすることができる。

8.3.5 ジョイスティックインタフェース

ロボットに対して行動を教示する場合、言語情報では表現する事が難しい状況もある。例えば移動ロボットを操縦する場合、「ちょっと右」や「しばらくまっすぐ」という言語による操縦よりは、ジョイスティックレバーのようなインタフェースが望ましい。ユーザは必要に応じてジョイスティックインタフェースを用いる事が可能である。物理的にジョイスティックを持たない端末の場合、マウスを用いてジョイスティックのエミュレーション環境を使用する事も可能である。

8.3.6 サーバクライアント形式による携帯端末の利用

ユーザインタフェースを管理するプロセスはサーバクライアント形式で PEXIS と通信するため、ネットワーク上に接続されていれば、ユーザはどのようなシステム上からもロボットにアクセス可能になる。携帯端末において無線 LAN を使用しているシステムであれば、ユーザは場所に限定されることなくロボットとの対話を行なう事が可能である。

実際に、Figure 8.4 のような携帯型のモバイルコンピュータ上に PEXIS のユーザインタフェースを構築している。このシステムは音声入力デバイスを保有しており、音声による対話が可能である。

³<http://www.createsystem.co.jp/>



Figure 8.4: PEXIS interface on a mobile computer

8.4 ロボットと PEXIS との接続環境

8.4.1 PEXIS とロボットの通信プロトコル

現在、ロボットが行動するためのシステムには数多くの種類があり、OSとしてはLinux, SolarisなどのUNIX系OS,あるいはWindowsや、小規模なロボットに使用されるH8シリーズなどの、マイクロチップ系も多い。プログラミング言語の側面から見ると、C言語, EusLispなどのLisp系など、多くの種類が存在する。パーソナルロボットは様々な形態が想定されるので、PEXISに限られたOS,言語にのみ対応する事はできない。そのため文字列による通信プロトコルを定め、あらゆるOS,あらゆる言語におけるロボットシステムに対応可能な構成とした。このような文字列通信によるプロトコルは、分散オブジェクト環境を提供する言語CORBAなどでも採用されており、汎用性の高いプロトコルであると言える。欠点としては送信データが冗長となる点であるが、画像処理や音声処理などのリアルタイム性が求められる処理ではなく、ユーザとの対話という比較的レスポンスに急性性が求められない部分があるので、問題はない。

PEXISの果たす役割は大きく分けて、ユーザとの対話、経験の管理、推論の実行が挙げられる。通信を行なう際、ロボットはソケットを用いてPEXISと接続するが、対話のようにロボットが期待していないタイミングで情報が流れてくる通信路と、推論の実行のようにロボットが期待しているタイミングで情報が流れて来る通信路を同一にすると、支障が生じる。そこで、Figure 8.5のように対話用の通信路、推論の制御のための通信路、経験の管理などリアルタイム性の求められないコマンドの通信路、の3つの通信路を設ける事とした。現在の所通信路を管理するライブラリ層には、C言語とEusLispがインプリメントされている。ロボットはどちらかのライブラリを使用してPEXISとの通信を行なう。以下にその3つの通信路で送受信されるプロトコルについて説明する。

8.4.2 システム基本プロトコル

システム制御のために使用されるコマンド群を以下に説明する。

PEXISQueryNodeInfo

Bayesian Networkの特定のノードに対して、その確率変数の内容、親ノード、子ノードとの関係、確率変数と対応する生データの構造など、ノードに含まれる情報を参照する関数。ロボット側のプログラムでは、このノード情報を参考にして、ノードに入力可能なデータを生成する事になる。




Figure 8.5: Three connection path between robots and the PEXIS

PEXISQueryStateInfo

あるノードに割り振られている確率変数のうち、特定の状態値に対して、詳細情報を参照する関数。例えば色の名前のノードであれば、具体的な色名や、Hue と Saturation などの視覚特徴パラメータの範囲などを参照できる。

PEXISAddNewState

あるノードに対して新しい状態値を増設し、確率変数を更新させるために使用する。確率変数の更新だけでなく、経験データから得られる条件付き確率テーブルも変更を行う。さらに連続値の生データを扱うノードであれば、連続値と確率変数の各状態値の対応関係を初期化する関数のトリガともなる。

PEXISReadingReference

ロボットシステムの中ではシンボルはすべてアルファベットで表現されているが、日本語で表示を行ったり、音声発話を行うためには日本語表記のデータが必要になる。この関数は第7章で述べた自然言語処理プロセスとの通信を行い、アルファベット表記のシンボルを日本語表記のシンボルに変換する。

PEXISQueryMutualInformation

特定の二つのノード間の、相互情報量⁴を求める。ロボット側のプログラムでは、この相互情報量を参考にして、ノード間のリンクを張るべきか、張らないべきかを判断する。

⁴第4章を参照の事

PEXISQueryTerminalState

ジョイスティックレバーや、GUI のボタンなど、ユーザインタフェースサイドに存在する各種の情報を参照する。ロボット側のプログラムでは、この情報を元にロボットの操縦コマンドを生成したり、行動をトリガする。

8.4.3 対話プロトコル

ユーザとの対話の制御のために使用されるコマンドを以下に説明する。

PEXISDisplayToUser

指定したメッセージを Figure 8.3 のようなユーザインタフェースターミナルに表示する。特定のユーザだけに対するメッセージ通信も可能。

PEXISSpeakToUser

指定したメッセージを、音声合成を用いて指定したユーザに対して発話する。

PEXISSpeakToHost

指定したメッセージを、音声合成を用いて指定したホストマシン上で発話する。特定のユーザとの発話ではなく、ロボットの近辺にいる不特定多数のユーザへの発話などに使用される。

PEXISGetUserInput

ロボットがユーザに質問をする時など、ロボットが主導権を握って会話を進める時に用いる。結果としてユーザが話した内容が送られて来る。

8.4.4 推論プロトコル

システムに対して推論を行なうための主なコマンドを以下に説明する。

PEXISMakeBayesianNetwork

使用する Bayesian Network を PEXIS に報告し、初期化を行う。同時に複数の Bayesian Network を登録可能である。複数の Bayesian Network に対して重複したノード名が存在しない限り、ノード名だけで目的の Bayesian Network を参照する事が可能である。

PEXISInputDiscreteEvidence

観測されたデータを Bayesian Network のノードに入力する。ただしそのデータは確率変数を直接指定して入力するものとする。

PEXISInputContinuativeEvidence

観測された生データを Bayesian Network のノードに入力する。確率変数に対応する状態を入力するのではなく、単に生データを入力するのが、上記の関数とは異なる。

PEXISExecuteDiscrete

上記の関数で入力された生データを離散化して、ノードに割り振られている状態変数の各状態に対応付ける。通常、上記関数と対の形で実行され、連続値を取るセンサデータの入力に使用される。

PEXISInputUncertainData

何も観測されていない場合に、「状態が不明」である情報を Bayesian Network のノードに入力する。第3章で述べたような、センサが機能していない状態や、第5章で述べた、観測できない情報が存在する場合などに使用する。

PEXISQueryReasoningVector

推論のターゲットとなるノードを指定し、推論を行なった結果を要求する。推論の結果は確率変数の値であり、確信度のベクトルである。

PEXISQueryDecision

第3章での行動決定や、第6章での局在性のチェックなど、上記関数で得られた確信度ベクトルを使って、一番確信度が高い状態を自動的に選択する。もし確信度が同等な状態が複数あった場合には、それらの状態値が同等である事を報告する。

8.5 経験の蓄積と学習の機能

8.5.1 経験データの標準化

本システムにおける経験の取り扱いには Bayesian Network によるものである。ロボットが学習を行なう際に必要となる経験データは、使用される Bayesian Network の各ノードがどのような状態を取るか、というデータとなる。しかしながら、第4章のユーザへの個人化や、第5章のような環境条件の変動などに伴い、Bayesian Network は動的に変化する事が多い。そのため、Bayesian Network の各ノードに関する状態値のみを蓄積している場合、Bayesian Network が変動してしまうと全く意味のない経験データとなってしまう。

Bayesian Network の各ノードの状態値を決定するプロセスは、例えば連続値の離散化によるものであったり、人物を特定するための画像処理であったりする。すなわち、ロボットが各センサから入力したパターン情報をシンボル化したものが Bayesian Network の学習に必要なデータである。ここでシンボル情報を経験として蓄積する事によって前述した問題が発生するので、シンボル情報ではなく、パターン情報を経験とすることが妥当となる。つまり、なるべくセンサ情報を「生」の状態でも保存することが望ましい事になる。

このように、経験データには2段階の階層が必要となるので、より「生」の状態に近い第一段階と、Bayesian Network のノードに入力される第二段階のデータに区分する。ここで、第一段階の経験データを RDD(Robot Depended Data) 形式と表現し、第二段階の経験データを PRD(Pexis Raw Data) 形式と表現する。ロボットはまず RDD 形式でユーザとのインタラクションの経験を蓄積し、RDD 形式から PRD 形式に変換を行なう。そして PRD 形式の経験データを用いて Bayesian Network を学習させる。

第一段階の RDD 形式では、その名が示す通り、各ロボットの形態に応じた「生」のデータを保存する。データにはセンサの種類や、その他経験データを操作するために必要となる情報を埋め込む。第3章で説明した障害物回避タスクにおける RDD 形式データの例を Table 8.7 に示す。

各項目の内容は以下の通りである。

:lever

ユーザが教示したレバー操作の値。二つの整数値がそれぞれジョイスティックの x 座標、y 座標を表す

:parallax

ロボットが獲得したステレオ視覚による視差情報。実際には32個の整数値から成り、画面全体に分布する視差情報を表現する。

Table 8.7: Example of RDD-form data

```
# :bayesian-network-name avoid
:prob 100 0 0 0 :lever 0 90
:parallax 67 70 70 80 81 90 98 107 .... 108 99 90 82 80 70 70 67
:prob 100 0 0 0 :lever 0 90
:parallax 67 70 70 80 81 90 98 107 .... 108 99 90 82 80 70 70 67
:prob 33 0 0 66 :lever 80 0
:parallax 70 70 80 80 90 97 106 112 .... 100 90 82 80 70 70 66 60
:prob 47 0 2 0 :lever 0 -3
:parallax 80 80 71 70 70 70 70 .... 85 80 71 70 63 60 60 58
:prob 47 0 2 0 :lever 0 -3
:parallax 80 80 71 70 70 70 70 .... 85 80 71 70 63 60 60 58
:prob 100 0 0 0 :lever 0 73
:parallax 72 66 60 60 60 60 60 .... 85 80 70 70 60 60 60 55
:prob 8 0 91 0 :lever -80 0
:parallax 30 65 97 102 111 122 136 154 .... 77 70 65 60 60 53 50 50
```

:prob

インタラクションが行なわれた時の行動決定の確信度。この値を参考にしてユーザの指示とロボットの推論結果の差異を算出する

一方、この RDD 形式の経験データを PRD に変換処理した結果のデータを Table 8.8 に示す。

この変換で、32 個の整数値で表現されていたセンサ値を平滑化し、Bayesian Network に存在するノード数である 8 個に合わせている。また、レバーの値は x 座標、y 座標の値から、局座標表現に変換されている。

PRD 形式で表現されているデータから、最終的にノードの状態値を決定するのは連続値の離散化で行なう。各ノードには離散化を行なう戦略が割り当てられており、この戦略に従って PRD 形式の経験データは Bayesian Network の状態値へと変換される。Bayesian Network の構造を変更する際には、この離散化戦略も構造の一部と見なし、変更対象の一部となる。実際に使用している離散化戦略の例を Table 8.9 (センサノード :Parallax の離散化) と Table 8.10 (レバーの状態 :Lever) に示す。

8.5.2 経験管理プロトコル

システムに対してロボットが経験したデータを報告し、経験データベースに蓄積するための制御は、以下のコマンドによって実現されている。

Table 8.8: Example of PRD-form data

```
:Lever 67 90
:Parallax1 71 :Parallax2 94 :Parallax3 124 :Parallax4 175
:Parallax5 242 :Parallax6 157 :Parallax7 94 :Parallax8 71
:Lever 62 90
:Parallax1 71 :Parallax2 94 :Parallax3 121 :Parallax4 177
:Parallax5 238 :Parallax6 167 :Parallax7 94 :Parallax8 71
:Lever 80 0
:Parallax1 71 :Parallax2 94 :Parallax3 107 :Parallax4 175
:Parallax5 233 :Parallax6 157 :Parallax7 94 :Parallax8 71
:Lever 80 90
:Parallax1 75 :Parallax2 70 :Parallax3 112 :Parallax4 255
:Parallax5 184 :Parallax6 115 :Parallax7 76 :Parallax8 60
:Lever 80 90
:Parallax1 75 :Parallax2 70 :Parallax3 112 :Parallax4 255
:Parallax5 184 :Parallax6 115 :Parallax7 76 :Parallax8 60
:Lever 73 90
:Parallax1 64 :Parallax2 60 :Parallax3 127 :Parallax4 255
:Parallax5 179 :Parallax6 113 :Parallax7 76 :Parallax8 58
:Lever 80 180
:Parallax1 73 :Parallax2 130 :Parallax3 211 :Parallax4 245
:Parallax5 147 :Parallax6 102 :Parallax7 68 :Parallax8 53
```

PEXISOpenRddFile

指定された経験データベースファイルを読み込む

PEXISStoreRddLine

現在の経験データをデータベースファイルに追加する

PEXISCloseRddFile

指定された経験データベースファイルを保存する

PEXISCptRevisionOnline

最新の経験データを用いて、Bayesian Network の条件付き確率値テーブルを更新する

Table 8.9: definition of division strategy for sensor node

# Number of State				
3				
# Parameter Dimension				
1				
# State No.&Value	min	max	mean	
0	0	-1	33	15
1	1	33	61	45
2	2	61	1000	100

Table 8.10: definition of division strategy for behavior node

# Number of State						
6						
# Parameter Dimension						
2						
# State No.&Value	min	max	mean	min	max	mean
0	0	-1	20	10	-1	361
1	1	20	120	70	45	135
2	2	20	120	70	225	315
3	3	20	120	70	135	225
4	4	20	120	70	-1	45
5	5	20	120	70	315	360

