

| | |
|----|--|
| 1章 | <p>1-1 人工知能(AI) とは 人工知能とは何か 推論・認識・判断など人間と同じ知的な処理能力を持つ機械という点では一致 しかし そもそも「知性」や「知能」自体の定義がないため「人工知能とは何か」についての共通定義がない レベル1: シンプルな制御プログラム 電化製品など すべての振る舞いがあらかじめ決められている レベル2: 古典的な人工知能 掃除ロボットや診断プログラムなど 探索・推論・知識データを利用することで 状況に応じて極めて複雑な振る舞いをする レベル3: 機械学習を取り入れた人工知能 検索エンジンや交通渋滞の予測など 非常に多くのサンプルデータをもとに入力と出力の関係を学習し 製品 レベル4: ディープラーニングを取り入れた人工知能 音声認識・画像認識・機械翻訳など 特徴量と呼ばれる変数を自動的に学習するサービスや製品 AI 効果 人工知能で何か新しいことが実現され その原理が分かると「それは単純な自動化であって知能とは関係ない」と結論付ける人間の心理的な効果 人工知能とロボットの違い ロボットの脳にあたる部分が人工知能 人工知能の研究は「考える(知的処理能力)」という「目に見えないもの」を中心に扱う</p> <p>1-2 人工知能研究の歴史 エニアク(ENIAC) 1946年アメリカのペンシルベニア大学で開発された 世界初の汎用コンピュータ ダートマス会議 1956年に開催 初めて人工知能という言葉が使われる ジョン・マッカーシーが主催 世界初の人工知能プログラムロジック・セオリストのデモンストレーション 第1次 AI プーム 推論・探索の時代 1950年代後半~1960年代 トイ・プロブレム(簡単なゲームのような問題 迷路やオセロのようにルールとゴールが決まっている問題 そのような問題しか解けない) 第2次 AI プーム 知識の時代 1980年代 エキスパートシステム(初心者でも問題解決が可能となるような専門知識をもとに動作する) 第五世代コンピュータ(日本政府によって1982年から1992年にかけて進めた国家プロジェクト) 第3次 AI プーム 機械学習と特徴表現学習の時代 2010年~ 機械学習: ピッグデータを用いて人工知能が自ら知識を習得 ディープラーニング(深層学習): 特徴量(注目すべき特徴を定量的に表した数値)を人工知能が自ら習得する 3つのAI プームはお互いに関連している 機械学習の本質的な技術は第1次プームのとき 推論・探索・知識表現が研究が継続されている</p> |
| 2章 | <p>2-1 探索・推論 迷路(探索木) 幅優先探索と深さ優先探索という方法がある 幅優先探索:最短距離でゴールにたどり着く解を見つけることができる メモリ不足になる可能性がある 深さ優先探索 メモリはあまり要らない ハノイの塔 ボールに積み重なった円盤を動かす計画 探索木を使って解くことができる ブランチ&bound 探索を利用してロボットの行動計画を作成する ブランチ&boundの研究で「前提条件」<行動>の結果の組み合わせで記述する STRIPS が有名 SHRDLU 1968年から1970年にかけてペリー・ウィリアムズによって開発された「積み木の世界」でブランチ&boundを実現する研究 英語による指示で様々な物体を動かす この成果がCycプロジェクトに引き継がれる コスト 組み合わせを効率よく探索するため取り入れた概念 あらかじめ知っている知識や経験を利用しコストを計算 探索を短縮する コストの計算に利用される知識を「ヒューリスティックな知識」と呼ぶ Mini-Max法 自分が指すときはスコアが最大になるように手をつなぐ 相手が指すときは自分のスコアが最小になる選択をすると考ええる α β法 Mini-Max法による探索をできるだけ速く行う手法 αカット:最大のスコアの選択でスコアの小さいノードを外す βカット:最小のスコアの選択でスコア大きいノードを外す モンテカルロ法 ゲームがある局面まで進んだら 完全にランダムに進め続け シミュレーションをし にくく最終(ブレイクアウト)させ勝率(スコア)を計算する ブルートフォース(力任せ)で押切る 対してAlphaGoはブルートフォースではなくディープラーニングの技術を使ったのが画期的</p> <p>2-2 知識表現 人工無能 特定のルール・手順に沿って会話を機械的に処理するだけ チャットボット おしよべりボット など イライザ(ELIZA) 人口無能の元祖 1964-66年にジョセフ・ワイゼンバウムによって開発 パターンに応じた発言を返答するチャットボット あたかも本物の人間と対話しているような錯覚(イライザ効果)に陥る エキスパートシステム ある専門分野の知識を取り込んだプログラム 1970年代にスタンフォード大学で開発されたマイシン(MYCIN)はバクテリアの診断支援をするプログラムで 専門医ではない医師よりは良い結果を出した DENDRAL 1960年代に開発 未知の有機化合物を特定するエキスパートシステム エドワード・フェイゲンバウムによりスタンフォード大学で開発された 知識獲得のボトルネック(エキスパートシステムの限界) 知識ベースの構築に専門家・ドキュメント・事例などが必要 暗黙的な知識 インタビュースタッフの研究 大量の知識や事実・一貫性のなさ → 知識ベースの保守が困難 意味ネットワーク 長期記憶の構造モデルとして考案 重要な知識表現の方法 概念 をラベルの付いたノードで取り「is-a」の関係は継承関係(矢印の向きが上位概念)を表す 「part-of」の関係は真性を表す Cycプロジェクト 知識ベースのシステムに膨大な知識が必要という課題に挑戦 すべての一般常識をコンピュータに取り込もうというブランチ&boundの知識 タググラス・レドワードにより1984年からスタートし 今も続いている オントロジー 本来は存在論(存在に関する体系的理論)という意味 人工知能ではドメイン・グループや概念の明示的な仕掛けと定義 知識の共有と活用が目的 「言葉」意味の関係性を共有できるような仕掛けとして定義 概念間の関係 「is-a」の関係(上位概念) 「part-of」の関係(全体と部分) 「part-of」の関係 全体と部分の関係が成立しない場合がある いろいろな種類の「言葉」意味の関係性を共有できるような仕掛けとして定義 ハイウェイトオントロジー(重畳オントロジー) 知識のように記述するかしっかりする 人間の関わる傾向が強い 時間とコストがかかる Cycプロジェクトがその一例 レイトウェイトオントロジー(軽重オントロジー) 効率を重視してきりぎりし自動で行う ウェブマイニング(ウェブデータの解析)やデータマイニング(ビッグデータの解析)で利用される セマンティック Web Web サイトが持つ意味をコンピュータで理解させる コンピュータ同士で処理を行わせるための技術 