



### ★第1章：人工知能概論

- 1-1. 人工知能とは
- 1-2. ディープラーニング（深層学習）
- 1-3. 弱い人工知能（AI）と強い人工知能（AI）
- 1-4. 人工知能の利用動向
- 1-5. 今後の展望
- 1-6. 制度的課題：知的財産の観点

### ★第2章：ディープラーニングの基礎知識

- 2-1. 人工知能の手法一覧
- 2-2. 統計的手法
- 2-3. 推論と探索
- 2-4. エキスパートシステム
- 2-5. 機械学習



第1章：人工知能概論

### ■ 人工知能のFAQ（人工知能学会のサイトより抜粋）

#### ■ Q. 人工知能とは何でしょうか？

A. 知的な機械、特に、知的なコンピュータプログラムを作る科学と技術です。人の知能を理解するためにコンピュータを使うことと関係がありますが、自然界の生物が行っている知的手段だけに研究対象を限定することはありません。

#### ■ Q. では、知能とは何でしょうか？

A. 知能とは、実際の目標を達成する能力の計算的な部分です。人間、動物、そして機械には、種類や水準がさまざまな知能があります。

#### ■ Q. AIは人の知能をまねようとしているのではないのですか？

A. ときにはそうしますが、いつもというわけではありません。あるときは、機械に問題を解決させることについて、他人や自分自身がどうするかを調べます。一方、AIのほとんどの研究は、人間や動物について研究するよりも、知的に解決しなければならない問題そのものについて研究しています。AI研究者は、人間がやらないような方法や、人間ができるよりも多くの計算を伴う方法を用いることもできます。

人工知能学会は、人工知能の研究には二つの立場があると述べています。立場の違いをこのように定義してよいか、また、これらの立場は本当に異なるのかということについて議論の余地がありますが、1つは人間の知能そのものを持つ機械を作ろうとする立場、もう1つは人間が知能を使ってすることを機械にさせようとする立場です。そして、実際の研究のほとんどは後者の立場で進められています。ですので、人工知能の研究といっても、人間のような機械を作っているわけではありません。それでは、実際にどのような研究が行われているのか、その例をみていきましょう。

### [エキスパートシステム]

専門家の知見をルールとして蓄積し、推論の手法を用いて問題を解決するシステムです。

## [音声認識]

マイクに向かって話した内容をコンピュータに理解させる研究です。カーナビゲーションなどのシステムで実用化されています。車内などの限定された状況以外での認識を可能にしたり、誰が話しているのかを特定する研究などに発展しています。

## [画像認識]

カメラなどで撮った内容をコンピュータに理解させる研究です。コンピュータ内にある絵の内容を理解させる画像理解と、絵の明るさや色調（例えば、デジタルカメラのセピア調など）を変えたりする画像処理とに大きく分けられます。画像処理は実用化されていますが、画像理解はまだ研究段階です。

## [機械学習]

観測センサーやその他の手段で収集されたデータの中から一貫性のある規則を見つけ出そうとする研究です。数学の統計の分野と強い関連があります。また、機械学習はAIの他のほとんどの分野で利用されています。

## [自然言語処理]

文章に何が書かれているか、その意味内容をコンピュータに理解させる研究です。音声認識や情報検索の分野に応用されています。

## [情報検索]

蓄積されたデータの中から人間が必要とするものを見つけ出すための技術です。WWWの検索エンジンなどで活用されています。

## [推論]

いろいろなルールを統合して矛盾のない答えを導き出すための手法です。最も基本になるのはアリストテレスの三段論法というものです。これは「ソクラテスは人間である。人間は死ぬ。よって、ソクラテスは死ぬ」という

三段階で結論を出すものです。

#### [探索]

データの集まりから条件に合うものを見つけ出す手法です。データの数が多く、条件が複雑なので様々な工夫が必要になります。機械学習や推論の基盤となる技術です。

#### [データマイニング]

データベース技術と機械学習が結びついた技術で、大量の整理されていないデータから役に立つと思われる情報を見つけ出す手法です。例えば、ネット上で買い物をする際、あなたの趣味に合ったおすすめ品が示されることがあると思います。これは、今までの買い物のデータをもとに顧客の好みをデータマイニングによって調べています。

#### [ニューラルネット]

生物の神経をもとにした手法です。機械学習の有力な手法として発展し、AIの各分野で活用されています。

## 人工知能とは

- レベル1：単純な制御プログラム  
マーケティング的に「人工知能」を名乗っているだけ
- レベル2：古典的な人工知能  
推論、探索、知識ベースなどにより、組み合わせが極端に多い入力と出力を関係付ける方法を定義する
- レベル3：機械学習を取り入れた人工知能  
サンプルやデータをもとに入力と出力の関係であるルールや知識を自ら学習する  
入力は、目的に応じて入力対象の特徴をあらわすもの（特徴量）である必要がある
- レベル4：ディープラーニングを取り入れた人工知能  
特徴量自体を学習する機械学習