8.6 総合実験

8.6.1 荷物配達タスクへの応用

この PEXIS を利用して、移動ロボットに対して、特定の物体を特定の人物に届ける、という行動を実現させる [中 99]。具体例として Table 8.11 のような会話がなされた時の PEXIS 内部の動作を説明する。

Table 8.11: Example of conversation during delivery task

ユーザ 「私の名前は A です」
 ロボット 「分かりました。A さんですね、御要件は何ですか」
 ユーザ 「荷物の配達をお願いします」
 ロボット 「どなたにお運びしましょうか」
 ユーザ 「B さんの所までお願いします。」
 ロボット 「分かりました。B さんはどこにいますか」
 ユーザ 「B さんは C 号室にいます」
 ロボット 「分かりました。荷物を置いて下さい」
 (ユーザが荷物を置く)
 ユーザ 「置きました。伝言をお願いします」
 ロボット 「分かりました。では伝言をお願いします」
 (ユーザが伝言を録音する)
 ロボット 「それでは配達を開始します」
 (ロボット移動開始。C 号室に到着)
 ロボット 「B さん、荷物を届けに来ました」
 (B が荷物を受けとる)
 ロボット 「A さんからの伝言があります」
 (伝言を再生する)

まず最初の会話で人物に関するオブジェクトが生成され、その名前として“A”が登録される。この段階で、


```
#pexis-object1007
is-a = person
name = A
```

という知識が生成される。次の発話でロボットは荷物の配達を要求される。PEXIS 内部で荷物に関するオブジェクトが生成され、差し出し人として A が登録される。受けとり人に関する発話をユーザがしなかったため、この時点で PEXIS はユーザに対して受けとり人に関する質問を行なう。

```
#pexis-object1007
is-a = person
name = A
#pexis-object1008
is-a = baggage
from = #pexis-object1007
to = #pexis-object1009
#pexis-object1009
is-a = person
name = B
```

しかし、PEXIS 内部に、B という人物に関する情報が欠けており、どの部屋にいるかが分からない。そこでロボットは B がどの部屋にいるのかを、ユーザ A に対して質問する。

```
#pexis-object1007
is-a = person
name = A
#pexis-object1008
is-a = baggage
from = #pexis-object1007
to = #pexis-object1009
#pexis-object1009
is-a = person
name = B
location = #pexis-object1010
#pexis-object1010
is-a = room
name = C
```

同様にして、伝言に関するオブジェクト

```
#pexis-object1011
is-a = message
from = #pexis-object1007
to = #pexis-object1009
```

も生成される。これまでの手順の結果、B の場所が分かったので、PEXIS は移動ロボットに対して中間言語 GOTO C を発行し、移動が終了するのを待つ。画像列による部屋間の移

動が終了すると、移動ロボットは PEXIS に到着した事を伝え、PEXIS はユーザ B に対して発話を行なう。

8.6.2 携帯型ユーザインタフェースの活用

ここでは、8.3.6節で示したモバイルコンピュータを用いた PEXIS の使用について実験例を示す。

実験を行なった状況は、モバイルコンピュータを持ったユーザがロボットを呼び出し、荷物の運搬を依頼する p₁ というものである。実験風景を Figure 8.6, Figure 8.6 に、その時の会話結果を Table 8.12, Table 8.13 に示す。

この実験例では、モバイルコンピュータを持つユーザがいる位置を、ロボットが知る事ができないために、「あなたはどこにいるのですか?」という質問を投げかけているが、例えば GPS モジュールや、カメラデバイスを持つモバイルコンピュータであれば、それらの情報から位置を認識して、自動的にロボットがユーザの元に移動する、という事も可能であると考えられる。




Figure 8.6: Interaction using mobile interface unit (1)

Table 8.12: Dialogue with mobile interface unit (1)

ユーザ 「ここまで来て」 (写真1)
 ロボット 「あなたはどこにいますか？」
 ユーザ 「エレベータホール前です」
 ロボット 「分かりました」 (写真2)
 ロボット 「御用件は何でしょうか？」 (写真4)

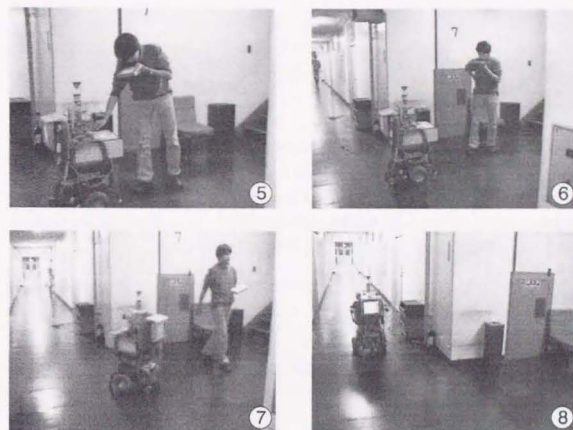


Figure 8.7: Interaction using mobile interface unit (2)

Table 8.13: Dialogue with mobile interface unit (2)

ユーザ 「これをしまっておいて」 (写真5)
 ロボット 「分かりました」
 ユーザ 「僕は帰ります」 (写真6)
 ロボット 「さようなら」 (写真7)
 (ロボット元の部屋まで戻る) (写真8)

8.6.3 PEXIS の複数ロボット間対話への応用

ここでは、PEXIS が持つ、ユーザとロボットの間のインタラクション環境を、ロボットとロボットの間のインタラクションに応用する事を提案する。今までの実験でしばしば登場したが、ロボットが自分自身で解決できない場合は、ユーザに対する質問行動や依頼行動を行なっている。この際、質問や依頼を行なうロボットの側からすると、問題解決を自分以外の「エージェント」に託しているだけであって、相手が人間であっても、ロボットであっても一向に構わない。そこで、ユーザに対する質問行動や、依頼行動を行なう場合に、自分自身が PEXIS に対するユーザとして振舞い、PEXIS に接続されている他のロボットへ発話を行なう。ロボットシステムの開発の側面からは、Figure 8.8 のように、ソケット通信による接続をロボット側とユーザ側の双方に開設すれば良いだけなので、ソフトウェアの変更を最小限に抑えながら、複数のロボット同士の対話環境を実現する事が可能となる。




Figure 8.8: Block diagram of interaction between plural robots

ロボット同士の対話例として、次のような実験を行なった。状況としては、ユーザが移動ロボット(ロボットM)に対して荷物を運んで来るように指示をするが、移動ロボットはマニピレータを持っていないために、ヒューマノイドロボット(ロボットH)に依頼行動を行なう。ユーザとロボット、ロボット同士の会話例を Table 8.15 に、その時の実験風景を Figure 8.10 に示す。




Figure 8.9: Interaction between a user and a mobile robot

Table 8.14: Dialogue between a mobile robot and a user

ユーザ	「隣の部屋の黄色い箱を取って来て」(写真1)
ロボットM	「分かりました」(写真2)
ロボットM	「その黄色い箱を取って下さい」(写真4)




Figure 8.10: Interaction between two robots

Table 8.15: Dialogue between the mobile robot and a humanoid robot

ロボットM「その黄色い箱を取って下さい」(写真5)
 ロボットH「わかりました」
 (ロボットH、ロボットMの台に箱を置く)(写真7)
 ロボットH「置きましたよ」(写真8)



Figure 8.11: After receiving the target box from the humanoid

Table 8.16: Dialogue after receiving the target box

ロボットM「ありがとうございました」写真9
 ロボットM「元の部屋に戻ります」写真10
 ユーザ 「どうもありがとう」写真12

8.7 本章のまとめ

本章では、第3章から第7章にかけて述べたように、パーソナルロボットに必要となる、対話に基づく行動知能の形成を実現する機構を、ソフトウェアの側面から考察し、必要となる要素をシステムとしてインプリメントするための構成法について述べた。複数のロボットで共通の経験や知識を共有するために、ロボットの本体に経験を置かず、知識と経験を管理するサーバーを構成し、複数のロボットと複数のユーザとの間のインタラクションを行なうヒューマンロボットインタラクションシステム:PEXISを実現した。サーバである PEXIS に対して、ロボットやユーザがクライアントとして接続する形式を取る事により、ユーザはネットワーク経由で携帯端末から場所を限定される事なくロボットとのインタラクションを行なう事が可能となり、また、ロボットもプログラミング言語や OS の種類に依存せずに PEXIS を使用する事が可能となった。また、ユーザとロボットとの対話環境を活用して、複数のロボット同士が対話を行なう手法についても述べた。

このようなパーソナルロボットと人間の対話のためのソフトウェア的なプラットフォームは存在しておらず、パーソナルコンピュータの上で GUI が発達したように、パーソナルロボットの上での対話環境の基礎が築かれる事が望まれる。

第9章

結論と今後の展望

9.1 本論文の結論

9.1.1 人間との対話に基づくロボットの行動知能形成手法

第2章「人間との対話に基づくロボットの行動知能形成」では、HRI(Human-Robot Interaction)の研究の難しさが、単なるロボティクスと、HCI(Human-Computer Interaction)の要素技術の統合では達成できない事にある事を述べ、人間、ロボット、実環境の3者を有機的に結合する、ロボットの行動決定モデルの重要性について述べた。そしてそのような行動決定モデルを実現するためのアプローチとして、Bayesian Networkによる表現を導入し、そのモデルの構築に、ユーザとロボットの対話に応用する概念を提案した。

9.1.2 ユーザとの対話に基づく行動知能の後天的形成

第3章「対話経験の蓄積に基づく自律行動の獲得」では、パーソナルロボットにとって必要となる自律行動学習において、ユーザの意思を反映した学習を行なわせるための教示手法を提案した。この教示手法の中では、Bayesian Networkを用いて経験を表現し、経験を利用した行動生成、教示情報の経験への蓄積を行なう。このような確率的な経験表現を用いる事によって、ロボットの知識が無い初期段階ではユーザ主導の教示による行動獲得、ある程度経験を獲得した後はロボットの自律的な判断による行動生成と学習の促進が可能となった。また、この教示フェーズと自律学習フェーズの境界を無くし、常に半教示フェーズ、半自律フェーズで行動する行動決定モデルを構築した。ユーザに使用される事を前提としたロボットは、このようなハイブリッドな行動獲得手法が求められ、その具体例として障害物を回避する移動ロボットにおいて、効果的な学習が可能である事を示した。

第4章「対話経験の蓄積に基づくユーザへの適応化」では、ユーザの個人的な嗜好や習慣に応じてロボットが行動を適応させるための手法について述べた。このパーソナリ化の問題は、第3章におけるBayesian Networkによる行動決定モデルの構成問題に帰着できる事を示し、状態空間の構成を行なう評価基準を導入した。二つの評価基準として、ネットワークの構造の変動が過去の対話経験に与える矛盾性に注目し、推論のエラー値という基準を設けた。この基準により過去のユーザとの対話経験を再利用し、オフラインでユーザに適応したネットワークの状態空間を構成した。二つの評価基準として、確率モデルが持つ相互情報量に注目し、事象間の相関関係を相互情報量で評価する手法を提案した。この手法により、必要十分な量のネットワーク構造を構成し、状態空間を形成可能である事を示した。これらの手法は状態空間が変化しても学習のための行動を初めからやり直す必要は無く、経験データを用いた数値計算のみでユーザへの適応を行なう事ができる利点を持つ事を示した。

第5章「対話と自律行動に基づく環境知識の獲得」では、ロボットのための行動知能の一部として、オフィスや家庭などの日常空間でユーザと共に活動する事を前提とした、環境知識の表現方法および獲得方法について述べた。環境知識は主に地図情報と人間の活動情報の二つから構成される。

前者の地図情報に関しては、ビューシーケンスによる地図の表現手法を述べ、移動ロボットにおける自律的な地図の獲得、対話に基づく部屋の名前の獲得、などの環境知識の獲得行動を実現した。

後者の人間の活動情報に関しては、まず、視覚情報による人間像の観察処理について述べ、次に Bayesian Network による人物と場所と時刻に関する知識表現を提案した。固定的な表現では実環境の変動を表現する事が難しかったが、本手法の統計的な知識表現では、確率を用いて環境の情報を表現する事が可能であり、完全に正しい情報ではなく、実際の行動に十分適用可能な程度の環境知識を扱う事が可能であることを確かめた。

また、ユーザとの対話の結果を経験として蓄積し、Bayesian Network を学習させる事により、全く無知の状態から徐々に環境知識を獲得する手法について述べた。このような対話に基づく環境知識の獲得手法は、あらかじめ使用される環境についての知識を埋め込む事のできないパーソナルロボットにとって必要不可欠な機能であり、実験を通じてその有効性を示した。

9.1.3 パーソナルロボットとの対話を実現する基盤システム

第6章「対象の局在性に基づく適切な対話の生成」では、ユーザの曖昧な指示や、センサ能力の不足、視覚処理における不良設定問題など、実世界で行動するロボットにとって生じる数々の情報の不足を、ユーザとの対話で解決するアプローチの重要性を示し、そのアプローチを実現するためのキーとして対象の局在性という概念を提案した。この局在性を利用して、ユーザが指示を出した参照物体と、ロボットが目目している物体の同一性を検証する手法と、ユーザの使用する視覚特徴表現によって局在性を評価する手法を導入した。これらの評価基準を用いて、局在性を満たすような視覚特徴表現を逆に求める事によって、適切な発話を生成する事を可能とした。さらに、言語による表現だけでは曖昧性が解決できない場合に、実際にロボットが指差し行動を行なう事で問題解決する手法、ロボットがユーザに提案や依頼を行なう手法を実現した。

第7章「言語情報と行動知能との結合関係の獲得」では、ユーザが与える自然言語を、実世界で行動するロボットの動作コマンドに変換するための手法について述べた。一般的な自然言語処理による対話システムを目指すのではなく、ロボットとの対話に限定した対話システムを目指し、ロボットに搭載されている機能、能力などに応じた意味文法要素を導入した。ま