LOD(Linked Open Data) コンピュータ処理に適したデータを公開 共有するための技術 ワトソン IBM が開発 2011年クイズ番組で優勝 Question-Answering(質問応答)システム ウィキメディアからライブラリ LOD(Linked Open Data) コンピュータ処理に適したデータを公開 共有するための技術 東大ロボくん 東大入試合格を目指す人工知能 2011年から2016年まで研究 ほとんどの私立大学に合格できるレベルに達した 何らかの技術的なブレイクスルーがない限り東大合格は不可能という理由から開発凍結</p> <p>2-3 機械学習・深層学習 統計学 人工知能のプログラム自身が学習する仕組み 2000年以降ビッグデータというキーワードと共に注目を集める レコメンデーションエンジンやスパムフィルターなどが機械学習により実用化される 機械学習 自然言語処理 復讐の車輪といふまでもなく 大量で用意された膨大な量の対訳データ(コーパス)をもとに最も正確である確率的最適化を選択する ニューラルネットワーク 機械学習の一つ 人間の神経回路を真似することで学習を実現しようとするもの ニューラルネットワークの元祖である単純パーセプトロンは心理学者フランク・ローゼンブラットが1958年に考案した ディープラーニング(深層学習) ニューラルネットワークを多層にしたもの 順張逆伝播法(バックプロパゲーション)と呼ばれる方法を用いて学習する 自己符号化器の研究や活性化関数の工夫により層を深くしても学習可能に ILSVRC 画像認識の精度を競い合う競技会 2012年トロント大学のジェフリー・ヒントンらが SuperVision(チーム名) が優勝 AlexNetと呼ばれるモデルを用いたディープラーニング それまで特徴量を決めるのは人間だった ISL 上記の大会で2位 東大が開発 AlexNet にエラー率を10%以上も引き離される</p> |
| 3章 | <p>3-1 人工知能分野の問題 フレーム問題 「今しようとしてこれに関係があることがどれだけを選び出すことが、実は非常に難しい」ことをさす 1969年にジョン・マッカーシーとバトリック・ヘイズが提唱 チューリングテスト 数学者アラン・チューリングの発案 会話の相手かコンピュータと見分けなければコンピュータには知能がある 1966年に開発されたイライザ(ELIZA) 1991年以降テスト合格を目指すローブナーコンテストが開催 強いAIと弱いAI アメリカの哲学者ジョン・サールが提示した区分 強いAI: 本物の心を持つ人工知能 弱いAI: 知的活動と同じような問題解決ができる便利な道具 中国語の部屋 ジョン・サールが提示した思考実験 英語しか分からない人を部屋に閉じ込めて 中国語の文字をマニュアルに置き換える チューリングテストに合格しても知能があるかわからない シンボリックラーニング問題 1990年ステイブ・ハルパーンにより議論 記号(シンボル)とその対象がいかにして結びつくかという問題 身体性 知能の成立に身体が不可欠という考え方があり「身体性」に着目したアプローチと呼ばれる 外界と相互作用できる身体が概念とはとらえられない ルールベース機械翻訳(RMBT) 1970年代後半 登録済みのルールを適用することで原文を分析し 訳文を出力する機械翻訳の手法 人手では限界があり うまく行かなかった 統計学的機械翻訳(SMT) 1990年代以降 性能は飛躍的に向上ししかし実用レベルではない 翻訳のために必要となる一般常識が膨大で扱うことが極めて困難 知識獲得のボトルネックと呼ばれる ニューラル機械翻訳(NMT) 現在の主流 ディープラーニングを使った技術 2016年Google 機械翻訳の品質が格段に向上</p> <p>特徴表現学習 特徴量(=注目すべきデータの特徴を定量的に表したものを)を機械学習自身に発見させるアプローチ ディープラーニングは「特徴表現学習」を行う機械学習アルゴリズムの一つ 深層ニューラルネットワーク 特徴量とはある量が適用できなくなる点のこと 人工知能が自分自身より賢い人工知能を作ろうとした 連続的な人工知能を作るように人間の想像力が及ばない超越的な知性が誕生する レイ・カーツワイルが2045年と主張 ステイブ・ホーキング「完全な人工知能の開発は人類の終焉を意味するかもしれない」イロノ・マスク「人工知能にはかなり慎重に取り組み必要がある」ビル・ゲイツ「人工知能に懸念を抱く側にいる」1人だ</p> |
| 4章 | <p>4-1 代表的な手法 教師あり学習 与えられたデータ(入力)を元に そのデータがどんなパターン(出力)になるかを識別・予測するもの 分類問題(離散値を予測する問題)と回帰問題(連続値を予測する問題)がある 教師なし学習 学習で用いる教師(=出力データ)がない データそのものの持つ構造・特徴を学習対象とする 強化学習 行動を学習する仕組み 目標とする報酬(スコア)を最大化するためにはどのような行動をとって行けばいいかを学習する 線形回帰(Linear Regression) データに最も当てはまる直線を考える 正規化項を加えた手法としてラジ回帰とリッジ回帰がある ロジスティック回帰 分類問題に用いる手法 シグモイド関数を用いて 閾値で正例(+)と負例(-)を分類する 3種類以上の分類にはソフトマックス関数を用いる ランダムフォレスト 決定木を用いる手法 特徴量をランダムに選んで出す 決定木の学習にランダムに取り出す一部データを用いる(ブートストラップサンプリング) 複数の決定木の結果から多数決で出力を決定 ランダムフォレストのように 複数のモデルで学習させる方法をアンサンブル学習といい 特に全体から一部データを用いて複数のモデルを学習する方法をバギングという ブースティング 一部のデータを繰り返し抽出し抽出したモデルを学習させる 複数のモデルを並列に作成するバギングに対して 逐次的に作成する モデルには決定木が用いられる 勾配ブースティングなどが有名 サポートベクターマシン(SVM) 各データ点との距離が最大となるような境界線を求めること ベクター分類を行う 距離を最大化すること マージン最大化と決す カーネル関数でデータを高次元に写像 カーネルトリックで式変換 ニューラルネットワーク 人間の脳の構造を模したアルゴリズム ニューロンと呼ばれる神経細胞が結びつくと神経回路という巨大なネットワークにより人間の脳はパターン認識している 単純パーセプトロン 単純なニューラルネットワークのモデル 入力層と出力層で表現 出力層で用いるニューロンのつながりは重みで表し出力は0か1の値となる シグモイド関数などの活性化関数を用いる 多層パーセプトロン 単純パーセプトロンの層を増やしたモデル 入力層と出力層の間に隠れ層が追加 予測値との誤差をニューラルネットワークにフィードバックする 