

明 細 書

発明の名称：学習装置、学習方法及び学習プログラム

技術分野

[0001] 本発明は、学習装置、学習方法及び学習プログラムに関するものである。

背景技術

[0002] 従来、用意された画像の中から教師データとなるモデルの学習に効率の良い画像を選出して拡張するニューラルネットワークを用いたディープラーニングによる学習方法があった（例えば、特許文献1）。従来の学習方法は、データ拡張の処理とデータ選出の処理に工夫があり、大規模なデータの学習に適応するものであった。

[0003] ここで、従来の学習方法では、データ選出の処理の際に、データ拡張の処理前と同じ画像を選択しないという条件を加えることで、データ拡張の処理によって増やした類似の画像が重複して学習されることを低減して学習画像が偏らないようにしていた。しかしながら、従来の学習方法では、1回の学習に使用する教師データとなる画像の数が少なくなるため、画像の特徴をなかなか学習しきることができず、学習のループ回数が増加してしまい、学習完了までに時間がかかる場合があった。

先行技術文献

特許文献

[0004] 特許文献1：日本国特開2024-002431号公報

発明の概要

発明が解決しようとする課題

[0005] 本発明は、学習の速い学習装置、学習方法及び学習プログラムを提供することを目的とする。

課題を解決するための手段

[0006] （1）本発明の一態様に係る学習装置は、元画像データに基づいて増加させた学習候補データを作成するデータ拡張処理部と、前記学習候補データに、

確信度評価値を付す確信度評価部と、前記学習候補データの中から前記確信度評価値の順に学習用データを抽出する学習用データ抽出部と、前記学習用データに基づく学習を行う学習処理部と、を備え、前記学習用データ抽出部は、前記学習用データを、前記学習候補データに付された前記確信度評価値があらかじめ設定された確信度評価閾値になるまで抽出する。

(2) 上記(1)において、前記学習候補データの中から、元画像データが共通する拡張画像群の代表を代表画像として選出する代表画像選出処理部を備えてよい。

(3) 上記(2)において、前記学習用データ抽出部は、前記学習用データを、前記代表画像の種類数があらかじめ設定された代表画像種類数閾値になるまで抽出してよい。

(4) 上記(2)において、前記学習用データ抽出部は、前記代表画像の中で最も大きい前記確信度評価値が付された学習候補データより小さな前記確信度評価値が付された学習候補データを学習用データに含めてよい。

(5) 本発明の一態様に係る学習方法は、元画像データに基づいて増加させた学習候補データを作成するデータ拡張処理ステップと、前記学習候補データに、確信度評価値を付す確信度評価ステップと、前記学習候補データの中から前記確信度評価値の順に学習用データを抽出する学習用データ抽出ステップと、前記学習用データに基づく学習を行う学習処理ステップと、を備え、前記学習用データ抽出ステップにおいて、前記学習用データを、前記学習候補データに付された前記確信度評価値があらかじめ設定された確信度評価閾値になるまで抽出する。

(6) 本発明の一態様に係る学習プログラムは、コンピュータに、元画像データに基づいて増加させた学習候補データを作成するデータ拡張処理機能と、前記学習候補データに、確信度評価値を付す確信度評価機能と、前記学習候補データの中から前記確信度評価値の順に学習用データを抽出する学習用データ抽出機能と、前記学習用データに基づく学習を行う学習処理機能と、を実行させる学習プログラムであって、前記学習用データ抽出機能において

、前記学習用データを、前記学習候補データに付された前記確信度評価値があらかじめ設定された確信度評価閾値になるまで抽出する。

発明の効果

[0007] 本発明によれば、学習の速い学習装置、学習方法及び学習プログラムを提供できる。

図面の簡単な説明

[0008] [図1]学習装置の概要を説明する図である。

[図2]学習方法のフローの概要を説明する図である。

[図3]学習用データの抽出を代表画像の枚数で制限した場合における学習方法のイメージを示す図である。

[図4]学習用データの抽出を確信度評価閾値で制限した場合における学習方法のイメージを示す図である。

発明を実施するための形態

[0009] (実施形態)

以下、図面を参照して本発明の実施形態について詳細に説明する。

図1は、学習装置100の概要を説明する図である。図2は、学習方法のフローの概要を説明する図である。図3は、学習用データの抽出を代表画像の枚数で制限した場合における学習方法のイメージを示す図である。図4は、学習用データの抽出を確信度評価閾値 α で制限した場合における学習方法のイメージを示す図である。なお、以下、共通する機能を有する部分には、同じ符号又は記号が付される場合がある。

[0010] (学習装置)

図1を参照して、本実施形態に係る学習装置100について説明する。図1に示すように、本実施形態の学習装置100は、データ拡張処理部10、確信度評価部20、代表画像選出処理部30、学習用データ抽出部40、学習処理部50及び制御部60を備えている。