た、ユーザが使用する個人的な語彙に対応するために、ディクテーション機能を用いた未知語検出、構文解析部を利用した意味文法要素の種類の推定、を行ない、未知語と物理世界とのパラメータのバインディング問題を対話を通じて解決する手法について述べた。

第8章「ヒューマンロボットインタラクションシステム:PEXIS」では、第3章から第7章にかけて述べたように、パーソナルロボットに必要な、対話に基づく行動知能の形成を実現する機構を、ソフトウェアの側面から考察し、必要となる要素をシステムとしてインプリメントするための構成法について述べた。複数のロボットで共通の経験や知識を共有するために、ロボットの本体に経験を置かず、知識と経験を管理するサーバーを構成し、複数のロボットと複数のユーザとの間のインタラクションを行なうヒューマンロボットインタラクションシステム:PEXISを実現した。サーバである PEXIS に対して、ロボットやユーザがクライアントとして接続する形式を取る事により、ユーザはネットワーク経由で携帯端末から場所を限定されることなくロボットとのインタラクションを行なう事が可能となり、また、ロボットもプログラミング言語や OS の種類に依存せずに PEXIS を使用する事が可能となった。また、ユーザとロボットとの対話環境を活用して、複数のロボット同士が対話を行なう手法についても述べた。

9.2 課題点と今後の展望

9.2.1 言語獲得研究への展望

第7章で述べた自然言語処理は、シンボルレベルで盛んに研究されている自然言語処理と比べるとその機能は非常にシンプルなものであり、意味文法要素の増加や、文脈を考慮した曖昧性の解消など、インプリメントの側面からは課題が多く残っている。

一方、未知語を検出し、その意味を物理世界とのインタラクションを介して獲得する手法については、シンボルレベルのみの典型的な研究例から多少外れる問題であり、今後の研究の進化が期待される領域の一つである。本研究における統計処理に基づくシンボラグラウンディング手法は、言語と概念を結合する際に教師なし学習を実現できる特徴を持つ手段である。そのため、統計情報を用いて言語が持つ実世界上での意味を獲得する研究[鈍見 98, 鈍見 92]や、単語の概念の獲得に関する研究などへの応用が可能であると考えている。

また、HCIの分野では、ユーザと自然な対話を重ねながらその中から経験的に言語を獲得する手法が提案されている[Kobayashi 96]。自然言語処理の難しさとして、言語を使用しているユーザが暗黙のうちに持っている背景知識をいかに反映するか、という事がある。第4章で述べたような語彙の意味をユーザ個人に適応して変動させるような処理を行なう事によって、ユーザとシステムが背景知識を共有する事となり、より知的な自然言語インタフェースを構築できると考える。今後の自然言語処理が向かいつつある方向の一つとして、利用者の知識をシステムが取り込むような形態が提案されており[村木 96]、本研究の枠組はこの流れに合致したものであると言える。

ロボットを用いた言語の獲得は、人間の幼児が行なっている行動を介した言語獲得の機構を解明するという観点からも、今後注目される研究領域になるとと言える。

9.2.2 人間機械協調システムへの展望

第3章で述べた行動決定モデルは、例えばITSなどの自動運転システムへの応用が考えられる。実際に、カリフォルニア州のITSプロジェクトであるPATH(Partners for Advanced Transit and Highways)の中でRussellsらはBAT(Bayesian Automated Taxi)プロジェクト[Forbes 95]を展開しており、確率モデルによる自動運転システムの可能性が示唆されている。しかしながらこの確率モデルは設計者があらかじめシステムに組み込む事を前提としており、ユーザの存在はまったく無視されている。これに本論文で示したユーザとのインタラクションモデルを適用する事で、ユーザの運転を観察しながらモデルを構築し、個人個人の運転に最適なモデルを経験的に獲得する事が可能である。

現実問題として、自律運転システムの実現には法整備やインフラストラクチャの問題などが山積みとなっているが、運転をサポートする事を前提とした運転補助システムへの応用を考える事は容易である。実際にカーナビゲーションシステムにおける音声対話の研究は数多くなされており[有田 95, 伊藤 93]、単なるナビゲーションのための対話システムから、学習する対話システムへと進化することは必然的動向といえる。このように、運転サポートシステムは、タスク領域がある程度限定されており、実環境において活動するロボットのための対話システムのテストベッドとして、大きな期待を有する応用範囲であると言える。

9.2.3 日常空間に進出するロボットへの展望

日常空間に進出するロボットは「パーソナルロボット」という枠組として本論文で扱ってきた。ユーザとのインタラクションを前提として行動するパーソナルロボットでは、本論文で示した対話に基づく行動知能形成モデルは非常に重要なものになると予想される。現在パーソナルロボットは産業界からも実現可能なものとして注目されており、SONYのAIBO、NECのR100、松下電気のペットロボットなど、ユーザとのインタラクションを前提としたエンタテインメントロボットが続々と登場してきている。しかしながらそのどれもがコンセプト的な製品に留まっており、どの程度のインタラクションや行動の発達機構を組み込めるかは未知数である。本論文の第8章で示したインタラクションシステムPEXISはこのような既存のロボットシステムにおいて使用する事を目標として設計されているシステムであり、現在のハードウェアとしてのパーソナルロボットに続いて、パーソナルロボットのためのソフトウェアが追従する事ができれば、エンタテインメント空間から、日常空間への進出が可能になると考える。

9.2.4 脳の情報処理システムへの展望

本論文で使用したBayesian Networkはニューラルネットワークと非常に似た性質を持ち合わせており、NealはボルツマンマシンはBayesian Networkの特別なケースである事を示している[Neal 92]。そのため、ニューラルネットワークの学習で用いられている勾配降下法をBayesian Networkの学習に応用する様々な手法も提案されている[Russel 97, 本村 97, Motomura 97]。ニューラルネットワークによる行動知能の表現は、簡単にはユーザや開発者に理解できない点の問題である事を既に述べた通り、ニューラルネットワークとBayesian Networkの明確な差は、ニューラルネットワークには意味論を持つ命題との関連が全く存在しない点である。これを逆に考えると、ニューラルネットワークとの類似性があるBayesian Networkは、脳の情報処理システムを工学的に実現するアプローチ[川人 96]に、新しい「意味」や「状態」という側面を付加させる可能性がある事を示唆していると言える。実際に、ブレインサイ

エンスの側面からは、ある場所に移動すると発火する「場所ニューロン」や、特定の物体を見ると発火する「おばあさん細胞」などの現象が報告されている事は有名であり[立花 96]、大脳皮質における教師なし学習では、環境情報や行動などが離散的な「状態」として扱われ、それらの間の統計的な表現が獲得されているとする主張もある[Doya 99]。

本論文では、このような脳の情報処理への応用を行う具体的な方法論にまでは言及できないが、今後の研究の方向として十分期待できる側面を持つと考える。

謝辞

本研究は東京大学大学院工学系研究科情報工学専攻の井上博允教授の御指導のもとで行なわれました。

井上博允教授には、なかなか研究の進まない筆者を暖かく見守って下さり、御指導して頂きました。また、新しい計画への挑戦も快く受け入れて頂き、筆者を精神的に非常に心強く支えて頂きました。研究成果が出ず、失敗につながってしまった計画の事で悩んでいた時期にも、前向きに次の研究に対して取り組む方向に導いて頂きました。日本学術振興会の特別研究員として博士課程の研究を進めてこられたのも井上先生のおかげです。先生の叱咤激励のおかげでようやく本論文を完成できたと言っても過言ではありません。大変感謝致します。

稲葉雅幸助教授（東京大学大学院工学系研究科情報工学専攻）には、ソフトウェアの構築の上で非常に有効なコメントを沢山頂きました。自分ではなかなか気が付くことのできなかったポイントを鋭く指摘して頂く事が何度もあり、システムを構築していく上で、また研究者としての姿勢など多くの事を学びました。大変お世話になりました。

田中英彦教授（東京大学大学院工学系研究科情報工学専攻）、武市正人教授（同専攻）、中村仁彦教授（東京大学大学院工学系研究科機械情報工学専攻）には、本論文をまとめるにあたって非常に有意義なご意見を頂きました。大変感謝しております。

藤田技官、戸塚技官、大澤さん、千代延さんには研究を進めるにあたっての備品の購入などに御協力頂きました。数多くの雑務から学生を守って頂き大変感謝しております。

過去にハイパースクータープロジェクトでお世話になった柴田さんからは、非常に多くのものを学びました。本論文のテーマである、パーソナルロボットにおける人間とロボットの対話は、柴田さんとの議論の中で生まれたものであり、第6章で登場した局在性という概念も柴田さんのアイデアです。研究をする事の面白さ、研究をする事の厳しさ、博士課程に進学する事を決意したのも、柴田さんの研究を楽しむ姿に接する事ができたからです。研究室を卒業されてからも、時々筆者の研究の事を気遣い連絡を頂く事が何度もあり、博士論文の提出直前にも草稿を読んで頂き、多くのフィードバックを得る事ができました。大変感謝致します。

同様に同じ研究チームでお世話になった松本さんにも感謝致します。柴田さんとは一味違った観点から研究をとらえ、数多くのアドバイスを頂きました。綿密に計画を立て研究を着実に進めて行く松本さんの指揮には、とかく研究が発散してしまいがちな筆者に有効なブレーキを何度もかけて頂く事がありました。本論文で登場した移動ロボット:Hyper Mouseは、松本さんが長年に渡って作り上げて来たものです。もの作りに弱い筆者が作るロボットとは違い、完成度の高いこのロボットのおかげで、本論文をスムーズに執筆する事ができました。

研究室OBの斉藤さんには、コンピュータ管理の面で様々な事を教わりました。本論文で登場したシステムのほとんどはLinuxで動作していますが、Linuxに関する知識のほとんどは斉藤さんから頂いたと言えるでしょう。研究室に入りたてのUNIXを知らない筆者に、一から

OSの基礎をたたき込んで頂きました。ロボットで動作するデバイスドライバの書き方を教わる事がなければ、本論文のロボットシステムは実現する事はできませんでした。

同じロボットとのインタラクションに興味がある博士課程2年の星野さんとは、第5章で登場したフレンドリーファクトの実験でいろいろな協力をしてもらいました。ほとんどロボットの制作には関わらず、ソフトウェアの設計だけに集中する事ができたのも、星野さんのおかげです。筆者とは違った観点からロボットとのインタラクションを捉えている星野さんからは、筆者が気付かなかった側面から多くの指摘をもらう事ができました。より一歩進んだロボットとのインタラクションの研究分野を是非、確立して欲しいと思います。

また、上半身人間型ロボットH4の製作とメンテナンスには、近野教助手(現東北大学助教)、リサーチアソシエイトの加賀美さん、長嶋さん、博士課程1年の除山君にお世話になりました。このロボットについてもソフトウェアの開発だけに集中する事ができ、大変自分の研究の効率をあげる事が可能になりました。特に、H4のソフトウェア開発を支えてくれた博士課程2年の香山君には大変感謝します。彼のおかげで数々の実験を効率良く行う事ができました。

自然言語処理をEusLisp上にインプリメントする際には、ポストドクターの金広さん、博士課程2年の水内君にいろいろとサポートしてもらいました。素晴らしいプログラミングツールであるEusLispですが、なかなか使う機会がなく、博士課程の最後になってやっと使いこなせるようになったのも、二人のおかげです。

視覚処理システムの開発には、博士課程1年の岡田君の力添えをもらいました。彼の開発した視覚処理システムによって、デブスマップの生成など、強力なパフォーマンスを得る事ができました。数々の実験は彼のシステムがなければ実現していなかったでしょう。

博士課程1年の西脇君には、論文の推敲、ビデオ撮影の手助け、研究室の計算機環境の設定など、数々のバックアップをしてもらいました。特に論文の推敲に関しては深い考察をしてもらい、筆者が気づく事のできなかった論点のずれを的確に指摘もらいました。また、英文の論文の推敲の際にはリサーチアソシエイトの山口博明さん、ポストドクターの Mr. James J. Kuffner、修士2年の山本さんのお世話になりました。

修士課程1年の中君には、移動ロボットによる配達行動の実験に参加してもらいました。こつこつと研究を進める中君のおかげで非常にインパクトのあるロボット行動を実現する事ができました。是非、そのパワーで次の研究テーマに向けて新しいチャレンジをして欲しいと思います。

学部4年の岡部君には、Windows環境におけるViaVoiceを利用したプログラミングを行ってもらいました。UNIXで育った筆者にはWindowsでプログラミングをする事が大変壁が高く、岡部君のおかげで良いアプリケーションを書く事ができました。これからは是非こ

わりのあるソフトウェア構成で面白いロボットを作ってもらいたいと思います。

修士2年の頃に同期だった、安藤君、宮崎君、そして1年後輩だった坂井君には、とても感謝致します。彼らには、議論の相手になってもらったり、疲れた頭をほぐす冗談話など、非常に研究室を居心地の良いものにしてもらいました。特に、修士論文提出前の1週間に交わしたいろいろな会話は一生忘れられないものになると思います。

音声認識システムの構築に際しては、電子技術総合研究所情報部音声研究室の速水信氏をはじめ、音声研究室の皆様がソフトウェアの提供と多くの助言を頂きました。この非常に優れたシステムのおかげで、当初予定した以上の認識機能を実現することができました。大変感謝致します。

また、研究室外の方々からも、貴重な御助言を頂きました。本論文のキーワードである、ロボットとの対話に基づく知能の形成という側面から、電子技術総合研究所、事情通ロボットプロジェクトの松井俊浩氏、麻生英樹氏、原功氏、本村陽一氏から有効な御意見を頂きました。大変感謝致します。白井良明教授(大阪大学)、油田信一教授(筑波大学)、大森隆司教授(東京農工大)、溝口博助教授(埼玉大学)、細田耕助教授(大阪大学)、市川純章助手(東京理科大)、倉林さん(理化学研究所)、岡田さん(東京大学リサーチアソシエイト)、からは学会活動や研究会などを通じて貴重な指摘をたくさん頂きました。感謝致します。