（松尾豊：『人工知能は人間を超えるか』より）

レベル1の単純な制御プログラムは、自ら学習するような機能を持っておらず、従来からある単純な制御プログラムです。例えば、気温の変化に合わせてエアコンのON、OFFを制御するようなプログラムはレベル1に分類されます。制御できる範囲も狭く、実際には人工知能ではありませんが、人工知能搭載等の謳い文句で発売されます。

レベル2の古典的な人工知能は、大量のデータや情報などを読み込んでおき、条件分岐により多岐に渡る制御を行うことができるプログラムを指します。これも、人工知能が自ら学習するような機能はありません。なので、条件分岐については、人間がこのような条件ならこのような制御を行うと予めプログラムしておかなければなりません。エキスパートシステムと呼ばれる人工知能を利用して専門的な知識を扱えるようにしたシステムもここに該当します。

レベル3の機械学習を取り入れた人工知能は、Googleに代表される検索エンジンや、ビッグデータの解析、手書き文字の認識などに利用されています。この人工知能では、人間が特徴のある入力（学習データ）を用意する必要があり、事前にその特徴のある入力と出力の関係からパターンやルールを学習します。そして学習したパターンやルールを使用し、新しい入力に対する出力を導き出します。

レベル4のディープラーニングを取り入れた人工知能は、入力の特徴を数値化した特徴量自体を学習することができます。これにより、レベル3で人間が入力を用意していた工程を機械が担うこととなります。人の顔から年齢や感情を判定する技術や、車の自動運転などの技術に活用されています。

## 人工知能とは

■ 人工知能 (Artificial Intelligence, AI) とは、人工的にコンピュータ上などで人間と同様の知能を実現させようという試み、あるいはそのための一連の基礎技術を指す (wikipediaより)

■ 様々なアルゴリズムで上記のことを実現しようとしている

### 機械学習

- ニューラルネットワーク (今回のテーマはここ)
- 強化学習、遺伝的アルゴリズム、サポートベクターマシン (SVM)

### データマイニング

- 主成分分析、クラスタ分析

### ゲーム理論

### その他

今回のAI講座ではニューラルネットワークについて学習しますが、ニューラルネットワークにかかわる機械学習の分類である、教師あり学習、教師なし学習、強化学習について説明します。

教師あり学習は、入力に対して正しい出力が用意されている学習データを使用し、入力と出力の関係を学習するものです。学習した入出力の関係性から予測や分類を行う際には、教師あり学習が利用されます。教師なし学習は、入力のみ与えられ正しい出力は用意されていません。それは正解が分からないことを意味しますから、入力から特徴量を求めることで、正解の分からない未知のデータに対する予測や、クラスタリングに利用されています。ニューラルネットワークは教師あり学習、教師なし学習どちらを行う手法としても活用できます。

強化学習は、機械自身が成功と失敗を繰り返しながら学習していく方法です。囲碁で有名になった人工知能「AlphaGo」は、この強化学習を採用しています。どのように機械が学習していくかという、例えば、ロボットを歩かせたい場合、今までは人間がロボットの姿勢を制御するプログラムや体の動きを制御するプログラムを作成し、失敗したら人間が再度プログラムを作り直すというように繰り返していました。しかし強化学習では、ロボットを歩かせてその動きによって、ロボットに対して報酬を与えるようにします。1m歩いたときより、10m歩いたときの報酬を高くします。これを繰り返すことでロボットはより大きな報酬を得られる方法を探します。このように、機械自身が価値を最大化するような学習を強化学習といいます。

### ■ ニューラルネットワーク (wikipediaより)

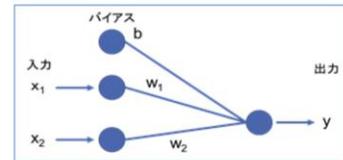
人工神経を相互接続したもので計算を構造化し、コネクショニズム的計算技法で情報を処理する

入力と出力の間の複雑な関係をモデル化する

データのパターン認識や観測された変数間の未知の同時分布における統計的構造を捉える

### ■ ディープラーニング

多層のニューラルネットワークによる機械学習手法 (詳細は後述)



$$y = w_1 x_1 + w_2 x_2 + b$$

単純パーセプトロンの例

コンピュータは非常に高速に計算をすることができますが、人間のように見たものが一体何なのかを認識することは不得意です。この問題を解決するために、脳の神経回路網を模してニューラルネットワークが生まれました。

生物の脳の神経細胞であるニューロンは、ネットワークを形作りニューロン同士の間で信号を伝えています。1つのニューロンに焦点を当ててみると、あるニューロンは複数のニューロンから信号を受け取ります。このとき、受け取る信号は大きさがまちまちであるため、同じ大きさの信号を複数受け取るわけではありません。受け取った信号の和が、ある一定の大きさを超えた時、他の複数のニューロンに対して信号を送ります。このプロセスが何度も繰り返されることで、脳では色々な情報を認識されています。このようなニューロンの集合体としての働きを