[0011] 学習装置100は、機械学習モデル（以下、モデルという。）に、対象データ（例えば、画像データ）に対して適切な評価を行うことができるように

、学習をさせる装置である。ここで、モデルとは、コンピュータが判別可能な入力値を受け取り、評価値を出力する機械学習における仕組み（アルゴリズム）である。

[0012] モデルは、対象データの内容を認識し、評価を行う。例えば、対象データが画像データである場合、被写体の品質（良品であるか不良品であるか等）を評価する。

[0013] モデルは、ニューラルネットワークとパラメータとを含む構造を有する。ニューラルネットワークは、複数のニューロンを結合させた構造を有する。ニューラルネットワークは、例えば、複数のニューロンがグループ化された層を連ねた階層型の多層ニューラルネットワークであってよい。ニューラルネットワークは、ニューロンの個数及び結合関係で定義される。ニューロン間又は層間の結合強度は、パラメータ（重み係数など）を用いて定義される。ニューラルネットワークでは、対象データが入力され、複数のニューロンの演算結果及びパラメータに基づいて、対象データの評価が行われる。モデルは、例えば、対象データ（学習データ）に対して、良品ラベル及び不良品ラベルの何れかに分類する機能又は良品スコアを算出する機能を有する。

[0014] 学習装置１００は、主要なハードウェアとしてコンピュータ（図示省略）を備えている。コンピュータは、ＣＰＵ、ＧＰＵ等のプロセッサ、ＲＡＭ、ＲＯＭ、ハードディスク又はソリッドステートドライブ（ＳＳＤ）等の記憶装置、インターネット等のネットワークへの接続を行う通信部等を備えている。また、コンピュータの記憶装置には、コンピュータを本実施形態の学習装置１００として作動させるための学習プログラムが記憶されている。なお、コンピュータには、クラウドコンピューティングシステムが含まれる。学習装置１００が備える各機能部は、ハードウェアとしてコンピュータと、ソフトウェアである学習プログラムによって実現される。

[0015] データ拡張処理部１０は、元画像データに基づいて増加させた学習候補データ（学習候補データセット）を生成する機能部である。この増加させる処理により、画像データの質と量を向上させていわゆる水増しをすることがで

き、少ないデータから機械学習モデルの学習にとって質の高い効率的なデータかつ十分な大量のデータを生成でき、モデルの性能を高めることができる。元画像データの増加は、例えば、元画像データを左右反転させたり、上下反転させたり、 180° 回転させたデータを作成するフリップ処理、元画像データをX方向又はY方向に座標をずらしたデータを作成するシフト処理、元画像データを右方向又は左方向に微小角度回転させてデータを作成する微小回転処理、元画像データに中央値フィルタ又はガウシアンフィルタ等のフィルタをかけてデータを作成するフィルタ処理等によって行う。

[0016] 確信度評価部20は、学習候補データに、あらかじめ定められた式により算出される確信度評価値 E_s を付す機能部である。確信度評価値 E_s は、そのデータを学習することでモデルの判定性能の向上にどれほど寄与するかの期待度を示す指標である。言い換えると、確信度評価値 E_s は、モデルがデータを学習する時点でどのくらい自信をもってそのデータを評価（判断）しているかを示す指標である。

[0017] [確信度評価値]

学習装置100（確信度評価部20）は、確信度評価値 E_s を求めるにあたり、学習候補データごとに、対応する特徴量に基づいて、学習候補データと、良品ラベルが付与された学習データ（モデルの機械学習の基礎となった教師データ）である良品データとの、特徴空間における距離である良品距離を算出する。このように、確信度評価値 E_s は、学習候補データと学習データとの特徴空間における距離に基づいて算出されるパラメータであってよい。なお、以下、良品距離及び不良品距離の表現に用いられる「距離」には、一例として、特徴空間に投射されたデータ間のユークリッド距離を用いることができる。特徴空間における距離を算出することができれば、ユークリッド距離には限定されず、マハラノビス距離等も用いることができる。学習データ群のうちの1つのデータである学習データと学習候補データ群のうちの1つのデータである学習候補データとの距離は、例えば以下の式1で算出される。

[数1]

$$d_{(k,s)}(\vec{p}_s, \vec{q}_k) = \sqrt{\sum_{i=1}^j (q_{(k,i)} - p_{(s,i)})^2} \cdots (1)$$

ここで、 $q(k, i)$ は学習データ k の特徴空間のある次元 i における座標であり、 $p(s, i)$ は学習候補データの特徴空間のある次元 i における座標である。 $d(k, s)$ は学習データ k と学習候補データとの距離であり、 q_k のベクトルは、学習データ k の特徴空間の座標データの集合であり、 p_k のベクトルは、学習候補データの特徴空間の座標データの集合である。なお、 k は学習データのデータ数 ($m+n$: m 及び n は整数) 以下の整数であり、 i は予め定められた次元の数 (j) 以下 (j は整数) の整数であり、 s は学習候補データのデータ数 (t) 以下 (t は整数) の整数である。

[0018] 学習候補データと良品データ OK のうちの 1 つのデータである良品データ OK g までの距離を $d(OKg, s)$ とすると、 $d(OKg, s)$ は式 1 を用いて以下の式 2 のように表される。なお、OK g のうち、OK は良品を示す符号であり、 g は、良品データ OK のデータ数 (m) 以下の整数である。