順張逆伝播法が考えられた ディープラーニング登場前の人気は低かった 自己回帰モデル(ARモデル) 時系列データを対象とする 入力が複数種類の場合ベクトル自己回帰モデル(VARモデル)と呼ぶ 時系列データの分析(時系列分析)に用いられる k-means法 階層的クラスタリング データをk個のグループ(クラスター)に分ける 適当にクラスターに振り分け 重心との距離で振り分け直し 重心の位置の変化がなくなるまで繰り返す ウード法 階層ありクラスタリング 距離の近い2つのデータ(クラスター)を1つのクラスターにまとめる処理を繰り返す クラスタリングにおけるまともな樹形図(dendrogram)で表すことができる 主成分分析(PCA) 相関を持つ多数の特徴量を互いに相関のない少数の特徴量(=主成分)へと次元削減する 学習時間の削減 データの可視化 主成分分析以外にも特異値分解や多次元尺度構成法などの手法 可視化しようしている t-SNE 隠れフィードバック レコメンデーションに用いられる 似たユーザーの買っている商品を推薦する 事前にある程度のデータが必要(コールドスタート問題) 対して商品別に特徴量付与するコンテンツベースフィルタリングがある トピックモデル 複数のクラスターにデータを分類する 潜在的ディレクトリ配分(LDA)が代表的な手法 記事がどのトピックに分類されるかを記事内に出てくる単語から確率で求める 似たような文章の推薦 強化学習の理論 将来にわたって獲得できる累積報酬を最大化する 割引率と呼ばれるハイパーパラメータを用いる バンディットアルゴリズム 活用(知っている情報の中から報酬が最大となる行動を選ぶ)と探索(情報を獲得するために行動する)のバランスをとる 具体的な手法は ε-greedy 方策 UCB 方策 等 マルコフ決定過程モデル 環境に対してマルコフ性(将来の状態は現在の状態のみに依存する)を仮定する 価値関数 単純に価値関数といった場合は状態価値関数ではなく行動価値関数を指す Q値とも呼ばれる Q値を最適化する手法には Q学習やSARSAがある 方策勾配法 方策(Policy)があるパラメータで表される関数とし そのパラメータを学習することで 直接方策を学習しているアプローチ 具体的手法として REINFORCE(AlphaGoにも活用)がある Actor-Critic 価値関数ベースと方策勾配法ベースの考え方を組み合わせた手法行動を決める Actor(評価器)と方策を評価する Critic(評価器)から成り立つ 応用手法として AC3などがある</p> <p>4-2 モデルの評価 交差検証 手元にある全データを 訓練データ(学習用のデータ)とテストデータ(評価用のデータ)に分割して評価する 訓練データをさらに訓練データと検証データに分割し検証データで一度モデルの評価を行うこともある 交差検証には ホールドアウト検証(データを2つに分けて検証)と k分割交差検証(データをいくつかの組に分類し学習・評価を行う 少ないデータでも精度が出る)がある 混同率 予測値と実測値の組み合わせ表 TP 真陽性 FN 偽陰性 FP 偽陽性 TN 真陰性 正解率(Accuracy) TP + TN / TP + FP + FN + TN 全データ中 どれだけ予測が当たったか 適合率(Precision) TP / TP + FP 予測の中で 実際にも正であったもの 再現率(Recall) TP / TP + FN 実際にも正であったものの中で 正だと予測できた F値(F-measure) 適合率と再現率の調和平均 2 × Precision × Recall / Precision + Recall 過学習 訓練データのみ最適化されてしまっている状態 正規化は学習の過剰を用いる式に項を追加し 重みの値の範囲を制限し 過学習を防ぐ 正規化を施すと近似的に性能が低下する(未学習) ラジ回帰はL1 正規化(一部のパラメータを0にする)を適用 リッジ回帰はL2 正規化(パラメータの大きさに応じて0に近づける)を適用 Elastic Netは両者を組み合わせた手法 ROC 曲線 横軸に FPR(FP/TP+FN) 縦軸に TPR(TP/TP+FN) を適用 2クラス分類で閾値を0から1に変化させたときの曲線をプロット ROC 曲線下の面積を AUCと呼び1に近いほどモデルの性能が良い モデルの解釈 局所的に説明性をもたせていくというアプローチとしては LIMEやSHAPといった手法がある 単純なモデルによる近似を行い特徴量の寄与度を測る モデルの選択と情報量 オッカムの剃刀「ある事柄を説明するためには 必要以上に多きを仮定するべきでない」という指針 赤池情報量基準(AIC)「統計モデルの複雑さと予測精度のバランスを考えた」指標</p> |
| 5章 | <p>5-1 ニューラルネットワークとディープラーニング 多層パーセプトロン ニューラルネットワークの基本形 入力と出力の関係性が隠れ層に重みとして表現されている 隠れ層がない単純パーセプトロンではできなかった非線形分類ができるようになった ディープラーニング 隠れ層を増やしたニューラルネットワーク 層が「深い」から深層学習とも呼ばれる 人工知能の研究分野を指すもの モデル自体はディープニューラルネットワークと呼ぶことが大半 勾配消失問題 隠れ層を増やすと誤差のフィードバックがうまくいかない 大きな理由の1つがシグモイド関数の特性(微分が0.25にしかならない) 2-1 ニューラルネットワーク・ディープラーニングのアーキテクチャ オートエンコーダ 可視層(入力層と出力層)と隠れ層の2層からなるネットワーク 隠れ層に「入力の情報が圧縮されたもの」が反映(入力層の次元>隠れ層の次元とする) エンコード(入力層→隠れ層)デコード(隠れ層→出力層) 粗粒度オートエンコーダ ディープオートエンコーダ 一気にすべての層の学習をするのではなく入力層に近い層から順番に学習させる逐次的な方法を取る オートエンコーダを順番に学習していく手続のことを事前学習と言う ファインチューニング オートエンコーダを積み重ねていった最後にロジスティック回帰(シグモイド関数)・ソフトマックス関数による出力層/回帰問題においては線形回帰を見し ネットワーク全体で重みの調整をする 深層信念ネットワーク ジェフリー・ヒントンが2006年(粗粒度オートエンコーダを提唱したのもこの年)に提唱した手法 教師無し学習に制限付きボルツマンマシンという手法を用いている</p> <p>5-2 ディープラーニングを再現するには ムアアの法則「半導体回路の性能と複雑性は18ヶ月ごとに2倍となる」という経験則 CPUとGPU CPUは様々なタスクを順番に処理していくことに長ける GPUは大規模な並列演算処理に特化 GPUがディープラーニングの発展に大きく貢献している GGPU 画像以外の目的に最適化されたGPU