、数学的モデルにしたのがニューラルネットワークです。また、脳の神経回路網をコンピュータ上でモデルとして再現しようという考え方をコネクショニズムといいます。

- 入力と出力の間の複雑な関係をモデル化する
  - 分類（出力がグループのラベル）
    - 判別、領域抽出など
  - 回帰（出力が連続値）
    - 未来予測など
- ディープラーニングの利点
  - データの前処理（特徴量への変換）が従来の機械学習ほど必要でない
- ディープラーニングの欠点
  - 大量の学習データが必要
    - 近年ではセンサーデバイスの普及により、大量のデータが取得しやすくなった

機械学習を用いると、入力と出力の間の複雑な関係をモデル化することができます。分類とは、例えば、写真に写っている動物が猫なのか犬なのか分類することを指します。分類では、学習データに正解データ（ラベル）が付いており、コンピュータは入力から割り出した出力を正解データと比べながら、入力と出力の関係をモデル化していきます。つまり、前述した教師あり学習に分類されます。正解データは教師データともいわれます。回帰とは、明日の天気や株価等、未知のデータを予想することを指します。回帰で用いられる学習データは連続したデータであり、天気や株価であれば過去の時系列データを使用します。この連続した学習データから入力と出力の関係をモデル化し、未知のデータを予想します。学習に用いられる連続したデータには答えがあるため、こちらも教師あり学習に分類されます。

ディープラーニングでは「データの前処理が必要ない」ということが利点です。人間の手によって行われる作業が機械に置き換わり、前処理のためにかける時間や専門知識が以前よりは少なくなったことを意味しています。このように人間の手間が少なくなった一方で、今度は膨大な量のデータが必要になりました。近年ではIoT等を含めセンサーデバイスが普及し、以前よりデータは取得しやすくなってきています。

### ■ きのこの山とたけのこの里の分類（Interface 2017年8月号より）

#### ■ 従来の機械学習（SVM）

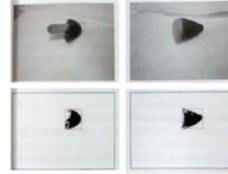
入力対象の何を抽出し、どうやって解析するかを人間が考える

1. きのこの山は柄の部分が細いので白い部分が多そうだ
2. きのこの山は傘の部分に凹凸が多そうだ

画像取得→2値化（チョコの部分抽出）

1. バウンディングボックス内の白と黒の面積比の計算
2. 黒い部分の頂点を検出し頂点数を求める

分類対象を1.と2.の数値データで表している



(Interface 2017年8月号 p.33)

#### ■ ディープラーニング

取得した画像を入力データとする

- 画像の画素値が入力データ



(Interface 2017年8月号 p.33)

従来の機械学習と、ディープラーニングの違いに、人間が特徴量の抽出をしなくてよくなったことが挙げられます。図の例のように、入力対象の何を抽出し、どうやって解析するかというのは、人間の経験と知識により決めなければなりませんでした。このような技術の特徴量エンジニアリングといいますが、これはとても専門的な知識を必要とする技術であるため、時間と手間がかかり、機械学習の普及にも悪影響を及ぼし、人工知能の実用化が進まない原因にもなっていました。しかし、ディープラーニングでは、膨大な量のデータから入力対象の何を抽出し、どのように解析するかというパターンやルールをコンピュータ自身が見つけ出します。つまり、特徴量をコンピュータ自身が学習から見つけ出します。その結果、未知のデータからも答えを導き出すことが可能になるのです。

## ディープラーニング（深層学習）

- 畳み込みニューラルネットワーク  
Convolutional Neural Network、CNN  
教師あり学習  
画像データの扱い、認識、分類に強い
- リカレントニューラルネットワーク  
Recurrent Neural Network、RNN  
教師あり学習  
時系列データの扱い、未来予測や自動作文に強い
- オートエンコーダ  
Auto Encoder、AE  
教師無し学習  
ノイズ除去や画像生成に強い

All Rights Reserved, Copyright© UHD2018

10

ニューラルネットワークの詳しい仕組みは後述しますが、ここでは代表的なディープラーニングの種類について紹介します。

ニューラルネットワークの中でも、特に近年脚光を浴びているのが畳み込みニューラルネットワークです。その特徴として、ネットワークの仕組み自体は簡潔であるにもかかわらず、複雑なパターン認識問題に対応することが可能であることが挙げられます。ネットワークの仕組みが簡潔であるということは、入力から出力を判断するまでの計算が少ないことを意味します。

一般的なニューラルネットワークの手法は、ある任意の独立した時間において、入力から出力を判断します。しかし、未来予測等を行うには任意の時間だ

けでなく、時系列を考慮して判断する必要があります。そのために開発された手法がリカレントニューラルネットワークです。リカレントニューラルネットワークでは、前の時間に得た情報を次の時間に反映させることで最終的な出力を得ることができます。