また、学会や研究会などを通じて知り合った多くの友人にも多くの力を借る事ができました。早川君(早稲田大学)とは、ロボットと人間とのインタラクションに関する研究会を通じて知り合い、筆者とは違うアプローチからロボットとのインタラクションの問題を捉える視点に多くの刺激を受けました。奈良先端大学院大学博士課程2年の森本君からは強化学習の研究の立場から、本論文への意見をもらいました。感謝します。

最後に、学部4年生、修士2年間、博士課程3年間と長い間、本論文の執筆に関わって頂いた多くの方々、友人、家族に改めて感謝致します。

1999年12月 稲邑 哲也

参考文献

- [Akiba 94] Tomoyoshi Akiba and Hozumi Tanaka. A Bayesian Approach for User Modeling in Dialogue Systems. Technical report, Dept. of Computer Science, Tokyo Institute of Technology, 1994.
- [Angluin 87] Dana Angluin. Learning Regular Sets from Queries and Counterexamples. *Information and Computation*, Vol. 75, No. 2, pp. 87-106, Nov. 1987.
- [Appelt 85] Douglas E. Appelt. Planning English Referring Expressions. *Artificial Intelligence*, Vol. 26, pp. 1-33, 1985.
- [Asada 96] Minoru Asada, Shoichi Noda and Koh Hosoda. Action-Based Sensor Space Categorization for Robot Learning. In *Proceedings of the 1996 IEEE/RSJ International Conference on Intelligent Robotics and Systems (IROS'96)*, pp. 1502-1509, 1996.
- [Asada 99] Minoru Asada, Eiji Uchibe and Koh Hosoda. Cooperative behavior acquisition for mobile robots in dynamically changing real worlds via vision-based reinforcement learning and development. *Artificial Intelligence*, Vol. 110, No. 2, pp. 275-292, Jun 1999.
- [Asoh 96] H. Asoh, Y. Motomura, I. Hara, S. Akaho, S. Hayamizu and T. Matsui. Acquiring a Probabilistic Map with Dialogue-Based Learning. In *Proceedings of ROBOLEARN-96*, 1996.
- [Basye 92] Kenneth Basye, Thomas Dean, Jak Kirman and Moises Lajter. A Decision-Theoretic Approach to Planning Perception and Control. *IEEE Expert*, Vol. 7, No. 4, pp. 58-65, 1992.
- [Baumberg 94] A. Baumberg and D. Hogg. An efficient method for contour tracking using active shape models. In IEEE Computer Society ed., *Proc. of the Workshop on Motion of Nonrigid and Articulated Objects*, 1994.
- [Bischoff 99] Rainer Bischoff and Tamhant Jain. Natural Communication and Interaction with Humanoid Robots. In *The 2nd International Symposium on Humanoid Robots (HURO'99)*, 1999.
- [Brooks 86] Rodney A. Brooks. A Robust Layered Control System for a Mobile Robot. *IEEE Journal of Robotics and Automation*, Vol. 2, No. 1, pp. 14-23, 1986.
- [Buxton 95] Hilary Buxton and Shaogang Gong. Advanced Visual Surveillance using Bayesian Networks. In *Proceedings of IEEE Workshop on Context-based Vision*, 1995.
- [Card 91] Stuart K. Card. *Intelligent Interface*, chapter 2, pp. 27-47. 海文堂, 1991. (邦訳: 知的インタフェース, 認知科学研究会訳).
- [Chapman 91] David Chapman. *Vision, Instruction, and Action*. The MIT Press, 1991.
- [Charniak 91] Eugene Charniak. Bayesian Networks without Tears. *AI Magazine*, Vol. Winter, pp. 50-63, 1991.
- [Charniak 93] Eugene Charniak. A Bayesian model of plan recognition. *Artificial Intelligence*, Vol. 64, No. 1, pp. 53-79, 1993.

- [Chen 94] Pang C. Chen and Yong K. Hwang. Generating Natural-Language like Robot Motion Command Set through Machine Learning. In *Proceedings of the 1994 IEEE International Conference on Systems, Man and Cybernetics*, pp. 114-119, 1994.
- [Coombs 93] David J. Coombs. Real-time binocular smooth pursuit. *Int. Journal of Computer Vision*, Vol. 11, No. 2, pp. 147-164, 1993.
- [Doya 99] Kenji Doya. What are the Computations of the Cerebellum, the Basal Ganglia, and the Cerebral Cortex? *Neural Networks*, Vol. 12, pp. 961-974, 1999.
- [Eberts 91] Ray E. Eberts and Cindelyn G. Eberts. *Intelligent Interface*, chapter 4, pp. 69-124. 南文堂, 1991. (邦訳: 知的インタフェース, 認知科学研究会訳).
- [Eizirik 93] Leila M. R. Eizirik, Valmir C. Barbosa and Sueli B. T. Mendes. A Bayesian-Network Approach to Lexical Disambiguation. *Cognitive Science*, Vol. 17, pp. 257-283, 1993.
- [Forbes 95] Jeff Forbes, Tim Huang, Keiji Kanazawa and Stuart Russell. The BATmobile: Towards a Bayesian Automated Taxi. In *Proceedings of the 14th International Joint Conference on Artificial Intelligence (IJCAI'95)*, pp. 1878-1885, 1995.
- [Friedman 97a] Nir Friedman, Dan Geiger and Moises Goldszmidt. Bayesian network classifiers. *Machine Learning*, Vol. 29, No. 2-3, pp. 131-163, Nov 1997.
- [Friedman 97b] Nir Friedman, Moises Goldszmidt, David Heckerman and Stuart J. Russell. Challenge: Where is the Impact of Bayesian Networks in Learning. In *Proceedings of the 15th International Joint Conference on Artificial Intelligence (IJCAI'97)*, pp. 10-15, 1997.
- [Fry 98] John Fry, Hideki Asoh and Toshihiro Matsui. Natural Dialogue with the Jijo-2 Office Robot. In *Proceedings of the 1998 IEEE/RSJ International Conference on Intelligent Robotics and Systems (IROS'98)*, pp. 1278-1283, 1998.
- [Fujita 97] Masahiro Fujita and Koji Kageyama. An Open Architecture for Robot Entertainment. In *Proceedings of the First International Conference on Autonomous Agents*, pp. 435-442, 1997.
- [Fukumizu 99] Kenji Fukumizu. Statistical active learning in multilayer perceptrons. *IEEE Transactions on Neural Networks*, 1999.
- [Ghosh 99] Sumit Ghosh, Manisha Mundhe, Karina Hernandez and Sandip Sen. Voting for movies: the anatomy of a recommender system. In *Proceedings of the Third International Conference on Autonomous Agents (Agents'99)*, pp. 434-435, 1999.
- [Graefe 97] Volker Graefe and Rainer Bischoff. A Human Interface for an Intelligent Mobile Robot. In *Proceedings of the 6th IEEE International Workshop on Robot and Human Communication (ROMAN'97)*, pp. 194-199, 1997.
- [Grice 75] H. Paul Grice. Logic and Conversation. *Peter Cole and Jerry L. Morgan, editors, Syntax and Semantics: Speech acts*, Academic Press, Vol. 3, pp. 41-58, 1975.

- [Hailu 98] G. Hailu and G. Sommer. Learning by Biasing. In *Proceeding of the International Conference on Robotics & Automation*, pp. 2168-2173, 1998.
- [Heckerman 91] David Heckerman. *Probabilistic Similarity Networks*. MIT Press, 1991.
- [Heckerman 94] David Heckerman, John S. Breese and Koos Rommelse. Troubleshooting under uncertainty. In *International Workshop on Principles of Diagnosis, AAAI*, pp. 121-130, 1994.
- [Heckerman 95a] David Heckerman, Dan Geiger and David Chickering. Learning bayesian networks: The combination of knowledge and statistical data. *Machine Learning*, Vol. 20, pp. 197-243, 1995.
- [Heckerman 95b] David Heckerman, Abe Mamdani and Michael P. Wellman. Real-World Applications of Bayesian Networks. *Communication of the ACM*, Vol. 38, No. 3, pp. 24-37, March 1995.
- [Herzog 94] Gerd Herzog and Peter Wazinski. Visual TRANslator: Linking Perceptions and Natural Language Descriptions. *Artificial Intelligence Review*, Vol. 8, No. 2/3, pp. 175-187, 1994.
- [Hirai 97] Kazuo Hirai. Current and Future Perspective of Honda Humanoid Robot. In *Proceedings of the 1997 IEEE/RSJ International Conference on Intelligent Robotics and Systems (IROS'97)*, pp. 500-508, 1997.
- [Hirasawa 98] Jun'ichi Hirasawa, Noboru Miyazaki, Mikio Nakano and Takeshi Kawabata. Implementation of coordinative nodding behavior on spoken dialogue systems. In *Proc. on the Sixth International Conference on Spoken Language Processing (IC-SLP'98)*, pp. 2347-2350, 1998.
- [Horswill 93] I. Horswill. Polly: A Vision-Based Artificial Agent. In *Proceedings of the Eleventh National Conference on Artificial Intelligence (AAAI'93)*, pp. 824-829, 1993.
- [Hoshino 99] Yukiko Hoshino, Masaki Miyamoto, Yasutada Suzuki, Hideko Yamamoto, Masayuki Inaba and Hirochika Inoue. Development of friendly artifact -first prototype: Penguin-. In *Proceedings of the 1999 IEEE/RSJ International Conference on Intelligent Robotics and Systems (IROS'99)*, pp. 1026-1031, 1999.
- [Hwang 96] Yong K. Hwang, Pang C. Chen and Peter A. Watterberg. Interactive Task Planning through Natural Language. In *Proceedings of the 1996 IEEE International Conference on Robotics & Automation*, pp. 24-29, Apr 1996.
- [Hwang 98] Yong K. Hwang, Sung C. Kang, Sooyong Lee, Sang M. Park, Kyoung R. Cho, Hyun S. Kim and Chong W. Lee. Human Interface, Automatic Planning, and Control of a Humanoid Robot. *The International Journal of Robotics Research*, Vol. 17, No. 11, pp. 1131-1149, Nov 1998.
- [Inamura 98a] Tetsunari Inamura, Masayuki Inaba and Hirochika Inoue. Finding Human based on the Interactive Sensing. In *Proceedings of the 5th International Conference on Intelligent Autonomous Systems*, pp. 86-91, 1998.

- [Inamura 95b] Tetsunari Inamura, Tomohiro Shibata, Yoshio Matsumoto, Masayuki Inaba and Hirochika Inoue. Finding and Following a Human based on On-line Visual Feature Determination through Discourse. In *Proceeding of the 1998 IEEE/RSJ International Conference on Intelligent Robotics and Systems (IROS'98)*, pp. 348-353. 1998.
- [Inamura 99] Tetsunari Inamura, Masayuki Inaba and Hirochika Inoue. Acquisition of Probabilistic Behavior Decision Model based on the Interactive Teaching Method. In *Proceeding of the 9th International Conference on Advanced Robotics*, pp. 523-528. 1999.
- [Ishiguro 96] Hiroshi Ishiguro, Ritsuko Sato and Toru Ishida. Robot Oriented State Space Construction. In *Proceedings of the 1996 IEEE/RSJ International Conference on Intelligent Robotics and Systems (IROS'96)*, pp. 1496-1501. 1996.
- [Kagami 99] Satoshi Kagami, Atsushi Konno, Ryosuke Kageyama, Masayuki Inaba and Hirochika Inoue. Development of a Humanoid H4 with Soft and Distributed Tactile Sensor Skin. In *Preprints of 6th Int. Symp. of Experimental Robotics*, pp. 443-451. 1999.
- [Kashino 95] Kunio Kashino, Kazuhiro Nakadai, Tomoyoshi Kinoshita and Hidehiko Tanaka. Application of bayesian probability network to music scene analysis. In *IJCAI Workshop on Computational Auditory Scene Analysis*. 1995.
- [Kass 88] Michael Kass, Andrew Witkin and Demetri Terzopoulos. Snakes: Active Contour Models. *International Journal of Computer Vision*, Vol. 1, No. 4, pp. 321-331, 1988.
- [Khatib 99] O. Khatib, K. Yokoi, O. Brock, K. Chang and A. Casal. Robots in Human Environments: Basic Autonomous Capabilities. *The International Journal of Robotics Research*, Vol. 18, No. 7, pp. 684-696, Jul 1999.
- [Kim 83] Jin H. Kim and Judea Pearl. A Computational Model for Causal and Diagnostic Reasoning in Inference System. In *Proceedings of the Eighth International Joint Conference on Artificial Intelligence (IJCAI'83)*, pp. 190-193. 1983.
- [Kita 94] N. Kita, S. Rougeaux, Y. Kuniyoshi and S. Sakane. Thorough zdf-based localization for binocular tracking. In *Proceedings of IAPR Workshop on Machine Vision Application*, pp. 190-195. 1994.
- [Knoll 97] A. Knoll, B. Hildebrandt and J. Zhang. Instructing Cooperating Assembly Robots through Situated Dialogues in Natural Language. In *Proceedings of the 1997 IEEE International Conference on Robotics & Automation*, pp. 888-894. 1997.
- [Kobayashi 96] T. Kobayashi. ALICE: Acquisition of Language in Conversational Environment - An Approach to Weakly Supervised Training of Spoken Language System -. In *Proc. on the Fourth International Conference on Spoken Language Processing (ICSLP96)*, pp. 833-836. 1996.