NVIDIA社が開発をリードする Google社はテンソル計算処理に最適化されたTPUを開発 パーニーおじさんのルール「モデルのパラメータ数の10倍のデータが必要」という経験則 例えばAlexNetのパラメータ数は約6000万個なのでデータは約6億個必要になることになる</p> <p>5-3 活性化関数 tanh(ハイパーボリックタンジェント)関数 シグモイド関数の微分が最大となる対する工夫 -1から1の範囲をとる 微分の最大値は1 勾配消失問題を完全に防げない ReLU関数 入力値が0より大きい場合の微分が常に最大値の1となる 順張逆伝播の際に勾配が小さくなりくい(勾配消失しにくい) Leaky ReLU関数 0以下でもわずかな傾きがある Parametric ReLU 0以下の傾きを学習で最適化する Randomized ReLU(復数の傾きをランダムにためす)などの派生形がある</p> <p>5-4 学習の最適化 順張逆伝播 機械学習の手法が指すのは「モデルの予測値と実際の値との誤差をなくすこと」 誤差を損失関数として定義しこれを最小化する 関数の最小化問題と考えられる 勾配降下法 勾配(微分値)に沿って降りていくことで解を探索する イテレーション:繰り返す計算の回数 学習率:繰り返すごとに一度にどれだけ降りるか(ハイパーパラメータ) 勾配降下法の問題と改善 勾配がゼロの点に行きつづため大域最適解(本当の最適解)ではなく局所最適解(見せかけの解)に陥ることがある 学習率の値を大きくする 鞍点問題 鞍点(ある次元で極小であるが別の次元で極大となる点)から抜け出すことが困難(トラップと言う) 1990年代にモーメント量という手法が提唱された その後 Adagrad Adadelta RMSprop Adam AdaBound AmsBound など 5-6 更なるテクニック ドロップアウト 過学習を防ぐために ランダムにニューロンを「ドロップアウト」させる ドロップアウトはアンサンブル学習を行っていることになる 早期終了 学習を早めに打ち切る どんなモデルにも適用できる二重降下現象(テストデータに対する誤差が増えた後 再度下がるとも確認されているため学習を止めるタイミングは慎重に検討が必要) ノーフリーランチ定理「あらゆる問題で性能の良い汎用最適戦略は理論上不可能」という定理 ジェフリー・ヒントンが早期終了を「Beautiful FREE LUNCH」と表現したのがこの定理を意識して発せられた言葉 データの正規化 データの全体を調整する処理 正規化(一番簡単な戦略)の各特徴量を0から1の範囲に変換する処理 標準化:各特徴量の平均を0 分散を1とする処理 白化化:各特徴量を無相関化したうえで標準化する 重みの初期化とディープラーニングでは一様分布・正規分布ではうまくいかない 乱数にネットワークの大きさに合わせた適当な係数をかける シグモイド関数→Xavierの初期化 ReLU関数→Heの初期化 がよいとされる</p> |

| | |
|---|---|
| 6 | <p>バッチ正規化 各層に伝わってきたデータをその層でまた正規化してしまう バッチ正規化は活性化関数にかける前にデータを正規化するという処理を加える 過学習にくくなることも知られている</p> <p>6-1 畳み込みニューラルネットワーク</p> <p>畳み込みニューラルネットワーク (CNN) 画像データに適した構造として考えられた RGB 画像は縦と横だけでなく奥行も持つ3次元となる 視覚野の S 細胞 (濃淡パターンへの抽出) と C 細胞 (位置や向きをも同一とみなす) の働きを模倣</p> <p>ネオコグニロン: 福島県松原によって考えられた S 細胞と C 細胞を交互に組み合わせた構造 LeNet-5: 1998年にヤン・レクンによって考えられた 畳み込み層(S細胞に対応)とプーリング層(C細胞に対応)を複数組み合わせた</p> <p>畳み込み層 フィルタ (またはカーネル)を用いて画像から特徴を抽出する操作を行う 画像とフィルタを掛け合わせて線画とつづいて 人間の視覚野がもつ局所受容野に対応 移動不変性の獲得に貢献 「位置のずれ」に強いモデルができる</p> <p>プーリング層 画像サイズを決められたルールに従って小さくする ダウンサンプリングあるいはサブサンプリングとも呼ばれる 最大値プーリングや平均値プーリングがある 画像のズレに対する頑健性を持つことができる</p> <p>全結合層 特徴を2次元から1次元に変換する 特徴マップを1列(フラット)に並べる処理を行う 最近の手法では特徴マップの平均値を1ユニット(ニューロン)の値にする Global Average Poolingと呼ばれる処理を行うことが多い</p> <p>データ拡張 (data augmentation) データを収集する代わりに手元にある画像から疑似的に別の画像を生成する 上下左右を反転 斜めにゆがめる 上下左右を反転 一部を切り取る 拡大縮小する コントラストを変える 回転する などの処理</p> <p>その他 画像の一部の画素値を またはランダムに Cutout や Random Erasing 2枚の画像を合成する Mixup (Cutout と Mixup を組み合わせた CutMix なる)</p> <p>CNNの発展 DeepNeat 2012年のILSVRCで圧倒的勝率を誇った VGG いったん少ない層で学習して途中に畳み込み層を追加 GoogLeNet 同時に異なるフィルタサイズの畳み込み処理 (Inception モジュール)を導入</p> <p>ResNet 更に深いネットワークを表現するために考案された 「スキップ接続」(層を飛ばした結合)を導入 MobileNet 畳み込み層のパラメータを削減 Depthwise Separable Convolution を使用し計算量を1/8に削減</p> <p>Neural Architecture Search (NAS) リサレントニューラルネットワークと深層強化学習を用いてネットワーク構造を探索する NASNet や InasNet などが EfficientNet は単に高精度だけでなく転移学習に有用なモデルとして活用される</p> <p>転移学習 学習済みのモデルに 新たに何層かを付け足す その層だけを学習するだけで かなり高性能なネットワークを検索することができる 付け足した層だけでなくネットワーク全体を学習する方法をフィニチューニングと言う</p> <p>6-2 深層生成モデル</p> <p>深層生成モデル ディープラーニングを取り入れた生成モデル(元の画像と似たような画像データを生成することを目的としたモデル) 元データセットから潜在空間を学習し全体として表現 潜在空間から新しい画像を生成することができる</p> <p>変分オートエンコーダ(VAE) 