オートエンコーダとは、与えられた入力の特徴を獲得するための手法です。オートエンコーダでは、入力の次元を減らすことで特徴を抽出します。例えば、4つの入力を受け、2つの出力を得たとします。今度はその2つの出力を入力とし、4つの出力を得たとします。この時、最初の4つの入力と、最後の4つの出力がほぼ似たような値を得るようであれば、中間で得た2つの出力は、最初の4つの入力の特徴を表しているものといえます。この特徴を表す2つの出力の部分抽出するのがオートエンコーダです。

### ■ CNN

#### できていること

- 画像認識、画像の説明テキスト生成、運転支援、個人特定

#### 今後できそうなこと

- リアルタイムの検査（現在は処理できる画像の解像度は低い）
- 競技の採点
- 農業など、自然を対象とする仕事の自動化

### ■ RNN

#### できていること

- 翻訳、小説作成、電力予測、自動記事作成

#### 今後できそうなこと

- 話し相手、防犯、教育目的（学習管理）

CNNの実用例としては、コンピュータやセキュリティにおける顔認証システムや、写真に写ってしまった第三者の顔や車のナンバープレート等に自動でボカシ処理を入れるシステムなどが挙げられます。実用例からも分かるように、画像の解析や分類に強みを発揮しています。今後の発展として、リアルタイムで映像を解析・認識するシステム（交通事故防止のために道路標識を自動認識するなど）の研究や、農業において収穫物の出来を判定するシステムの研究も行われています。

RNNでは、音声認識を時系列に行うことで、過去に使用された単語や文脈から話の内容を認識するシステムの研究や、大規模な人流の計測を行うことで、災害時の安全な避難・誘導などに役立てるような研究も進んでいます。

### ■ AE

#### できていること

- 低解像度から高解像度への復元、画像生成（画風模倣、筆跡模倣など）

#### できそうなこと

- 芸術作品の生成
- 合成音声による声優

- その他、強化学習など今後も様々な手法があらわれると思います。

AEの活用には、入力された低解像度の画像について局所的な特徴を抽出し、それをもとの高解像度の画像に復元する技術や、入力として与えられた画像の特徴から、似たような特徴を持つ画像の生成技術などが挙げられます。このような技術をより発展させることで、過去の芸術家が用いた手法の特徴を抽出し、芸術品としての特徴を持った作品の生成も期待されています。

CNN、RNN、AEと3つに分けて紹介しましたが、これらを組み合わせた研究も進んでいます。

## ディープラーニング（深層学習）

- 実用的な計算速度が可能となった  
軽い学習アルゴリズムが登場した  
GPUの利用による計算能力の向上
- 大量の学習データ取得が容易になった  
センサーデバイスの普及  
オープンデータの普及
- オープンソースなフレームワークの登場でソフトウェアの実装が簡単になった  
ディープラーニング用のライブラリが公開され、簡単に実装することができるようになった  
しかも実際にGoogleやSonyが社内で行っているもの  
個人レベルでディープラーニングをすぐに扱うことができる

ディープラーニングの普及には、大量の学習データを取得できるか、適したアルゴリズムを作成できるか、対応できるハードウェアを用意できるか、などのハードルがありました。それらが近年解決されようとしているため、ディープラーニングが注目され始めたのです。

計算速度の向上例として、CPUではなくGPUの活用が挙げられます。GPUは、Graphics Processing Unit の略で、画像処理演算に特化しています。ディープラーニングに必要な計算能力は画像処理の計算能力と似ているため、GPUの利用が注目されるようになりました。また、クラウドコンピューティングにより同時に複数台のコンピュータを用いて計算できるようになったことも、計算速度の向上に寄与しています。

大量の学習データを収集する際、人間の手では限界がありますし、膨大な時間がかかってしまいます。これに対して、センサーを備えたデバイスが自動でデータを収集するようになったことで、学習データの収集効率は以前より格段に向上しました。また、大学や研究機関等がオープンデータとして誰でも使用できるデータセットを公開し始めたことも、ディープラーニングを活用しやすくなった一因といえるでしょう。

以前は一から作成しなくてはいけなかったプログラムも、ライブラリの充実によって比較的簡単に作成することができるようになりました。3章で改めて説明しますが、実際に企業が使用しているものも個人で扱うことができる場合があります。

## 弱い人工知能 (AI) と強い人工知能 (AI)

### ■ ジョン・サール (アメリカの哲学者) の造語

#### □ 弱い人工知能

- 人間の全認知能力を必要としない程度の問題解決や推論を行うソフトウェアの実装や研究
- チェスや囲碁など限定された範囲の問題について、一見知的に見える問題解決ができるもの