- [Kuniyoshi 94] Yasuo Kuniyoshi, Masayuki Inaba and Hirochika Inoue. Learning by Watching: Extracting Reusable Task Knowledge from Visual Observation of Human Performance. *IEEE Transaction on Robotics and Automation*, Vol. 10, No. 6, pp. 799-822, 1994.
- [Langley 92] Pat Langley, Wayne Iba and Kevin Thompson. An Analysis of Bayesian Classifiers. In *The Tenth National Conference on Artificial Intelligence*, pp. 223-228. 1992.
- [Langley 97a] Pat Langley. Machine Learning for Adaptive User Interface. In *Proceedings of the 21st German Annual Conference on Artificial Intelligence*, pp. 53-62. 1997.
- [Langley 97b] Pat Langley, Gregory M. Provan and Padhraic Smyth. Learning with Probabilistic Representations. *Machine Learning*, Vol. 29, pp. 91-101, 1997.
- [Langley 99] Pat Langley and Stephanie Sage. Tractable Average-Case Analysis of Naive Bayesian Classifiers. In *The Sixteenth International Conference on Machine Learning*. 1999.
- [Larranaga 96] Pedro Larranaga, Mikel Poza, Yosy Yurramendi, Roberto H. Murga and Cindy M.H. Kuijpers. Structure Learning of Bayesian Networks by Genetic Algorithms: A Performance Analysis of Control Parameters. *IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI)*, Vol. 18, No. 9, pp. 912-926, Sep 1996.
- [Lee 98] Joo-Ho Lee, Noriaki Ando and Hideki Hashimoto. Intelligent Interaction between Human Operator and Mobile Robot. In *Proceedings of the 7th IEEE International Workshop on Robot and Human Communication (ROMAN'98)*, pp. 95-100. 1998.
- [Lenat 95] Douglas B. Lenat. Cyc: A large-scale investment in knowledge infrastructure. *Communications of the ACM*, Vol. 38, No. 11, pp. 33-38, Nov 1995.
- [Lesser 99] Victor Lesser, Michael Atighetchi, Brett Benyo, Bryan Horling, Anita Raja, Regis Vincent, Thomas Wagner, Ping Xuan and Shelly XQ. Zhang. The UMASS Intelligent Home Project. In *Proceedings of the Third International Conference on Autonomous Agents (Agents'99)*, pp. 291-298. 1999.
- [Liu 98] Fang Liu and Rosalind W. Picard. Finding Periodicity in Space and Time. In *Proceedings of the 6th International Conference on Computer Vision*, pp. 376-383. 1998.
- [Lueth 94] Tim C. Lueth, Thomas Laengle, Gerd Herzog, Eva Stopp and Ulrich Rembold. KANTRA: Human-Machine Interaction for Intelligent Robots Using Natural Language. In *Proceedings of the 3rd IEEE International Workshop on Robot and Human Communication (ROMAN'94)*, pp. 106-111. 1994.
- [Mae 96] Yasushi Mae, Yoshiaki Shirai, Jun Miura and Yoshinori Kuno. Object Tracking in Cluttered Background Based on Optical Flow and Edges. In *Proceedings of International Conference on Pattern Recognition*, pp. 196-200. 1996.

- [Maes 93] Pattie Maes and Robyn Kozierek. Learning Interface Agents. In *Proceedings of the Eleventh National Conference on Artificial Intelligence*, pp. 459-465. July 1993.
- [Maes 94] Pattie Maes. Agents that Reduce Work and Information Overload. *Communications of the ACM*, Vol. 37, No. 7, pp. 30-40, 1994.
- [Matsui 94] Toshihiro Matsui. Multithread Object-Oriented Language EusLisp for Parallel and Asynchronous Programming in Robotics. In *Workshop on Concurrent Object-based Systems, IEEE 6th Symposium on Parallel and Distributed Processing*. October 1994.
- [Matsumoto 97] Yoshio Matsumoto, Masayuki Inaba and Hirochika Inoue. Memory-Based Navigation using Omni-View Sequence. In *Proceedings of International Conference on Field and Service Robotics*, pp. 184-191. 1997.
- [Matsumoto 99] Yoshio Matsumoto, Kazunori Ikeda, Masayuki Inaba and Hirochika Inoue. Visual Navigation Using Omnidirectional View Sequence. In *Proceeding of the 1999 IEEE/RSJ International Conference on Intelligent Robotics and Systems (IROS'99)*, pp. 317-322. Oct 1999.
- [Minato 98] T. Minato and M. Asada. Environmental change adaptation for mobile robot navigation. In *Proceedings of the 1998 IEEE/RSJ International Conference on Intelligent Robotics and Systems (IROS'98)*, pp. 1859-1864. 1998.
- [Mitchell 86] Tom M. Mitchell, Richard M. Keller and Smadar T. Kedar-Cabelli. Explanation-Based Generalization: A Unifying View. *Machine Learning*, Vol. 1, pp. 47-80, 1986.
- [Miura 93] Jun Miura and Yoshiaki Shirai. An Uncertainty Model of Stereo Vision and its Application to Vision-Motion Planning of Robot. In *Proceedings of the 13th International Joint Conference on Artificial Intelligence*, pp. 1618-1623. Aug 1993.
- [Mizoguchi 97] Hiroshi Mizoguchi, Katsuyuki Takagi, Yotoro Hatamura, Masayuki Nakao and Tomomasa Sato. Behavioral expression by an expressive mobile robot - expressing vividness, mental distance, and attention -. In *Proceedings of the 1997 IEEE/RSJ International Conference on Intelligent Robotics and Systems (IROS'97)*, pp. 306-311. 1997.
- [Morimoto 98] Jun Morimoto and Kenji Doya. Reinforcement learning of dynamic motor sequence: Learning to stand up. In *Proceedings of the 1998 IEEE/RSJ International Conference on Intelligent Robotics and Systems (IROS'98)*, pp. 1721-1726. Oct 1998.
- [Motomura 97] Yoichi Motomura, Isao Hara, Hideki Asoh and Toshihiro Matsui. Bayesian Network that Learns Conditional Probabilities by Neural Network. In *Proceedings of International Conference of Neural Information Processing*. 1997.

- [Nagao 95] Katashi Nagao and Jun Rekimoto. Ubiquitous Talker: Spoken Language Interaction with Real World Objects. *International Joint Conference on Artificial Intelligence*, Vol. 2, pp. 1284-1290, 1995.
- [Neal 92] Radford M. Neal. Connectionist learning of belief networks. *Artificial Intelligence*, Vol. 56, pp. 71-113, 1992.
- [Nourbakhsh 95] Illah Nourbakhsh, Rob Powers and Stan Birchfield. DERSH An Office-Navigating Robot. *AI Magazine*, Vol. 16, No. 2, pp. 53-60, 1995.
- [Ogata 99] Tetsuya Ogata and Shigeki Sugano. Emotional communication between humans and robots - consideration of primitive language in robots. In *Proceedings of the 1999 IEEE/RSJ International Conference on Intelligent Robotics and Systems (IROS'99)*, pp. 870-875. Oct 1999.
- [Okada 96] Ryuzo Okada, Yoshiaki Shirai and Jun Miura. Object tracking based on optical flow and depth. In *Proceedings of IEEE/RSJ International Conference on Multisensor Fusion and Integration for Intelligent Systems*, pp. 565-571. 1996.
- [Oviatt 91] S. L. Oviatt and P. R. Cohen. Discourse Structure and Performance Efficiency in Interactive and Noninteractive Spoken Modalities. *Computer Speech and Language*, Vol. 5, No. 4, pp. 297-326, 1991.
- [Paass 95] Gerhard Paass and Jorg Kindermann. Bayesian query construction for neural network models. In *Advances in Neural Information Processing Systems 7*, pp. 443-450. The MIT Press, 1995.
- [Pearl 88] Judea Pearl. *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*. Morgan Kaufmann, 1988.
- [Pomerleau 89] Dean A. Pomerleau. ALVINN: An autonomous land vehicle in a neural network. Technical Report CMU-CS-89-107, CMU, 1989.
- [Pomerleau 93] Dean A. Pomerleau. *Neural network perception for mobile robot guidance*. Kluwer Academic Publishing, 1993.
- [Quinlan 86] J. R. Quinlan. Induction of decision trees. *Machine Learning*, Vol. 1, pp. 81-106, 1986.
- [Rimey 92] Raymond D. Rimey and Christopher M. Brown. Where to Look Next Using a Bayes Net: Incorporating Geometric Relations. In *Proceedings of ECCV92*, pp. 542-550. 1992.
- [Rimey 94] Raymond D. Rimey and Christopher M. Brown. Control of Selective Perception Using Bayes Nets and Decision Theory. *International Journal of Computer Vision*, Vol. 23, No. 2, pp. 173-207, 1994.
- [Rougeaux 94] S. Rougeaux, N. Kita, Y. Kuniyoshi, S. Sakane and F. Chavand. Binocular Tracking Based on Virtual Horopters. In *Proceedings of the 1994 IEEE/RSJ International Conference on Intelligent Robotics and Systems (IROS'94)*, pp. 2052-2057. 1994.

- [Rowley 96] Henry A. Rowley, Shumeet Bala and Takeo Kanade. Neural Network-Based Face Detection. In *Proceedings of International Conference on Computer Vision and Pattern Recognition*, pp. 203-208. 1996.
- [Russel 97] Stuart Russel and Peter Norvig. Artificial Intelligence: A Modern Approach (邦題 エージェントアプローチ人工知能). 共立出版, 1997.
- [Russell 95] Stuart J. Russell and Peter Norvig. *Artificial Intelligence: A modern Approach*. Prentice Hall, 1995.
- [Sato 96] Tomomasa Sato, Yoshifumi Nishida and Hiroshi Mizoguchi. Robotic room: Symbiosis with human through behavior media. *Journal of Robotics and Autonomous Systems*, No. 18, pp. 185-194. 1996.
- [Sawaragi 97] Tetsuo Sawaragi and Osamu Katai. Resource-bounded reasoning for interface agent for realizing flexible human-machine collaboration. In *Proceedings of the 6th IEEE International Workshop on Robot and Human Communication (RO-MAN'97)*, pp. 484-489. 1997.
- [Schraft 94] R. D. Schraft, M. Hagele and H. Volz. Service robots: The Appropriate Level of Automation and the Role of Users/Operators in the Task Execution. In *Proceedings of the 25th International Symposium on Industrial Robots (ISIR)*, pp. 225-231. 1994.
- [Sekimoto 97] T. Sekimoto, T. Tsubouchi and S. Yuta. A simple driving device for a vehicle-implementation and evaluation. In *Proceedings of the 1997 IEEE/RSJ International Conference on Intelligent Robotics and Systems (IROS'97)*. 1997.
- [Shardanand 95] Upendra Shardanand and Pattie Maes. Social information filtering: Algorithms for automating "word of mouth". In *Proceedings of the Conference on Human Factors in Computing Systems (CHI '95)*, pp. 210-217. ACM. May 1995.
- [Shi 98] Jianbo Shi and Jitendra Malik. Motion Segmentation and Tracking Using Normalized Cuts. In *Proceedings of the Sixth International Conference on Computer Vision*, pp. 1154-1160. 1998.
- [Shibata 95] Tomohiro Shibata, Yoshio Matsumoto, Taichi Kuwahara, Masayuki Inaba and Hirochika Inoue. Hyper scooter: a mobile robot sharing visual information with a human. In *Proceedings of the IEEE International Conference on Robotics and Automation*, pp. 1074-1079. 1995.
- [Shibata 96] Tomohiro Shibata, Yoshio Matsumoto, Taichi Kuwahara, Masayuki Inaba and Hirochika Inoue. Development and integration of generic components for a teachable vision-based mobile robot. *IEEE/ASME Transactions on Mechatronics*, Vol. 1, No. 3, pp. 230-236. 1996.
- [Shirai 99] Y. Shirai, H. Inoue, M. Inaba, M. Terada and Y. Tateyama. Robot as Friendly Artifact -Human Recognition and Interaction-. In *Proceeding of the Ninth International Conference on Advanced Robotics*, pp. 101-106. 1999.

- [Shortliffe 76] Edward Hance Shortliffe. *Computer-Based Medical Consultations: MYCIN*. Elsevier, 1976.
- [Stopp 94] Eva Stopp, Klaus Peter Gapp, Gerd Herzog, Thomas Laengle and Tim C. Lueh. Utilizing Spatial Relations for Natural Language Access to an Autonomous Mobile Robot. In *The 18th German Annual Conference on Artificial Intelligence*, pp. 39-50. 1994.
- [Takahashi 98] Takuya Takahashi, Satoru Nakanishi, Yoshinori Kuno and Yoshiaki Shirai. Human-robot interface by verbal and nonverbal behaviors. In *Proceedings of the 1998 IEEE/RSJ International Conference on Intelligent Robotics and Systems (IROS'98)*, pp. 924-929. 1998.
- [Torrance 94] Mark C. Torrance. Natural Communication with Robots. Master's thesis, Massachusetts Institute of Technology. 1994.
- [Veloso 98] Manuela Veloso, William Uther, Masahiro Fujita, Minoru Asada and Hiroaki Kitano. Playing Soccer with Legged Robots. In *Proceedings of the 1998 IEEE/RSJ International Conference on Intelligent Robotics and Systems (IROS'98)*, pp. 437-442. Oct 1998.
- [Ward 98] Nigel Ward. The relationship between sound and meaning in Japanese back-channel grunts. In *4th Annual Meeting of the (Japanese) Association for Natural Language Processing*. 1998.
- [Welser 93] Mark Welser. Some Computer Science Issues in Ubiquitous Computing. *Communication of the ACM*, Vol. 36, No. 7, pp. 74-85. 1993.
- [Whitehead 95] Steven D. Whitehead and Long-Ji Lin. Reinforcement learning of non-markov decision processes. *Artificial Intelligence*, Vol. 73, No. 1-2, pp. 271-306. 1995.
- [Winograd 76] Terry Winograd. 言語理解の構造. 産業図書, 1976. 例一博訳.
- [Wren 97] Christopher Wren, Ali Azarbayejani, Trevor Darrell and Alex Pentland. Pfänder: Real-Time Tracking of the Human Body. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 19, No. 7, pp. 780-785. 1997.
- [Wu 93a] Dekai Wu. Approximating Maximun-Entropy Ratings for Evidential Parsing and Semantic Interpretation. In *Proceedings of the 13th International Joint Conference on Artificial Intelligence (IJCAI'93)*, pp. 1290-1296. 1993.
- [Wu 93b] Dekai Wu. Estimating Probability Distributions over Hypotheses with Variable Unification. In *Proceedings of the Eleventh National Conference on Artificial Intelligence (AAAI'93)*, pp. 790-795. 1993.
- [Yairi 98] Takehisa Yairi, Shin'ichi Nakasaka and Koichi Hori. State Abstraction from Heterogeneous and Redundant Sensor Information. In *Proceedings of Intelligent Autonomous Systems*, pp. 234-241. 1998.
- [Yamasaki 95] Nobuyuki Yamasaki and Yuichiro Anzai. Active Interface for Human-Robot Interaction. In *Proceedings of the IEEE International Conference on Robotics & Automation*, pp. 3103-3109. May 1995.