入力データを圧縮してよく統計的に変換する すなわち平均と分散で表現する ように学習 入力データは統計分布のある1つの点となる ランダムにサンプリングした1点を復元することで新しいデータを作成</p> <p>敵対的生成ネットワーク(GAN) ジェネレータ ディスクリミネイター 偽物画像を作るように学習とディスクリミネイター 偽物をきちんと見抜けるように学習で構成される 2種類のネットワークを競い合わせる</p> <p>DCGAN GANにCNNを採用したもの Pix2Pix 画像を別の画像に変換 あらかじめペアの画像を学習のために用意しなくてはならない Cycle GAN 元の画像と再度変換した画像が一致するように学習</p> <p>6-3 画像認識分野での応用</p> <p>画像認識タスク 画像に写る代表的な物体クラスの名称を出力するタスク ILSVRCが開催されている ILSVRC で用いている ImageNetには膨大な数の画像データがあり正確ラベルの擬わい例も含まれる</p> <p>2012年 AlexNet ディープラーニングに基づくモデルとして初めて優勝 2014年 Inception モジュールを用いる GoogLeNet が優勝 同年 VGG というネットワーク構造の設計を単純化した方法が提案されている</p> <p>2015年 Skip connectionを導入した ResNetが優勝 人の識別精度を超える (以降 Wide ResNetやDenseNetなどの派生モデルが登場)2017年 Attention機構を導入したSqueeze-and-Excitation Networks (SENet)が優勝</p> <p>物体検出タスク 入力画像を見る物体クラスの名称とその物体の位置を特定するタスク 2段階モデルにはR-CNNと後継モデルやFPN 1段階モデルにはYOLOと後継モデルやSSD が挙げられる</p> <p>R-CNN 物体候補領域をSelective Searchで抽出 リサイズされたCNNに入力 最上位層の1つ前の層を特徴マップとして SVN によるより粗大識別する 処理時間がかかる</p> <p>Fast R-CNN 画像全体を入力して特徴マップを得ることで高速化 物体候補領域に相当する部分を切り出し Paster R-CNN Selective Searchを Region Proposal NetworkというCNNモデルに置き換えさらに高速化</p> <p>YOLO (You Only Look Once) 入力画像の各位置における物体領域らしさと矩形領域を直接出力する SSD CNNの途中の特徴マップからYOLOのように領域単位で物体らしさと矩形領域を出力 デフォルトボックスを導入</p> <p>セグメンテーションタスク 画像の画像ごとに識別を行うタスク 画像全体を対象とするセマンティックセグメンテーションと物体検出した領域を対象とするインスタンスセグメンテーションがある</p> <p>個々の物体をそれぞれ分離しつつ 道路や建物などはひとまとめにする ペアディクセグメンテーションもある</p> <p>FCN CNNをセマンティックセグメンテーションに利用した手法 特徴マップが出力に対して小さくなる SegNet エンコーダ側の最大プーリングした位置を記憶し デコーダ側の拡大時特徴マップの値を配置 境界付近の結果をばやさせない</p> <p>U-Net エンコーダ側で特徴量マップを拡大する際 エンコーダ側の特徴マップを同じサイズに戻すように切り出して エンコーダ PSpNet エンコーダとデコーダの間に複数階層で特徴を捉える Pyramid Pooling Moduleを追加</p> <p>Atrous convolution(Dilated convolution) も同じ カーネルサイズを大きくするとパラメータ数が増えるという問題を解決 DeepLabで採用 さらにエンコーダ・デコーダ構造とASPPを採用したモデルはDeepLab V3+と呼ばれる</p> <p>姿勢推定タスク 人の頭や足、手などの相対位置を推定するタスク 信頼度マップによるアプローチがある 複数の人を同時に推定できるようにした手法にOpen Poseがある Open PoseはPart Affinity Fieldsと呼ばれる処理を導入</p> <p>マルチタスク 複数のタスクを1つのモデルで対応すること 物体検出モデルで識別と位置検出を同時に行うなど Mask R-CNNはFast R-CNNによる物体検出とインスタンスセグメンテーションを同時に行うマルチタスクのモデル</p> <p>6-4 音声処理と自然言語処理分野</p> <p>A-D変換 アナログデータをデジタルデータに変換する処理 音声はパルス符号変調(PCM)という方法でデジタルデータに変換されることが一般的</p> <p>高速フーリエ変換(FFT) 周波数解析を高速に行う手法として広く使われる FFTにより音声信号は周波数スペクトルに変換できる</p> <p>スペクトル包絡(スペクトル包絡の検出) 「音色」の違いはスペクトル包絡の違いが原因 メル周波数ケプストラム係数(MFCC)を用いて求める スペクトル包絡のピークをフォルマント 周波数とフォルマント周波数と呼ぶ 音韻に近き</p> <p>隠れマルコフモデル(HMM) 音声認識を行うモデルとして標準的に使われている HMMは音素(言語ごとに区別される音の最小単位)ごとに学習しておくことで 様々な単語の認識に対応する</p> <p>n-gram 単位となるものを複数個並べたもの 単語を並べたものは単語 n-gramと呼ぶ nが1の場合はユニグラム 2の場合はバイグラム 3の場合はトライグラムと呼ぶ</p> <p>Bag-of-Words(BoW) 文や文章を出現する単語の集合として表現する 出現順序の情報が失われる 局所的出現頻率が重要な場合 n-gram と BoWを組み合わせたBag-of-n-gramを採用することもある</p> <p>ワンホットベクトル 1つ1つの次元だけが1で他がすべて0となっているベクトル 各単語に異なる整数値を順に割り当て IDはワンホットベクトルに変換することで 文章をBoWのベクトルとして表現できる</p> <p>TF-IDF 単語ごとに TF と IDF を掛け合わせたもの TFは当該文内での単語の出現割合 IDFは単語の出現する文書の割合の逆数の対数 文書内での出現回数が多い単語は少ないほど大きな値 単語の重要度を表すと考えられる</p> <p>単語埋め込み ワンホットベクトルによる情報量が低く高次元での単語埋め込みは単語同士の意味の違いを考慮できるため 情報量が大きい(値が0である次元が少ない)次元の低いベクトルに変換した単語の分散表現とも呼ぶ</p> <p>word2vec 単語の意味は その周辺の単語によって決まる、という分散表現を実現したものを