#### □ 強い人工知能

- 人間の知能に迫るようになるか、人間の仕事をこなせるようになるか、幅広い知識と何らかの自意識を持つもの

#### □ 汎用人工知能 (≡強い人工知能)

- 人間レベルの知能を実現するもの
- 限定された問題を解決する特定型人工知能ではなく、一般的な知能を実現するもの

- 人工知能の効果を最大化するためには、質の高い学習用データを基に付加価値を生み出す学習済みモデルを生成することが重要
- 学習済みモデルを初期状態とし再利用することで、比較的少数の学習データから優れた性能を持つ派生データを得ることができる
- 画像認識や音声認識の領域ではすでに実用性の高い技術として応用が進められている
  - 自動走行における車外走行環境認識、医用画像からの疾病等の診断支援など
  - 家庭や自動車内での音声対話や音声アシスタント、工場での異常音検知など

(AI白書2017より)

- 海外では検索サービスやSNSなどのインターネット空間での活動から得られるデータに対して適用を進めている
- 海外企業がすでに圧倒的なシェアを持つインターネット空間を中心とした人工知能利用に、今後対抗することは容易ではない
- 先行する企業はAIの機能を組み込んだ機械やロボットを普及させることで実空間における消費者との接点も押さえつつある
- 健康情報、自動車の走行データ、工場の稼働データなど、個人や企業の実世界における活動から得られる実空間データへの適用は今後の競争課題

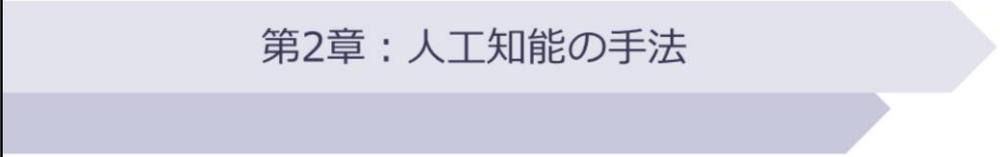
(AI白書2017より)

- 人工知能生成物の知財制度上の扱い
  - 学習済みモデルの利用者の創作的意図が認められない場合は著作物とはみなされない→人工知能の創作物は著作物ではない
  - 学習済みモデル利用者に創作意図と生成物を得るための創作的寄与があれば著作物とみなす
- 学習用データの活用と保護
  - 日本ではインターネット上の著作物を元に学習用データを作成・解析することは営利目的も含めて著作権侵害にならない
  - ただし、そのような学習用データの一般への提供は難しい
  - 海外では国によって異なるが、学習用データをオープンデータとして提供する活動がさかん

既存の学習済みモデルに学習データを追加してモデルを生成する「蒸留モデル」は元のモデルへの依拠性の認定が難しいため、著作権による保護が困難という状況です。

学習済みモデルの保護

- 学習済みモデルはプログラムとパラメータで構成されており、著作権法上の「プログラムの著作物」に該当するかの議論がある
- 著作物に該当しなくても、特許法の要件を満たすならば発明として保護されるとされている
- 著作物や発明に該当しなくても、不正競争防止法上の秘密管理性、有用性、非公知性などの要件を満たせば、「営業秘密」として保護されるとされている
- 既存の学習済みモデルに学習データを追加してモデルを生成する「蒸留モデル」は著作権による保護が困難  
→特許権や契約による保護が議論されている



## 第2章：人工知能の手法

## 2-1. 人工知能の手法一覧

- 統計的手法
- 推論と探索
  - 探索木
- エキスパートシステム
  - If-Thenルール
- 機械学習
  - k-近傍法（教師あり）
  - 決定木、ランダムフォレスト（教師あり）
  - 自己組織化マップ（教師なし）
  - サポートベクターマシン（教師あり）
  - ニューラルネットワーク（教師あり）
  - その他にもいろいろとあります
    - ✓ 遺伝的アルゴリズム
    - ✓ ベイジアンネットワーク
- 深層学習（ディープラーニング）・・・後に詳述

扱う問題によっては、  
従来手法も十分に有効

知能をより具体的に、「何かを判断するために場合分けする」ことと考えます。

## 2-2. 統計的手法

- 回帰・重回帰分析（回帰）
  - 回帰式により説明変数から目的変数を予測
- 判別分析（分類）
  - 判別式により目的変数を判別
- 主成分分析（次元圧縮）
  - 変数の共分散行列や相関行列の固有ベクトルを使って新たな変数を生成する
  - 変数の数が多いデータに対し、変数を統合してデータの傾向を表す
  - 新たな変数を生成することで、より少ない次元でデータを表す