- [Yoshida 96] Kenichi Yoshida and Hirochi Motoda. Automated User Modeling for Intelligent Interface. *International Journal of Human-Computer Interaction*, Vol. 8, No. 3, pp. 237-258, 1996.
- [Yoshiike 98] Takahide Yoshiike, Atsushi Konno, Koichi Nagashima, Masayuki Inaba and Hirochika Inoue. On-line recognition and mimicking of human posture. In *Proceedings of the 3rd International Conference on Advanced Mechatronics*, pp. 430-435, Aug 1998.
- [浅田 95] 浅田裕, 野田彰一, 依藤田健, 細田耕. 視覚に基づく強化学習によるロボットの行動獲得. 日本ロボット学会誌, Vol. 13, No. 1, pp. 68-74, 1995.
- [浅田 97] 浅田裕, 野田彰一, 細田耕. ロボットの行動獲得のための状態空間の自律的構成. 日本ロボット学会誌, Vol. 15, No. 6, pp. 886-892, 1997.
- [麻生 97] 麻生英樹, 赤穂昭太郎, 本村陽一. 統計的推論とAIの推論. 人工知能学会誌, Vol. 12, No. 2, pp. 196-203, March 1997.
- [麻生 98] 麻生英樹, John Fry, 速水悟, 浅野太, 本村陽一, 松井俊浩. 所内事情通口ボット Jijo-2 の対話機能. 意味と理解研究会, 1998.
- [安部 97] 安部直樹. 能動学習に関する計算論的学習理論の研究. 情報処理, Vol. 38, No. 7, pp. 575-582, Jul 1997.
- [荒木 94] 荒木雅弘, 堂下修司. 対話事例ベースによる発話内容の推定および未知語の解析. 第49回情報処理学会全国大会講演論文集, 第3巻, pp. 155-156, 1994.
- [有田 95] 有田正剛, 島津秀雄. カーナビゲーションシステム用音声対話インタフェース. 人工知能学会研究会資料 SIG-SLUD-9502-1, pp. 1-7, 1995.
- [安西 96] 安西祐一郎. 音声対話における認知モデル・パーソナルロボットを使用する際の音声情報の利用について. 重点領域研究「音声対話」第3年次研究成果報告書, pp. 333-340, 1996.
- [池田 95] 池田敬志, 荒木雅弘, 堂下修司. Bayesian Network を用いた意図理解. 言語処理学会第1回年次大会予集, pp. 69-72, 1995.
- [伊藤 93] 伊藤, 渡辺, 岸. 音声ナビゲーションシステムの開発. 自動車技術, Vol. 47, No. 8, pp. 18-23, 1993.
- [稲邑 95] 稲邑哲也, 柴田智広, 稲葉雅幸, 井上博允. ハイパスクーターの研究～呼びかけをヒントとした音声と画像の統合による遠方のユーザーの発見～. 第13回日本ロボット学会学術講演会予集, pp. 1017-1018, 1995.
- [稲邑 96] 稲邑哲也, 柴田智広, 稲葉雅幸, 井上博允. ハイパスクーターの研究: 視覚処理と音声対話処理の統合によるユーザーの発見. ロボティクス・メカトロニクス講演会'96講演論文集, pp. 638-641, 1996.
- [稲葉 98a] 稲葉雅幸, 星野由紀子, 井上博允. 導電性ファブリックを用いた全身被覆型触覚センサスーツ. 日本ロボット学会誌, Vol. 16, No. 1, pp. 80-86, 1998.

- [稲邑 98b] 稲邑哲也, 稲葉雅幸, 井上博允. 視覚情報と人間の操縦の観察に基づく移動ロボットの行動獲得. 日本機械学会ロボティクスメカトロニクス講演会 '98, pp. 2C111-6, 1998.
- [稲邑 98c] 稲邑哲也, 佐川立昌, 稲葉雅幸, 井上博允. 照明条件の変動下における人間の発見追従行動のための実時間視覚処理. 第16回日本ロボット学会学術講演会予集, pp. 1039-1040, 1998.
- [稲邑 99a] 稲邑哲也, 稲葉雅幸, 井上博允. Bayesian Network と GA を用いた対話経験の内部に基づく適応的インタフェースの実現—ヒューマンロボットインタラクションシステム PEXIS の機能その2—. 第17回日本ロボット学会学術講演会予集, pp. 1011-1012, 1999.
- [稲邑 99b] 稲邑哲也, 稲葉雅幸, 井上博允. 確率的経験表現に基づくヒューマンロボットインタラクションシステム PEXIS. 第17回日本ロボット学会学術講演会予集, pp. 1071-1072, 1999.
- [稲邑 99c] 稲邑哲也, 稲葉雅幸, 井上博允. 行動決定の確信度を利用した重み付け経験累積法に基づく自律行動の獲得—ヒューマンロボットインタラクションシステム PEXIS の機能その1—. 第17回日本ロボット学会学術講演会予集, pp. 1009-1010, 1999.
- [稲邑 00a] 稲邑哲也, 岡部真人, 稲葉雅幸, 井上博允. タスク達成の確信度に基づくユーザへの質問確認行動の生成. 日本機械学会ロボティクスメカトロニクス講演会 '00, 2000.
- [稲邑 00b] 稲邑哲也, 稲葉雅幸, 井上博允. 個人に適應した語彙を獲得するロボットとの自然言語対話処理—ヒューマンロボットインタラクションシステム PEXIS の機能その3—. 第5回ロボティクスシンポジウム予集, 2000.
- [乾 95] 乾健太郎, 徳水健伸, 田中穂積. 協調的対話の意思決定理論的説明. 言語処理学会第1回年次大会予集, pp. 77-80, 1995.
- [井上 92] 井上博允. ハイパーマシン: 実用化を指向する知能ロボットのカーネル. 日本ロボット学会第10回学術講演会予集, pp. 699-702, 1992.
- [今井 99] 今井倫太, 関一夫, 宮里勉. 身体的制約を利用したヒューマンロボットインタフェース. 人工知能学会大会(第13回)予集, pp. 547-559, 1999.
- [植野 96] 植野真由. 意思決定アプローチによる Bayesian Network の因果モデル構築. 人工知能学会誌, Vol. 11, No. 5, pp. 725-734, Sep 1996.
- [畠見 92] 畠見達夫. 実例に基づく強化学習法. 人工知能学会誌, Vol. 7, No. 4, pp. 697-707, 1992.
- [大崎 98] 大崎英穂, 高木英行. 対話型 EC 操作者の負担低減—評価値予測による提示インタフェースの改善—. 人工知能学会誌, Vol. 13, No. 5, pp. 712-719, 1998.
- [尾形 95] 尾形哲也, 菅野重樹. 自己保存に基づくロボットの行動生成—方法論と機械モデルの実体化—. 日本ロボット学会誌, Vol. 13, No. 5, pp. 54-65, 1995.
- [小野塚 97] 小野塚卓, 山村雅幸. ペイジアンネットワーク上の強化学習のロボットナビゲーションへの応用. 第11回人工知能学会全国大会論文集, pp. 421-424, 1997.

- [加賀美 98] 加賀美聡, 近野敦, 陸山竜介, 松澤光隆, 稲葉雅幸, 井上博允. 視覚行動統合研究のための車輪移動上半身型ヒューマノイドH4の設計と開発. 第16回日本ロボット学会学術講演会予稿集, pp. 835-836, 1998.
- [加賀美 99] 加賀美聡, 岡田慧, 稲葉雅幸, 井上博允. ロボット搭載用実時間視差画像生成システム. 第4回ロボティクスシンポジウム予稿集, pp. 177-182, 1999.
- [柏野 96] 柏野邦夫, 木下智義, 中島一博, 田中英彦. 音楽情景分析の処理モデル OPTIMA における和音の認識. 電子情報通信学会論文誌, Vol. J79-DII, No. 11, pp. 1762-1770, 1996.
- [加藤 93] 加藤一郎. リリスロボット-生活支援ロボットの構想. 日本ロボット学会誌, Vol. 11, No. 5, pp. 614-617, 1993.
- [加藤 99] 加藤寛一郎. エアバスの真実-ボーイングを越えたハイテク挑戦-. 講談社, 1999.
- [香山 99] 香山健太郎, 長嶋功一, 加賀美聡, 稲葉雅幸, 井上博允. 座標系による抽象度分類に基づく感覚記憶ベースの人間型ロボットアーキテクチャ. ロボティクス・メカトロニクス講演会'99, pp. 2P1-78-109, 1999.
- [川入 96] 川入光男. 脳の計算理論. 産業図書, 1996.
- [川崎 99] 川崎安教, 藤原健吾, 倉田純一, 内山寛信. 自然言語による移動ロボットの誘導制御. 日本機械学会ロボティクスメカトロニクス講演会'99, pp. 2P2-23-010, 1999.
- [喜多 95] 喜多伸之, S. Rougeaux, 國吉康夫, 坂根茂幸. 仮想ホログラムを用いた実時間両眼追跡. 日本ロボット学会誌, Vol. 13, No. 5, pp. 683-690, 1995.
- [北岡 93] 北岡教英, 河原達也, 堂下修司. 自由発話認識・理解のためのフレーズボットニング. 電子情報通信学会 研究技術報告書 SP93-116, NLC93-56, pp. 15-22, 1993.
- [木村 86] 木村一鈴, 只野寿太郎. 病院ロボット. 日本ロボット学会誌, Vol. 4, No. 6, pp. 61-64, 1986.
- [國吉 90] 國吉康夫. 知能ロボットによる人間の行為の観察と理解に関する研究. 博士論文, 東京大学大学院工学系研究科, 1990.
- [佐藤 92] 佐藤倫太, 関一夫, 安西祐一郎. ロボットとの対話: センサ情報を利用した音声対話システム Linta の設計と実装. 人工知能学会研究会資料 SIG-SLUD-9202-3, pp. 19-26, 1992.
- [佐藤 94] 佐藤律子, 河原達也, 堂下修司. 構文手動 A* 探索による音声認識における未知語の処理. 電子情報通信学会 研究技術報告書 SP94-25, pp. 17-23, 1994.
- [佐藤 95] 佐藤知正, 高木克幸, 溝口博, 中尾政之, 畑村洋太郎. 表現する移動ロボット. 日本機械学会 [No.95-17] ロボティクス・メカトロニクス講演会'95 講演論文集, pp. 543-546, 1995.
- [佐藤 96] 佐藤知正, 高木克幸, 中尾政之, 畑村洋太郎. 表現する移動ロボット. 日本機械学会 [No.96-2] ロボティクス・メカトロニクス講演会'96 講演論文集, pp. 644-647, 1996.
- [佐藤 99a] 佐藤知正, 森武俊. 人と機械の知的協調システム-行動審視機能に基づいた人間行動適合型機械システム. 計測と制御, Vol. 38, No. 6, pp. 357-362, Jun 1999.

- [佐藤 99b] 佐藤知正, 森下店, 森武俊. 人間行動適合型システムとその技術. 第17回日本ロボット学会学術講演会予稿集, 第3巻, pp. 1065-1066, sep 1999.
- [榎本 95] 榎本哲夫. 資源制約を有するエージェントの設計と概念学習. 日本ロボット学会誌, Vol. 13, No. 1, pp. 44-50, 1995.
- [紫井 85] 紫井算男. ベイズ統計入門. 東京大学出版会, 1985.
- [紫井 95] 紫井算男. 意思決定の認知統計学. 朝倉書店, 1995.
- [柴田 94] 柴田智広, 松本吉央, 桑原太地, 稲葉雅幸, 井上博允. ハイバースクーターの研究: 対話による視覚行動地区の記憶と再生. 第12回日本ロボット学会学術講演会予稿集, pp. 1145-1146, 1994.
- [柴田 95a] 柴田智広, 稲色哲也, 稲葉雅幸, 井上博允. ハイバースクーターの研究-対象の局在性に基づく人間の視覚的注意のオンライン転移システムの開発-. 第13回日本ロボット学会学術講演会予稿集, pp. 1015-1016, 1995.
- [柴田 95b] 柴田智広. 人間との視覚情報の共有に基づいて行動する移動ロボットの研究. 博士論文, 東京大学大学院工学系研究科情報工学専攻, Dec. 1995.
- [柴田 96a] 柴田智広, 坂井克弘, 松本吉央, 稲色哲也, 稲葉雅幸, 井上博允. Hyper Scooter の研究-視覚情報に基づいた前方を歩行するユーザーの追従走行-. 第13回ロボティクスシンポジウム予稿集, pp. 23-28, May 1996.
- [柴田 96b] 柴田智広, 松本吉央, 稲葉雅幸, 井上博允. 人が搭乗しその場で行動を指示できるパーソナル視覚移動ロボット Hyper Scooter の開発. 日本ロボット学会誌, Vol. 14, No. 8, pp. 1138-1144, 1996.
- [白井 85] 白井克彦, 小林哲則, 岩田和彦, 深沢克夫. ロボットとの柔軟な対話を目的とした音声入出力システム-wabot-2 における会話系-. 日本ロボット学会誌, Vol. 3, No. 4, pp. 362-371, Aug 1985.
- [菅沼 92] 菅沼義昇. 対象間の差異による学習と知識構造. 人工知能学会誌, Vol. 7, No. 1, pp. 87-104, 1992.
- [鈴木 99] 鈴木保匡, 星野由紀子, 稲色哲也, 稲葉雅幸, 井上博允. ユーザの愛着獲得のための対話型 GA よるロボットの行動生成. 日本機械学会ロボティクスメカトロニクス講演会'99, pp. 2A1-76-114, 1999.
- [関本 95] 関本武志, 坪内孝司, 油田信一. 視覚映像とポインティングデバイスを用いた移動ロボットの授経システム. 第13回日本ロボット学会学術講演会予稿集, pp. 163-164, 1995.
- [関本 96] 関本武志, 坪内孝司, 油田信一. 環境中で走行経路を直接指示する移動ロボット授経のためのヒューマンインタフェース. 第14回日本ロボット学会学術講演会予稿集, pp. 337-338, 1996.
- [高橋 98] 高橋拓弥, 中西知, 久野義徳, 白井良明. 音声とジェスチャーによる対話に基づくヒューマンロボットインタフェース. インタラクション'98 論文集 (主催) 情報処理学会ヒューマンインタフェース研究会, pp. 161-168, 1998.