スキップラム(単語から周囲の単語を予測するモデル)と CBOW(Continuous Bag-of-Words 周辺の単語から単語を予測するモデル)がある</p> <p>word2vecによって得られた国と首都を取り出し 主成分分析(PCA)を用いて2次元に次元圧縮した値は 国と首都の関係や地理的関係を保ってプロットできる</p> <p>fastText word2vec を捉え出したトラス、ミコロフらによって開発された 単語を構成する部分文字列の情報も含める 訓練データには存在しない単語の埋め込みの計算や語幹と語尾を分けて考慮することが可能 学習に要する時間が短い</p> <p>ELMo word2vec や fastText で得られる分散表現は各単語一つだけなのに対し 文脈を考慮した分散表現を得る手法 複数の意味を持つ単語の文においての適切な意味を表した表現を得られる</p> <p>RNN(リカレントニューラルネットワーク) 通常のニューラルネットワークに対して過去の隠れ層が追加されている RNNを使っていることと代表例として言語モデルがある Pretrained Modelsの基礎にもなっている</p> <p>時間軸に沿って誤差を反映する BackPropagation Through Time(BPTT)と呼ばれる勾配降下法が使われる RNNを使った音声認識で入力と出力の数が一致しない問題を解決したのが Connectionist Temporal Classification (CTC)</p> <p>LSTM(Long Short-Term Memory) 勾配消失問題や入力重み衝突や出力重み衝突といった問題を解決 LSTM ブロックを導入し時系列データを手入力ネットワーク内に保持する セル(Cel)は隠れ情報を内部にため込む配分損失を防ぐ</p> <p>入力ゲートは入力重み衝突のため 出力ゲートは出力重み衝突のため 忘却ゲートは誤差が過剰にセルに滞留するのを防ぐ リセットゲートの役割を果たす LSTMを簡略化したGRUではリセットゲートと更新ゲートが入力・出力・忘却ゲートの代わりを果たす</p> <p>Bidirectional RNN RNNを2つ組み合わせることによって未知から過去方向も含めて学習できるようにしたモデル</p> <p>sequence-to-sequence(Seq2Seq) 入力が組み立てられた出力も時系列で予測 代表例が機械翻訳 RNN エンコーダ-デコーダという手法を用いる 画像の説明文を生成する Image Captioning ではエンコーダにCNNデコーダにRNNを用いる</p> <p>Attention 「時間の重み」をネットワークが組み立てた機械 予測文であって正確な翻訳が出力できるようにした Attention は「出力が見た各入力の貢献度(重み)」を表し入力出力の対応関係を可視化できる</p> <p>トランスフォーマー 2017年に提案 入力文と出力文をSource-Target Attention (またはEncoder-Decoder Attention)で機械 学習 エンコーダとデコーダでRNNを排除しSelf-Attentionと呼ばれるネットワーク構造を採用</p> <p>ネットワーク全体がSelf-AttentionとSource-Target Attentionという2種類のAttention機構により構成されている RNNの欠点である並列計算ができず処理速度が速くないと離れた単語間の関係が捉えきれない問題を解決</p> <p>Self-Attention(自己注意機構) 入力文内または出力文内の単語間の関連度を計算 文脈を考慮した1つ適切な分散表現を得る 計算が並列に行え 高速に処理できる 語順情報が失われるため入力に位置エンコーディングを付加する</p> <p>トランスフォーマーではエンコーダもSelf-Attentionを用いるが デコーダは入力文の情報も利用する デコーダでは未来の情報は使えないため生成するプロセスは並列化できないという仕組み上の違いがある</p> <p>GPT 2018年に提案 OpenAIが開発した事前学習モデル 事前学習で大規模なコーパスを用いた言語モデルの学習 トランスフォーマーのデコーダと似た構造を用いる 事前学習と転移学習で全く同モデルを用いる</p> <p>転移学習 「評価分析 自然言語推論 質問応答 意味的類似度 文書分類」などの言語理解タスクを解くことができる 言語タスクをまとめたGeneral Language Understanding Evaluation (GLUE)ベンチマークというデータセットが公開されている</p> <p>BERT 2018年に提案 Googleが開発した事前学習モデル トランスフォーマーのエンコーダを用いている Masked Language Model(MLM)とNext Sentence Prediction(NSP)という2つのタスクによって事前学習を行う</p> <p>MLMはマスクされた単語を予測 NSPは2つの文が連続するかどうかを判定 転移学習でBERTの同様の応用タスクを解くことができる さらに品詞タグ付けや固有有用解析やSQuAD(回答の範囲を予測するタスク)を解くことも可能</p> <p>Pre-Trainingモデルの発展 パラメータ数は GPTが約1億 BERTが約3億だった ALBERTやDistilBERTは精度を落とさずパラメータ数の削減の工夫 一方パラメータ数を増やすことでより強力なモデルを目指したのも 2019年2月 GPT-2は約15億</p> <p>2019年9月 NVIDIAのMegatron-LMは約83億 2020年2月 MicrosoftのTuring-NLGは170億 2020年5月 GPT-3は1750億 また画像分野ではCNNを使わない新たな事前学習モデルであるVision Transformer(ViT)が提案された</p> <p>6-5 深層強化学習</p> <p>深層強化学習 ディープラーニングと強化学習を組み合わせた手法 2013年にDQN(Deep Q-Network)がDeepMindから発表された Atari2600のゲームを人間並みのスピードで攻略 ゲームや実世界の画像をそのまま入力とする</p> <p>DQN では 経験再生(経験データをブレイクアップに保存したランダムに抜き出し学習を行い 時間的割引を行い 時間的割引をなくし学習の安定化を図る)とターゲットネットワーク(過去のネットワークに教師の役割をさせる 値値を安定させる)を導入</p> <p>DQN以降 ダブル DQN 優先度付経験再生 デュリンネットワーク カテゴリーカールDQN ノイズネットワーク が発表されて すでに組み合わせたRainbowと呼ばれる手法に発展 