回帰・重回帰分析と判別分析は教師あり、主成分分析は教師なしの手法です。

## 2-3. 推論と探索

### □ 推論

- 人間の思考過程を記号で表現し、実行する

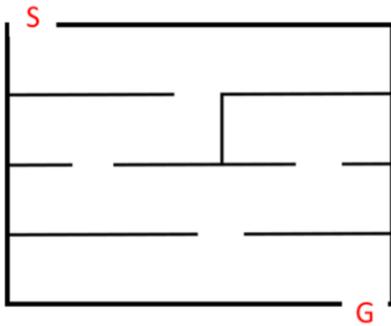
### □ 探索

- 取り得る可能性がある選択肢を木構造（探索木）で表現し、目的のノードまでの経路を調べる

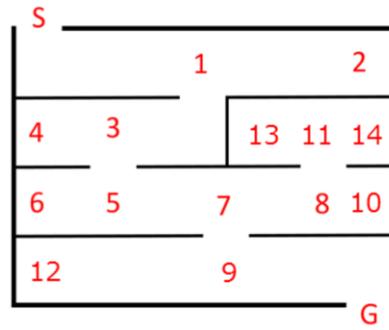
□ 迷路の問題表現

迷路を探索問題として表現する場合、分岐地点と行き止まりに記号を割り当て、経路を表す

迷路

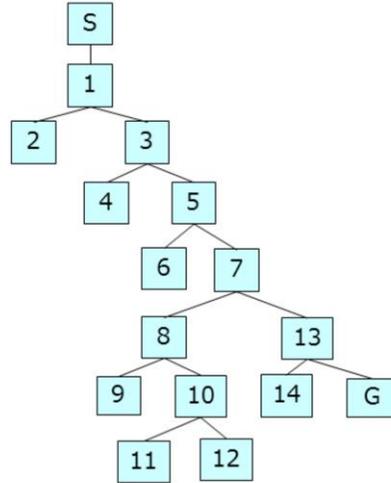
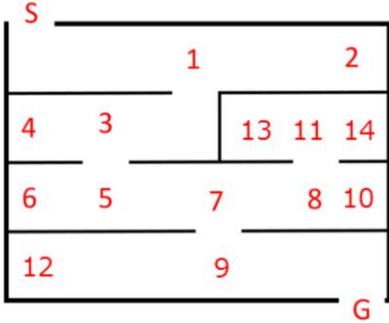


迷路の問題表現



■ 迷路の探索木

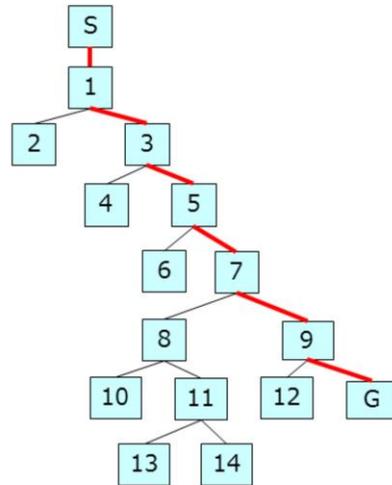
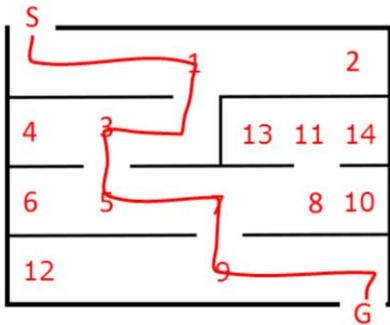
迷路の問題表現



## 探索木

- 幅優先探索、深さ優先探索などでゴールを探索する。

迷路の問題表現



- 盤面を評価するスコアを定義し、指せる可能性のある盤面すべてをノードとする探索木を生成する
- 次の指し手のスコアが良くなるようにノードを探索する
  - ミニマックス法：相手は自分のスコアが最小になるように、自分は自分のスコアが最大になるように指し手を探索する
- 序盤は可能性のある盤面が膨大な数になる
  - 枝刈り法：一定のルールに従ってそれ以上探索しないようにする
- 後半は盤面の可能性が少なくなるため、指し手の決定手法を変更する
  - モンテカルロ法：ランダムに指し手を決定することを繰り返し勝負を終了させる。勝負を終了させることを繰り返して、最も勝つ可能性が高い指し手を選択する。
- 盤面評価（スコア計算）手法など、他にも様々な工夫をしている

ここで挙げたものは代表的なものの一部であり、他にも様々な手法を組み合わせて実現しています。

盤面評価（スコア計算）は人間が工夫して計算方法を考えるため、対象となるゲームの知識が必要です

。

□ 盤面評価の手法の改良

- 2つの駒の位置関係（王将と金など）から、3つの駒の位置関係（王将と金と銀など）の方がより良く評価できる
- 盤面評価手法 = 特徴量表現の改良

□ 後半の指し手決定方法の変更

- 盤面評価スコアによる最善手探索よりも、ランダムな指し手でとにかく終了させることをたくさん繰り返し、勝率の高い指し手を選んだ方が効果的
- 指し手の選択肢が少なくなることで可能となる

## 2-4. エキスパートシステム

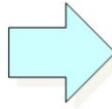
□ 専門分野の知識を取り込み、推論を行うことでその分野のエキスパートのように振る舞うシステム