- [高橋 99] 高橋泰岳, 浅田稔. 実ロボットによる行動学習のための状態空間の漸近構成. 日本ロボット学会誌, Vol. 17, No. 1, pp. 118-124, 1999.
- [武田 97] 武田英明, 小林展英, 松原慶幸, 上野教志, 西田豊明. 人間・機械の共生のための知識的環境の提案と実現の試み. 1997年度電子通信情報学会 情報・システムソサエティ大会併催シンポジウム「ソフトウェアエージェントとその応用」シンポジウム講演論文集, pp. 147-154, 1997.
- [立花 96] 立花隆. 脳を極める—脳研究最前線. 朝日新聞社, 1996.
- [館村] 館村純一. Cinema space. <http://cinema.media.iis.u-tokyo.ac.jp/>.
- [田中 83] 田中穂積, 元吉文男, 山梨正明. LISP で学ぶ認知心理学 3: 言語理解. 東京大学出版会, 1983.
- [テリ 89] テリー・ウィノグラード, フェルナンド・フロレス. コンピュータと認知を理解する—人工知能の限界と新しい設計理念—. 産業図書, 平賀 訳, 1989.
- [堂下 98] 堂下修司, 新美康永, 白井克彦, 田中穂積, 溝口理一郎 (編). 音声による人間と機械の対話. オーム社, 1998.
- [中川 95a] 中川龍一, 丹方幹雄. 視覚情報統合化に基づく概念と文法の獲得システム. 人工知能学会誌, Vol. 10, No. 4, pp. 619-627, 1995.
- [中野 95b] 中野有紀子, 加藤恒昭. 教示対話における発話内容と対話ストラテジー談話履歴と被教示者の理解度による影響—. 人工知能学会研究会資料 SIG-SLUD-9502-4, pp. 24-31, 1995.
- [中西 98] 中西泰人. 選択関数を用いた対話型進化システムの制御と評価—遺伝的プログラミングのデザイン支援システムへの応用—. 人工知能学会誌, Vol. 13, No. 5, pp. 704-711, 1998.
- [中 99] 中健, 稲邑哲也, 稲葉雅幸, 井上博允. 対話機能をもつ視覚移動ロボットによる配達サービス行動の実現. 日本機械学会ロボティクスメカトロニクス講演会 '99, pp. 2P2-23-014, 1999.
- [長尾 92] 長尾確. 協調的対話の計算モデル. 人工知能学会研究会資料 SIG-SLUD-9201-5, pp. 37-46, 1992.
- [長尾 96] 長尾確. マルチモーダル・ヒューマンコンピュータインタラクション—エージェント指向と実世界指向—. 計測自動制御学会誌, Vol. 35, No. 1, pp. 65-70, 1996.
- [長尾 98] 長尾光悦, 山本雅人, 鈴木恵二, 大内東. インタラクティブ GA に基づく画像検索システムの評価. 人工知能学会誌, Vol. 13, No. 5, pp. 720-727, 1998.
- [長尾 95] 長尾確, 勝本純一, 伊藤純一郎, 早川由紀, 八木正紀, 安村達見. ウォークナビ: ロケーションウェアなインタラクティブ情報案内システム. インタラクティブシステムとソフトウェア III, pp. 39-48, 1995.
- [長尾 97] 長尾確. エージェント拡張現実感—エージェントによる実世界と情報世界の統合—. 情報処理学会誌, Vol. 38, No. 4, pp. 257-266, 1997.

- [綿見 92] 綿見美貴子, 松原仁, 中島秀之. 複数の領域間の関係に基づいて概念を獲得するシステム Rhea. 人工知能学会誌, Vol. 7, No. 6, pp. 1096-1107, 1992.
- [綿見 98] 綿見美貴子. 言語を獲得するコンピュータ. 共立出版, 日本認知科学会, Sep. 1998.
- [平田 90] 平田真一, 白井良明, 浅田稔. 知的画像切り出し. 電子情報通信学会技術研究報告, Vol. PRU90-104, pp. 53-60, 1990.
- [福水 96] 福水健次. 能動学習—最適な質問の効果と問題点—. 日本神経回路学会第7回全国大会講演論文集, pp. 153-157, 1996.
- [藤城 95] 藤城華子, 平松薫, 安西祐一郎. 自律移動ロボットの使いやすさの向上のためのユーザ支援システム "HURIC". 情報処理学会ヒューマンインタフェース研究会報告 95-HI-59, pp. 31-36, 1995.
- [藤井 99a] 藤井隆夫, 浅間一, 倉林大輔, 喜悅早人, 遠藤聡. 知的データキャリアによる群ロボットの機能創発. 日本ロボット学会誌, Vol. 17, No. 6, pp. 848-854, 1999.
- [藤江 99b] 藤江真也, 小林哲則. 自律型ロボットの行動を介した言語獲得. 人工知能学会全国大会予稿集, pp. 223-224, 1999.
- [古田 99] 古田一雄. 行動発話分析によるプラント運転員の知識モデル構築. 人工知能学会誌, Vol. 14, No. 6, pp. 989-1000, Nov. 1999.
- [星野 98] 星野由紀子, 鈴木保匡, 山本英子, 廣川嘉隆, 稲葉雅幸, 井上博允. 日常生活での視覚触覚対話行動研究のための卓上全身型ロボットの開発. 第16回日本ロボット学会学術講演会予稿集, pp. 5-6, 1998.
- [松山 89] 松山隆司. Dempster-Shafer の確率モデルに基づく Evidential Reasoning の論理的意味に関する考察. 人工知能学会誌, Vol. 4, No. 3, pp. 340-350, May 1989.
- [松井 95] 松井俊浩, 速水信, 麻生英樹, 原功, 本村陽一. 学習型所内事情通ロボットの計画. 第13回日本ロボット学会学術講演会予稿集, pp. 1065-1066, 1995.
- [松井 97a] 松井俊浩. おせっかいロボットとも呼ばれる事情通ロボットの計画. *biz*, Vol. 29, No. 12, pp. 4-11, 1997.
- [松本 97b] 松本吉史, 坂井弘弘, 稲邑哲也, 稲葉雅幸, 井上博允. PC ベースのハイパーマシン: 知能ロボットの汎用カーネル. 第15回日本ロボット学会学術講演会予稿集, pp. 979-980, Sep. 1997.
- [松本 97c] 松本央夫. ビューバーストアプローチによる移動ロボットの経路誘導に関する研究. 博士論文, 東京大学大学院工学系研究科情報工学専攻, Dec. 1997.
- [松本 97d] 松本吉史, 稲葉雅幸, 井上博允. 視野画像列を利用した経路表現に基づくナビゲーション. 日本ロボット学会誌, Vol. 15, No. 2, pp. 236-242, 1997.
- [松井 98a] 松井俊浩, 麻生英樹, 浅野大, John Fry. オフィスロボット Jijo-2 の対話理解. 第16回日本ロボット学会学術講演会予稿集, 1998.
- [松本 98b] 松本吉史, 池田和雄, 稲邑哲也, 稲葉雅幸, 井上博允. 全方位画像列に基づくナビゲーション: 自律移動による地図の獲得. 日本機械学会ロボティクスメカトロニクス講演会 '98, pp. 1B13-2, 1998.

- [三浦 92] 三浦純, 白井良明. 不確かさを考慮した視覚と行動のプランニング. 人工知能学会誌, Vol. 7, No. 5, pp. 850-861, 1992.
- [宮本 98] 宮本正城, 星野由紀子, 稲葉雅幸, 井上博允. 卓上全身体ロボットでの視覚に基づく人の発見と挨拶行動の実現. 第16回日本ロボット学会学術講演会予稿集, pp. 3-4, 1998.
- [宮崎 99] 宮崎淳史. 音声認識プログラム ViaVoice の技術と今後. *bit*, Vol. 31, No. 11, pp. 29-35, 1999.
- [村木 96] 村木一吾. (自然言語処理+利用者) × 対象=知的自然言語システム. 人工知能学会誌, Vol. 11, No. 4, pp. 522-529, July 1996.
- [毛利 95] 毛利隆夫. Nearest neighbor 法と記憶に基づく推論. 人工知能学会誌, Vol. 12, No. 2, pp. 188-195, Mar 1995.
- [本村 97] 本村陽一. 最適なベイズ識別のための状況依存の事前確率の学習. 第8回日本神経回路学会全国大会講演論文集, 1997.
- [本村 99] 本村陽一, 赤穂昭太郎, 麻生英樹. ベイジアンネットワーク学習の知能システムへの応用. 計測と制御, Vol. 38, No. 7, pp. 468-473, July 1999.
- [森 95] 森武俊. 動作認識: その手法と応用. 第13回日本ロボット学会学術講演会予稿集, pp. 237-240, 1995.
- [山本 92a] 山本吉伸, 佐藤光, 関一夫, 山崎信行, 安西祐一郎. オフィスロボットシステム HuRIS - RSCW の提案-. 情報処理学会第44回全国大会論文集, pp. 2-79-2-80, 1992.
- [山本 92b] 山本吉伸, 佐藤光, 山崎信行, 安西祐一郎. 人間とロボットの協調作業は可能か? - オフィスロボットシステム HuRIS -. 情報処理学会 HI 研究会資料, Vol. 92, pp. 117-124, 1992. HI-41-16.
- [山崎 95] 山崎信行, 安西祐一郎. Active Interface を用いた会場案内システムの設計と実装. 第13回日本ロボット学会学術講演会予稿集, pp. 1107-1108, 1995.
- [山崎 96] 山崎信行, 安西祐一郎. パーソナルロボット用機能別並列計算機アーキテクチャ ASPIRE の RISC を用いた設計と実装. 日本ロボット学会誌, Vol. 14, No. 4, pp. 593-601, 1996.
- [山村 97] 山村雅幸. Bayesian Network 上の強化学習. 第24回知能システムシンポジウム, pp. 61-66, 1997.
- [髙野 99] 髙野翔一. アダプティブ・クルーズコントロールにおけるヒューマンファクタ. 日本ロボット学会誌, Vol. 17, No. 3, pp. 35-37, Apr 1999.

付録 A

A.1 Bayesian Network における再帰的な確率伝播計算法

Bayesian Network の特徴の一つは、従来のベイズ則を元に算出する方法にくらべ、非常にシンプルな確率算出の方法にある。複数の事象がノードとしてネットワーク構造に配置されているため、それぞれの事象に対する観測結果から、推論目的の事象の条件付き確率を求めようとすると、計算式が煩雑になり、かつ簡単なアルゴリズムで計算する事ができない。

ここでアルゴリズムを説明するにあたって必要となる用語について説明を加える。確信度:BEL は証拠となる事象が観測された時に、推論しようとしている事象がどの程度の確率で起こるかを示すものである。証拠となる観測事象を e として、

$$BEL(x) = P(x|e) \quad (A.1)$$

となる。この確信度は事象 x が持つ確率変数の次元と同じ次元のベクトルとなる。ノード x とノード y の確率的な関係を表すには、条件付き確率表 (CPT:Conditional Probability Table) を使用する。(以下 CPT と呼ぶ) この CPT はマトリクスの形で表現される。例えば、ノード X における確率変数を (x_1, x_2, \dots, x_m) とし、ノード Y における確率変数を (y_1, y_2, \dots, y_n) とすると、CPT を表すマトリクス $M_{y|x}$ は

$$\begin{aligned} M_{y|x} &\stackrel{\text{def}}{=} P(Y = y|X = x) \\ &= \begin{pmatrix} P(y_1|x_1) & P(y_2|x_1) & \dots & P(y_n|x_1) \\ P(y_1|x_2) & P(y_2|x_2) & \dots & P(y_n|x_2) \\ \vdots & \vdots & \ddots & \vdots \\ P(y_1|x_m) & P(y_2|x_m) & \dots & P(y_n|x_m) \end{pmatrix} \end{aligned} \quad (A.2)$$

となる。また、二つのベクトル $f(x)$ $g(x)$ の積として、項ごとに積演算を行なうものとする。

$$(1, 2, 3)(3, 2, 1) = (1 \times 3, 2 \times 2, 3 \times 1) = (3, 4, 3) \quad (A.3)$$

内積の場合は「 \cdot 」を用いる

$$(1, 2, 3) \cdot (3, 2, 1) = 1 \times 3 + 2 \times 2 + 3 \times 1 = 10 \quad (A.4)$$

また、次の式

$$f(x) \cdot M_{y|x} \stackrel{\text{def}}{=} \sum_x f(x) M_{y|x} \quad (A.5)$$

を良く使用するので留意されたい。ベクトルの各項の和が1となるように、正規化係数として α を用いる。

$$\alpha(1, 1, 3) = (0.2, 0.2, 0.6) \quad (\text{A.6})$$

以下から、確率伝播のアルゴリズムについて概説するが、ネットワークの構造上大きく3つ分けて説明を行なう。それぞれ、Chain型、Tree型、PolyTree型である。

A.1.1 Chain型ネットワークにおける確率伝播

次式

$$\begin{aligned} \lambda(x) &= P(e^-|x) \\ \pi(x) &= P(x|e^+) \end{aligned} \quad (\text{A.7})$$