内発的報酬とよばれる報酬の工夫により性能が向上</p> <p>モンテカルロ木探索 複数回のゲーム木を展開したランダムシミュレーション(プレイアウト)をもとに近似的に良い手を決定する手法</p> <p>AlphaGo 2016年 DeepMind社が開発 AI、セドル9段に囲碁で勝利する モンテカルロ木探索に深層強化学習の手法を組み合わせる 盤面から勝率を計算するバリュートネットワークやポリネットネットワークを用いる</p> <p>AlphaGo Zero 教師あり学習は一切行わず 自己対戦で得たデータのみで深層強化学習を行う Alpha Zero 将棋やチェスの分野でも他を圧倒する AlphaGo Zeroと同じく自己対戦のみで学習</p> <p>マルチエージェント強化学習 味方相手の複数エージェントの協調的な関係や競争的な関係を考慮した分散学習 OpenAIのOpenAI Five(Mountain Dota2)に対応)やDeepMind社のAlphaStar(RTS スタークラフト2に対応)などが得る</p> <p>ロボット制御への応用 センサや制御信号のデータを一定の幅で離散化するだけでは状態や出力の数が増え学習が困難になる次元の呪いという問題がある 価値関数や方策を関数近似し高次元のデータを扱う</p> <p>状態に関する広い特徴表現を学習する状態空間強化学習が必要 関節角や台車の速度と言った連続値を直接出力する連続的行動空間の設定 報酬設計が難しい連続的報酬形成が必要 データの収集コスト 安全性の担保</p> <p>観測的解決策 タスクに関する事前知識(ドメイン知識)を組み込む工夫 事前に集めたデータ(オフラインデータ)から方策を学習する 強化学習は人間が期待する動作を教示する デモンストラーション(教師データ)</p> <p>オフライン強化学習は収集された固定のデータセットがエージェントに与えられる シミュレータで学習した方策を現実世界に移転して利用する設定は sim2real と呼ばれる リアリティギャップと呼ばれる差異が生まれる</p> <p>複数のシミュレータを用いたドメイントランスfer 最適な方策との差分を強化学習によって学習する遷移強化学習 モデルフリーから環境に関する予測モデルを活用するモデルベース強化学習 世界モデルの研究</p> <p>6-6 モデルの解釈性の問題とその対応</p> <p>Grad-CAM 画像認識系のタスクを対象として「画像のどこを見ているか」を可視化 勾配情報を用いた 低解像度による問題がある 入力値の勾配情報も用いたGuided Grad-CAMという手法もある</p> |
| 7 | <p>7-1 AIと社会</p> <p>AIのビジネス活用 AIによって経営課題を解決し利益の創出する 法を遵守する 法整備による技術の普及 倫理は「価値」に関する対話でもある 現代社会は様々な情報が物理的(アナログ)空間と仮想的(デジタル)空間に分散して存在する</p> <p>デジタル空間上の大量のデータ(ビッグデータ)の獲得によるAIの進歩 IoTやRPAを活用してアナログ空間からデジタル空間へブロックチェーンなどを用いて改ざんから保護する必要 AIを構成要素として含むAIシステム</p> <p>7-2 AIプロジェクトを設計する</p> <p>CRISP-DM データマイニングの業界横断的標準プロセス ビジネスの理解 データの理解 データの準備 モデリング 評価 展開の6つのステップに分割</p> <p>MLops (Machine Learning)とOperationsを統合した言語AIを本番環境で開発しながら運用するまでの概念 DevOpsから派生している</p> <p>AIの適用 そもそもAIを適用する必要があるか AIの特性を理解したうえで判断する データのフィードバックの機構をどのようにするか 運用を継続しながら推論の精度を上げていくことが現実的な進め方になる</p> <p>プロセスの再設計 AIを利活用にはBPR(Business Process Re-engineering)が発生する アナログ空間のプロセスからAIを利活用するプロセスに変換する必要がある 業務プロセスをそのまま活かすのではなくプロセスの設計を直す</p> <p>クラウドとエンジヤクラウドはインターネットを基盤としてサービスを利用できるようにした仕組み モデルをサービスとして提供するの方法として Web APIがある エンジヤは利用現場に配備するリソースのこと その場でモデル管理を実行する</p> <p>開発計画 学習に欲しい出力を数値として定量的に表す必要がある 定量的でも学習の難しいケース フェーズを細かく区切り柔軟に修正できる体制 適した契約形式を採用 適切適切にコミュニケーションをとってプロジェクト管理</p> <p>プロジェクト体制 開発段階からPMなどステークホルダーを巻き込んだ体制づくりが必要 マネージャー(ビジネスの観点)と開発者(技術的観点)とデザイナー(ユーザー視点)を含むチーム構成 経営者・法務・経営企画・広報との連携</p> <p>プライバシー・バイ・デザイン(GDPR) 開発段階からプライバシー(侵害予防)を指向する必要があります 最近ではセキュリティ・バイ・デザインや価値全体に配慮したセキュリティ・バイ・デザインや価値全体も登場</p> <p>7-3 データを収集する</p> <p>データの収集 AIシステムの開発にはデータの質と量が重要 オープンデータセットを適切に使う 利用できるデータがない場合は自分でセンサを利用 環境の情報を計測してデータを収集する必要がある プロジェクトのROIを踏まえたセンサの選定</p> <p>オープンデータセット 企業や研究者が公開しているデータセット コンピュータビジョン分野ではImageNet Pascal3C MS COCO 自然言語処理ではWordNet SQuAD DBPedia 音声分野ではLibriSpeechなどが挙げられる</p> <p>データの利用条件と制約 ①著作権法 ②不当競争防止法 ③個人情報保護法 ④個別の契約 ⑤その他 理由によりデータの利用に制約 金融分野におけるガイドラインでは機械学習は個人情報保護法における要配慮個人情報の取扱いより厳しい</p> <p>学習可能なデータ データの種類をなくす データに関するリスクを最小化する データの網羅性が重要 転移学習などの利用である程度はデータ数の少ない状況に対応 データの質を高める(ノイズで消えている) そもそも含まれていない</p> <p>データセットの他 不適切な標本抽出によるサブサンプリング・バイアス 現実世界の偏見をもそのまま反映 登録されている市場での信用性のなさ 欧米主導で作られていることに起因する問題 開発者に透明性・説明責任・答責性が求められる</p> <p>外部との連携 企業や他業種との連携や産学連携の増加 