□ If-Thenルール

➤ 条件を定義し、条件を満たせばその条件における判断を下す

□ 例

もし、  
警報が発令されている  
午前7時より前である  
発令されているのは県内である



午前の授業は休講とする



これらの知識は手動で設定

## エキスパートシステム

- 知識をコンピュータに与えるために膨大なコストが必要
  - 専門家にヒアリングをして知識を取り出すなど
- 知識（条件）の適切な管理が必要
  - 知識（条件）の数が増えるとお互いに矛盾したり一貫していなかったりする
- あいまいな条件を扱うための広い範囲の知識の記述が難しい
  - 「お腹に違和感がある」
  - お腹とはどの部分なのか？
    - ✓ 人間の身体構造の知識（お腹には胃、小腸、大腸などがある）が必要
  - 違和感とはどんな症状か
    - ✓ 鋭い痛み、鈍い痛み、張りがあるなど

処理としては単純な条件分岐だが、知識をどのように作るかが問題となっています。

ただし、処理が単純で、蓄積されたルールを人間が理解しやすいため、現在でも使われることがあります。

## 2-5. 機械学習

### □ 教師なし学習

- k-means法 (クラスタリング)
- 自己組織化マップ (次元圧縮)

### □ 教師あり学習

- k近傍法 (分類、回帰)
- 決定木、ランダムフォレスト (分類、回帰)
- サポートベクターマシン (分類、回帰)
- ニューラルネットワーク (分類、回帰)

### □ 強化学習 (時間の関係で今回は扱いません)

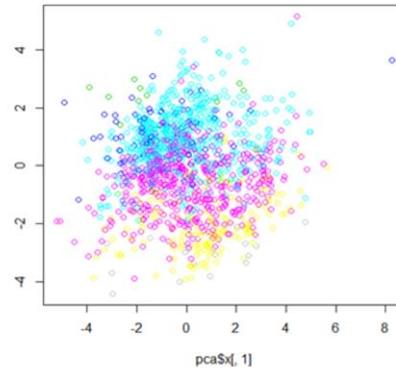
- 教師あり学習に似ているが、与えられた正解に対する価値を最大化するのではなく、その時点での環境における価値を定義し最大化する
- ある時点における環境における価値が大きくても正解に対する価値が大きいとは限らない

## 2-5-0. (参考) 主成分分析

- 主成分分析は教師無し学習と同じ目的の統計的手法
- 下の表のようなワインの成分とワインの品質のデータに対して、成分データでワインを特徴をあらわすことを考える

属性 (単位)
酒石酸濃度 (g/dm <sup>3</sup> g/dm <sup>3</sup> )
酢酸濃度 (g/dm <sup>3</sup> g/dm <sup>3</sup> )
クエン酸濃度 (g/dm <sup>3</sup> g/dm <sup>3</sup> )
残留糖分濃度 (g/dm <sup>3</sup> g/dm <sup>3</sup> )
塩化ナトリウム濃度 (g/dm <sup>3</sup> g/dm <sup>3</sup> )
遊離亜硫酸濃度 (mg/dm <sup>3</sup> mg/dm <sup>3</sup> )
総亜硫酸濃度 (mg/dm <sup>3</sup> mg/dm <sup>3</sup> )
密度 (g/dm <sup>3</sup> g/dm <sup>3</sup> )
pH
硫酸カリウム濃度 (g/dm <sup>3</sup> g/dm <sup>3</sup> )
アルコール度数 (% vol.)
ワインの味 (グレード)

第1主成分と  
第2主成分で  
プロット



点の色は品質の違いを表す

## 2-5-1. k-means法

- 教師なし学習
- 特徴空間の中で距離が近いものをおしを同じクラスとしてグループ化する
- 結果は初期クラス重心にかなり依存する
- 処理手順
  1. クラスタ数を決め、初期クラスタを設定する
  2. 各クラスタの重心を求める
  3. 各データと各クラスタ（の重心）との距離を計算し、各データに最も近いクラスタを割り当てる
  4. 2と3を繰り返す
- Rのkmeansなどで実装されている
- *k-means clustering* (wikipediaより) [https://en.wikipedia.org/wiki/K-means\\_clustering](https://en.wikipedia.org/wiki/K-means_clustering)

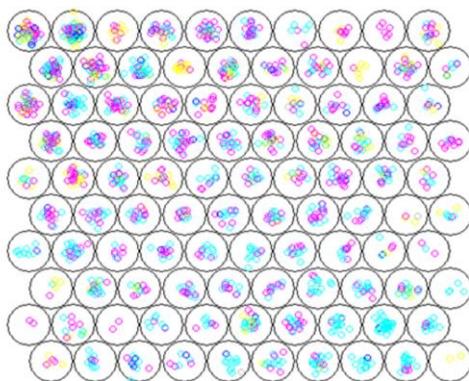
2次元での描画しかできないため高次元の実データではイメージを持ちにくいですが、英語版wikiの動画がわかりやすいので参照してください。