において、 $\lambda(x)$ と $\pi(x)$ を定義する。ここで e^-, e^+ は証拠変数であり、

$$\begin{aligned} BEL(x) &\stackrel{\text{def}}{=} P(x|e^+, e^-) \\ &= \alpha P(e^-|x) P(x|e^+) \\ &= \alpha P(e^-|x) P(x|e^+) \\ &= \alpha \lambda(x) \pi(x) \end{aligned} \quad (\text{A.8})$$

として、確信度 $BEL(x)$ を表現する事にする。これらのベクトル $\lambda(x), \pi(x)$ はノード X に関する情報であるが、この情報は、ノード間のアークを伝わって隣接するノードの λ, π に影響を与える。すなわち、証拠のノードに入力された確率の値を伝播させて、推論すべきノードの確信度を求めて行くわけである。 λ について、確率の伝播は

$$\begin{aligned} \lambda(x) &= \sum_y P(e^-|y, x) P(y|x) \\ &= \sum_y P(e^-|y) P(y|x) \\ &= M_{y|x} \cdot \lambda(y) \end{aligned} \quad (\text{A.9})$$

のように行なわれる。 π については、

$$\begin{aligned} \pi(x) &= P(x|e^+) \\ &= \sum_u P(x|u, e^+) P(u|e^+) \\ &= \sum_u P(x|u) \pi(u) \\ &= \pi(u) \cdot M_{x|u} \end{aligned} \quad (\text{A.10})$$

つまり、 π の情報¹ は親ノードから子ノードへ、 λ の情報は子ノードから親ノードへ、と伝播して行く。親ノードを持たないルートノード (Root Node) では、あらかじめ与えられた事前確率 (Prior Probability) を π とする。また、子ノードを持たない葉ノード (Leaf Node) は主に観測や証拠を表すノードとして扱われ、事象が観測された場合は、その観測結果が λ に代入され、観測されない場合は、デフォルト値として、 λ の全ての要素を1とするベクトルが代入される。

A.1.2 Tree型ネットワークにおける確率伝播

次に、Figure A.1 のように親ノードに複数の子ノードが連結する、Tree型のネットワーク構造の場合の確率伝播について説明する。ただし、あるノードに対して、親ノードは唯一しか存在しないものとする。この場合はほぼChain型の場合と同様の伝播である。 e_X^- をノード X より下側に存在するノードにおける証拠とし、 e_X^+ をノード X より上側に存在するノードにおける証拠とする。このような定義のもとでも確信度 $BEL(x)$ の定義は同様に、

$$\begin{aligned} BEL(x) &= P(x|e_X^+, e_X^-) \\ &= \alpha P(e_X^-|e_X^+, x) P(x|e_X^+) \\ &= \alpha P(e_X^-|x) P(x|e_X^+) \end{aligned} \quad (\text{A.11})$$

ここで、

$$\lambda(x) = P(e_X^-|x) \quad (\text{A.12})$$

および、

$$\pi(x) = P(x|e_X^+) \quad (\text{A.13})$$

とすることにより、

$$BEL(x) = \alpha \lambda(x) \pi(x) \quad (\text{A.14})$$

となる。ここで、確率の伝播のルールをまとめる。まず、ボトムアップの方向として、 $\lambda_X(u)$ を $\lambda(x)$ から計算する伝播則と、 $\lambda(x)$ を $\lambda_Y(x)$ から計算する伝播則と二つある。それぞれ、

$$\begin{aligned} \lambda_X(u) &= \sum_x P(e_X^-|u, x) P(x|u) \\ &= \sum_x P(e_X^-|x) P(x|u) \\ &= \sum_x \lambda(x) P(x|u) \\ &= M_{x|u} \cdot \lambda(x) \end{aligned} \quad (\text{A.15})$$

¹ π -message とち言う




Figure A.1: Network of Tree Type Structure

および

$$\lambda(x) = \prod_j \lambda_{Y_j}(x) \quad (\text{A.16})$$

である。

一方、トップダウン方向の伝播として、 $\pi_{Y_j}(x)$ および $\pi(x)$ を求める法則は次の通りである。

$$\begin{aligned} \pi(x) &= \sum_u P(x|u) \pi_X(u) \\ &= \pi_X(u) \cdot M_{x|u} \end{aligned} \quad (\text{A.17})$$

$$\pi_{Y_j}(x) = \alpha \pi(x) \prod_{k \neq j} \lambda_{Y_k}(x) \quad (\text{A.18})$$

A.1.3 Poly Tree 型ネットワークにおける確率伝播

最後に、Poly Tree 型のネットワークにおける伝播について説明する。Poly Tree とは Tree 型とは異なり、複数の親を持つ事ができる。今まで使用して来た証拠を表す e_X^- と e_X^+ について再定義を行なう。

$$\begin{aligned} e_X^- &= \{e_{XY_1}^-, \dots, e_{XY_m}^-\} \\ e_X^+ &= \{e_{XY_1}^+, \dots, e_{XY_m}^+\} \end{aligned} \quad (\text{A.19})$$

$e_{XY_j}^-$ は、ノード Y_j について、ノード X より上側に存在する証拠を意味する。同様に $e_{U_iX}^+$ は、ノード U_i について、ノード X より下側に存在する証拠を意味する。

この場合の伝播則は、 $\lambda(x)$ については計算方法が変わらない。

$$\begin{aligned} \lambda(x) &= P(e_X^- | x) \\ &= P(e_{XY_1}^-, \dots, e_{XY_m}^- | x) \\ &= P(e_{XY_1}^- | x) \cdot P(e_{XY_2}^- | x) \dots P(e_{XY_m}^- | x) \\ &= \prod_j \lambda_{Y_j}(x) \end{aligned} \quad (\text{A.20})$$

ここで、 $\lambda_{Y_j}(x)$ はもちろん、 $P(e_{XY_j}^- | x)$ を意味する。また、 $\pi(x)$ については、

$$\begin{aligned} \pi(x) &= P(x | e_X^+) \\ &= P(x | e_{U_1X}^+, \dots, e_{U_nX}^+) \\ &= \sum_{u_1, \dots, u_n} P(x | u_1, \dots, u_n) P(u_1, \dots, u_n | e_{U_1X}^+, \dots, e_{U_nX}^+) \\ &= \sum_{u_1, \dots, u_n} P(x | u_1, \dots, u_n) P(u_1 | e_{U_1X}^+) P(u_2 | e_{U_2X}^+) \dots P(u_n | e_{U_nX}^+) \end{aligned}$$

ここで、

$$\pi_X(u_i) = P(u_i | e_{U_iX}^+) \quad (\text{A.21})$$

として、

$$\begin{aligned} \pi(x) &= \sum_{u_1, \dots, u_n} P(x | u_1, \dots, u_n) \pi_X(u_1) \pi_X(u_2) \dots \pi_X(u_n) \\ &= \sum_u P(x | u) \prod_{i=1}^n \pi_X(u_i) \end{aligned} \quad (\text{A.22})$$

ここで注意しなければならないのが、 u_1, \dots, u_n の扱いである。ここで簡単のために、 U_1, U_2 の二つの親ノードが存在したとして、その確率変数がそれぞれ $U_1 = (\text{True}, \text{False})$, $U_2 = (\text{Good}, \text{Bad})$ だとする。この時の u_1, u_2 はこの二つのノードをまとめて一つのノードであるかのように扱った時の、確率変数を意味する。すなわち、

$$(u_1, u_2) = \{(\text{True}, \text{Good}), (\text{True}, \text{Bad}), (\text{False}, \text{Good}), (\text{False}, \text{Bad})\}$$

となる。すなわち、式 A.21 の \sum は 4 項の和となる。さらに、 $\pi(x)$ がベクトルである事を考慮すると、

$$\pi(x) = P(x | e_X^+)$$

$$\begin{aligned}
&= \sum_{u_1, u_2} P(x|u_1, u_2) P(u_1 | e_{\bar{U}_1, X}^+) P(u_2 | e_{\bar{U}_2, X}^+) \\
&= P(x|u_1 u_2 = TG) P(u_1 = T | e_{\bar{U}_1, X}^+) P(u_2 = G | e_{\bar{U}_2, X}^+) \\
&\quad + P(x|u_1 u_2 = TB) P(u_1 = T | e_{\bar{U}_1, X}^+) P(u_2 = B | e_{\bar{U}_2, X}^+) \\
&\quad + P(x|u_1 u_2 = FG) P(u_1 = F | e_{\bar{U}_1, X}^+) P(u_2 = G | e_{\bar{U}_2, X}^+) \\
&\quad + P(x|u_1 u_2 = FB) P(u_1 = F | e_{\bar{U}_1, X}^+) P(u_2 = B | e_{\bar{U}_2, X}^+)
\end{aligned}$$

これを $\pi_X(u_i)$ を使って表現すると,

$$\begin{aligned}
\pi(x) &= \sum_{u_1, u_2} P(x|u_1, u_2) \pi_X(u_1) \pi_X(u_2) \\
&= P(x|u_1 u_2 = TG) \pi_X(u_1 = T) \pi_X(u_2 = G) \\
&\quad + P(x|u_1 u_2 = TB) \pi_X(u_1 = T) \pi_X(u_2 = B) \\
&\quad + P(x|u_1 u_2 = FG) \pi_X(u_1 = F) \pi_X(u_2 = G) \\
&\quad + P(x|u_1 u_2 = FB) \pi_X(u_1 = F) \pi_X(u_2 = B)
\end{aligned}$$

すなわち, $\pi_X(u_1) \pi_X(u_2)$ の結果 (これを $\pi_X(u)$ と呼ぶ) は, 単なるベクトルの積ではなく,

$$\pi_X(u_1) = \begin{pmatrix} a \\ b \\ c \end{pmatrix} \pi_X(u_2) = \begin{pmatrix} d \\ e \end{pmatrix}$$

とした時,

$$\pi_X(u) = \begin{pmatrix} ad \\ ae \\ bd \\ be \\ cd \\ ce \end{pmatrix}$$

と計算する事である。この $\pi_X(u)$ と $P(x|u)$ を用いて,

$$\begin{aligned}
\pi(x) &= \sum_u P(x|u) \pi_X(u) \\
&= \pi_X(u) M_{x|u}
\end{aligned} \tag{A.23}$$

とも書くことができる。

λ の更新

次に

$$\lambda_X(u_i) = P(e_{\bar{U}_i, X}^- | u_i) \tag{A.24}$$

の更新について説明する。説明の中で新しくノード V を定義する。このノードは, X の親ノードのうち, 現在対象としている親ノード u_i を除いた全ての親ノードを表しており,

$$V = U - U_i = \{U_1, \dots, U_{i-1}, U_{i+1}, \dots, U_n\} \tag{A.25}$$

で表されるテンポラリのノードである。ここで $e_{\bar{U}_i, X}^-$ を

$$e_{\bar{U}_i, X}^- = \{e_{V, X}^+, e_X^-\} \tag{A.26}$$

のように分解する。ただし,

$$e_{V, X}^+ = \bigcup_{k \neq i} e_{\bar{U}_k, X}^+ \tag{A.27}$$

である。順に式を追って行くと,

$$\begin{aligned}
\lambda_X(u_i) &= P(e_{V, X}^+, e_X^- | u_i) \\
&= \sum_x \sum_v P(e_{V, X}^+, e_X^- | u_i, v, x) P(v, x | u_i) \\
&= \sum_x \sum_v P(e_X^- | x) P(e_{V, X}^+ | v) P(v, x | u_i) \\
&= \beta \sum_x \sum_v P(e_X^- | x) \frac{P(v | e_{V, X}^+)}{P(v)} P(x | v, u_i) P(v | u_i) \\
&= \beta \sum_x \sum_v P(e_X^- | x) P(v | e_{V, X}^+) P(x | v, u_i)
\end{aligned}$$

ここで, 式 (A.25) と式 (A.27) より,

$$\begin{aligned}
P(x | v, u_i) &= P(x | u) \\
P(v | e_{V, X}^+) &= \prod_{k \neq i} P(u_k | e_{\bar{U}_k, X}^+) = \prod_{k \neq i} \pi_X(u_k)
\end{aligned}$$

であるので, これを用いて,

$$\lambda_X(u_i) = \beta \sum_x \lambda(x) \sum_{u_k, k \neq i} P(x | u) \prod_{k \neq i} \pi_X(u_k) \tag{A.28}$$

となる。このままでは少々理解しづらいので, 実際に具体例を使って解説を加える。

Figure A.2 に示すような, 親ノードが u_1 から u_3 までである状況を考える。求めるものは $\lambda_X(u_i)$ である。




Figure A.2: Example of poly tree structure network

$$\begin{aligned}
 \lambda_X(u_1) &= \beta \sum_x \sum_{u_2, u_3} \lambda(x) P(x|u) \prod_{k \neq 1} \pi_X(u_k) \\
 &= \beta \sum_x \sum_{u_2, u_3} \lambda(x) P(x|u) \pi_X(u_2) \pi_X(u_3) \\
 &= P(x = Fi | u_1, u_2 = Tr, u_3 = Go) \lambda(x = Fi) \pi_X(u_2 = Tr) \pi_X(u_3 = Go) \\
 &\quad + P(x = Fi | u_1, u_2 = Tr, u_3 = Ba) \lambda(x = Fi) \pi_X(u_2 = Tr) \pi_X(u_3 = Ba) \\
 &\quad \vdots \\
 &\quad + P(x = Ra | u_1, u_2 = Fa, u_3 = Ba) \lambda(x = Ra) \pi_X(u_2 = Fa) \pi_X(u_3 = Ba)
 \end{aligned}$$

となる。ここで、この $P(x = Fi | u_1, u_2 = Tr, u_3 = Go)$ は Figure A.3 に示す通り、網がけの部分の要素を意味している。すなわち、この要素は u_1 の次元数と同じベクトルを表現しており、そのベクトルを x, v の組み合わせの数だけ足し合わせる計算を行なう事になる。

u_1, u_2, u_3			X	Fine	Rain
Head	True	Good			
Head	True	Bad			
Head	False	Good			
Head	False	Bad			
Tail	True	Good			
Tail	True	Bad			
Tail	False	Good			
Tail	False	Bad			

Figure A.3: Lambda part of CPT