組織外の知識や技術を取り込むオープン・イノベーションの現場でのトラブル 開発者にはユーザーが適切に関与するよう動くためのプロジェクト・マネジメント義務がある</p> <p>AI・データの利用に関する契約ガイドライン 2018年に経済産業省が策定 開発プロセスを①アセスメント段階 ②PoC段階 ③開発段階 ④追加学習段階に1つに必要な契約を結ぶ 「データ提供型」「データ創出型」「データ共用型」の契約類型</p> <p>7-4 データを加工・分析・学習させる</p> <p>データの加工 データの変換 データの集約 事前加工 正解データ作成(アンノテーション) アンノテーションのばらつきを解決するための要件の決定(マニュアルの作成)や作業者のサインメントの調整やレビュープロセス等の仕組み作りが必要</p> <p>プライバシーへの考慮 特定の個人の識別ができないように加工した匿名加工情報 カラ画像の利用の配慮点をまとめた「カラ画像利用ガイドブック」を2017年(2018年改訂)経済産業省、総務省、IoT推進コンソーシアムが共同</p> <p>2019年には「事前告知・通知に関する参考事例集」を公表 生体情報領域で使われていたELSI(Ethical, Legal and Social Implication 倫理的・法的・社会的影響を一体として検討)がAI開発現場でも重要視されるように</p> <p>開発環境 Pythonには多様なライブラリが揃う Python 自己と生体情報のバージョンを合わせる必要がある 環境切り替えにはpyenv・virtualenv・pipenv・Dockerなど コード作成にはAI開発エディタ・IDE・Visual Studio Notebookなど</p> <p>Python ライブラリ Numpy Scipy Pandas SciKit-learn LightGBM XGBoost TensorBoard MFlow Optuna Horovod CUDA TensorRT transformers mdxnetcn</p> <p>アルゴリズムの設計 簡潔とコストの切り合いを付けて進める必要 データやモデルの複雑さによるブランクボックス問題が安全やプライバシーにかかわる問題となる リスク防止のためXAI(Explainable AI)の開発が進んでいる</p> <p>フィルターバブル現象「おすけ機能」について 嗜好に基づいて最適化するパターン学習を強めすぎると 社会的分断を深める遠因となるかもしれない 特定の記事にしか注意を向けない傾向を助長したり特定の政治傾向を強化したりすると批判</p> <p>FAT(Fairness, Accountability, and Transparency) プライバシーや公平性の問題について 取り組む研究領域やコミュニティ 例えは計算機科学の国際学会であるACM主催するACM FATがある</p> <p>アセスメントツール データの収集およびモデルの検討を中心に行う データ収集の可否の確認 行うこととする問題に対して同様の問題を解いている事例や文献の有無を調査する モデルに適用での推論時間を視野にいれて選択する</p> <p>コンセプト検証(PoC)のフェーズでは データの加工とアルゴリズムの設計・調整を中心に進め 実際にはAIモデルを作成する プロセスを何度か回し実用的な精度に近づける AIでの職能人による最終決定を組み合わせるリスクを低減し運用へ</p> <p>7-5 実装・運用・評価する</p> <p>成果物を知的財産として守る データやモデルは一定の条件を満たせば知的財産として保護される 著作物は「思想・感情」を「創作的」に「表現」したものが プログラムは著作物となる可能性がある 自動作成されたパラメータなどは著作物としない</p> <p>営業秘密は非公開性・有用性・秘密管理性の要件を満たせば保護される 法改正により 「限定提供データ」や「オープンデータに関する適用除外」が追加 営業秘密としての保護を受ける秘密管理する モデルに特化などは著作物</p> <p>学習済みモデルのエッセンスが「蒸留」される 法制度上の知的財産権が認められない不明なところもある 実務では開発者間で契約を結び 権利の帰属 利用範囲・禁止行為などを明示することで 一定の解決を図る</p> <p>利用者・データ保持者の保護 個人情報を取り扱う際には利用目的をできる限り限定しななければならない 2018年にEU一般データ保護規則(GDPR)が運用開始 日本企業も法的規制を受ける場合がある 日本とEUは「十分性を認定</p> <p>悪用への対策 「敵対的攻撃(Adversarial attacks)」というAIモデルの認識を混乱させる方法が存在する 敵対的生成ネットワークを用いて作成されたジェネレーティブは人間の眼では真贋が判別できないほど精巧になっている</p> <p>予知しない悪意への対処 AI単体では精度の確保が難しい AI+人を前提としたプロセスによる アルゴリズムバイアス；データセットのバイアスやアルゴリズムの技術的限界によって機械による誤認識が起こる</p> <p>7-6 クラウド・マネジメント</p> <p>クラウド・マネジメント 危機を最小限に抑えと拡大を防ぐ「決済」と速やかに平常化に再発防止を目指す「復旧」が主眼 体制整備のためコーポレート・ガバナンスや内部統制の刷新が進められる</p> <p>ジェンダー・エヌ MITメディアラボの研究プロジェクト 多くのIT企業が提供する顔認証システムが ジェンダーや肌の色によって精度がまちまちであることを示す データセットの偏りを認識する必要がある</p> <p>AIと安全保障・軍事情報 自立型兵器 (Autonomous Weapons Systems) / 自立型致死兵器システム (Lethal Autonomous Weapon Systems) / 特定通常兵器使用禁止制限条約 (CCW) : LAWSに関する研究開発を禁止すべきという議論</p> <p>社会との対話 プライバシーやセキュリティなどの対策に関して実施状況を公開する Twitter社やGoogle社などの企業は透明性レポートをウェブ上で公開 一般社団法人オープン・インターネット協会によるサイバーパトロール</p> <p>指針作成 2016年に Amazon・Google・Facebook・IBM・Microsoft などを中心に Partnership on AI(PAI)が組織された IEEEが「倫理的に調和された設計」を公開 Future of Life Instituteが23項目の「アシモAI原則」を公開</p> <p>欧州委員会が 2019年4月「信頼性を確保したAIのためのマイクロソフトガイドライン」2020年2月「AI白書」を公開 中国は2019年5月に「北京AI原則」を公開 日本も2019年内閣府が「人間中心のAI社会原則」を公開</p> |