## 2-5-2. 自己組織化マップ

- 教師なし学習
- 入力データの類似度（ユークリッド距離など）の計算を繰り返して、類似度を基にデータをグループ分けする
- 入力層と出力層の2層で構成されるニューラルネットワーク
- 処理手順
  - 入力ノードと出力ノードに類似度が定義されている
  - 出力層のノードには近傍ノードが定義されている
  - 1. 出力ノードの重みベクトルをランダム化する
  - 2. ある一つの入力に対し、最も類似した出力ノード（BMU、Best Matching Unit）を見つける
  - 3. BMUとその近傍ノードの重みベクトルを、入力ノードの重みベクトル近づけるように変更する
  - 4. 2と3を繰り返す
- Rのsomパッケージ、kohonenパッケージなどで実装されている

■ 自己組織化マップの出力例（ワインの成分）

Positioning map



点の色は品質の違いを表す

### 2-5-3. k-近傍法 (k-Nearest Neighbor法)

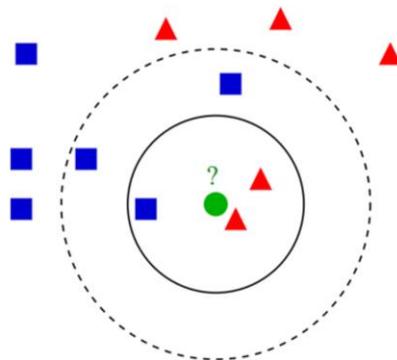
- 教師あり学習
- 特徴空間上で最も近い距離にある訓練データに基づいて分類や回帰を行う
- 線形分離が難しい場合でも分類可能
- 処理手順
  1. 正解がわかっているデータを基に、正解がわからないデータを分類する
  2. 未分類のデータに対して、k個の分類済みの近傍データを見つける
  3. 分類済みの近傍データの多数決などにより未分類のデータを分類・回帰する
- Rのclassパッケージなどで実装されている

おおまかに言うと、対象がなんらかの多変量データで表されていて、分類したいデータの近くに最も多い訓練データのクラスを採用することです。

回帰の場合は、近傍の訓練データのクラスの代わりに近傍データの平均や加重平均などを使います。

□ k-近傍法の例

- 青と赤は教師データ
- 緑はラベルを持っていないデータ
- この例では新しい緑のデータは赤と同じラベルと予測される



#### 2-5-4. 決定木

- 教師あり学習
- 段階的にデータを分割していき、木のような分析結果を出力する
- 分析結果の解釈や実装が容易
- 複数の決定木を組み合わせることで、ランダムフォレストなどの強力なアルゴリズムに発展させることが可能
- 処理手順
  1. データを分割する基準を決定する
    - 最もきれいにデータを分割できる基準を選ぶ
    - 「情報利得」が最大となる基準 = 「不純度」が最小
  2. データを分割する
  3. 設定した基準になるまで1と2を繰り返す
    - 終了条件は、木の深さ、終端ノード数、ノードに含まれるデータ数、誤り率などを考慮する
- Rのrpartパッケージなどで実装されている

前述の決定木を自動的に作成する方法です。

決定木はルールが人間に理解しやすく、ルールの変更をすぐに反映できるという利点があります。



## 決定木

- **不純度** : ジニ不純度、交差エントロピーなど
- ノード  $t$  におけるジニ不純度  $J(t) = 1 - \sum_{i=1}^N p(i|t)^2$ 、
- $p(i|t)$  : ノード  $t$  におけるクラス  $i$  の割合
- $N$  : クラス数
- 一つのノードに様々なクラスが含まれていると不純度が高くなる
  
- **情報利得** : 分割のよさ (分割前の不純度 - 分割後の不純度)
- ノード  $X$  をノード  $Y1$  と  $Y2$  に分割した場合の情報利得を  $IG(X, Y1, Y2)$  とする
- $IG(X, Y1, Y2) = E(X) - p(Y1) * E(Y1) - p(Y2) * E(Y2)$
- $E$  : 不純度、  $p$  : 割合 (  $p(Y1) + p(Y2) = 1$  )

## 2-5-5. ランダムフォレスト

- ランダムサンプリングされたトレーニングデータによって学習した多数の決定木を使用する方法
- 処理手順の概要
  1. ランダムにデータを抽出する
  2. 抽出したデータで決定木を生成する
  3. 1. と2. を繰り返す
  4. 予測結果の多数決で分類しきい値を決定する
- RのrandomForestパッケージなどで実装されている

## 2-5-6. サポートベクターマシン (SVM)

- 教師あり学習
- 訓練データから、各データ点との距離が最大になるマージン最大化超平面を求める（これだけでは線形分離可能な場合のみ）
- カーネル法を使い、特徴空間上で線形分離することで、実空間での非線形分離が可能
  - カーネル関数と呼ばれる関数で入力データをより高次元の特徴空間に写像し、特徴空間上で分割する
- Rのkernlabパッケージなどで実装されている