[数2]

$$d_{(OKg,s)}(\vec{p}_s, \vec{q}_{OKg}) = \sqrt{\sum_{i=1}^j (q_{(OKg,i)} - p_{(s,i)})^2} \cdots (2)$$

$q(OKg, i)$ は学習データ群のうちの良品データ OK g の特徴空間のある次元 i における座標であり、 q_{OKg} のベクトルは、良品データ OK g の特徴空間の座標データの集合である。

[0019] 学習候補データと各良品データ OK との距離の集合を $d(OK, s)$ のベクトルとすると、 $d(OK, s)$ のベクトルは式 2 を用いて以下の式 3 のように表される。

[数3]

$$\overrightarrow{d_{(OK,s)}} = (d_{(OK1,s)}, d_{(OK2,s)}, \cdots, d_{(OKm,s)}) \cdots (3)$$

[0020] 学習候補データにおける良品距離 $E(OK, s)$ は、例えば、 $d(OK, s)$ のベクトルの要素の中で最小値である。すなわち、良品距離 $E(OK, s)$

s) は、学習候補データと各良品データ OK との距離の集合である $d(OK, s)$ のベクトルの要素のうち、最小値である。良品距離 $E(OK, s)$ は、式 3 を用いて以下の式 4 のように表される。このとき、良品距離 $E(OK, s)$ が小さいほど、特徴空間内において、学習候補データが良品データ OK のうちいずれかの近くに位置することを示す。

[数4]

$$E_{(OK, s)} = \min \{ f(x) | x \in \overline{d_{(OK, s)}} \} \quad \cdots (4)$$

[0021] 学習候補データにおける良品距離 $E(OK, s)$ は、例えば、 $d(OK, s)$ のベクトルの要素の中で小さい方から a 個の要素を抽出し、a 個の要素の平均値としてもよい。a は、自然数であり、例えば 3 である。この場合の良品距離 $E(OK, s)$ は、式 3 を用いて以下の式 5 のように表される。このとき、良品距離 $E(OK, s)$ が小さいほど、特徴空間内において、学習候補データが複数 (a 個) の良品データ OK の近くに位置することを示し、学習候補データが良品データ OK の集団 (良品クラス) に近いことを示す。

[数5]

$$E_{(OK, s)} = \frac{1}{a} \sum_{i=1}^a \min \{ f(x) | x \in \overline{d_{(OK, s)}} \} \quad \cdots (5)$$

[0022] また、学習装置 100 (確信度評価部 20) は、学習候補データごとに、対応する特徴量に基づいて、学習候補データと、不良品ラベルが付与された学習データである不良品データとの、特徴空間における距離である不良品距離を算出する。学習候補データと不良品データ NG のうちの不良品データ NG h までの距離を $d(NG h, s)$ とすると、 $d(NG h, s)$ は式 1 を用いて以下の式 6 のように表される。なお、NG h のうち、NG は不良品を示す符号であり、h は、不良品データ NG のデータ数 (n) 以下の整数である。

[数6]

$$d_{(NGh,s)}(\vec{p}_s, \vec{q}_{NGh}) = \sqrt{\sum_{i=1}^I (q_{(NGh,i)} - p_{(s,i)})^2} \cdots (6)$$

なお、 $q_{(NGh,i)}$ は学習データのうち、不良品データ NGh の特徴空間のある次元 i における座標であり、 q_{NGh} のベクトルは、不良品データ NGh の特徴空間の座標データの集合である。

[0023] 学習候補データと各不良品データ NG との距離の集合を $d_{(NG,s)}$ のベクトルとすると、 $d_{(NG,s)}$ のベクトルは式6を用いて以下の式7のように表される。

[数7]

$$\overrightarrow{d_{(NG,s)}} = (d_{(NG1,s)}, d_{(NG2,s)}, \cdots, d_{(NGn,s)}) \cdots (7)$$

[0024] 学習候補データにおける不良品距離 $E_{(NG,s)}$ は、例えば、 $d_{(NG,s)}$ のベクトルの要素の中で最小値である。すなわち、不良品距離 $E_{(NG,s)}$ は、学習候補データと各不良品データ NG との距離のうち、最小値である。不良品距離 $E_{(NG,s)}$ は、式7を用いて以下の式8のように表される。このとき、不良品距離 $E_{(NG,s)}$ が小さいほど、特徴空間内において、学習候補データが不良品データ NG のうちいずれかの近くに位置することを示す。

[数8]

$$E_{(NG,s)} = \min \{ f(x) | x \in \overrightarrow{d_{(NG,s)}} \} \cdots (8)$$

[0025] 学習候補データにおける不良品距離 $E_{(NG,s)}$ は、例えば、 $d_{(NG,s)}$ のベクトルの要素の中で小さい方から a 個の要素を抽出し、 a 個の要素の平均値としてもよい。この場合の不良品距離 $E_{(NG,s)}$ は、式7を用いて以下の式9のように表される。このとき、不良品距離 $E_{(NG,s)}$ が小さいほど、特徴空間内において、学習候補データが複数 (a 個) の不良品データ NG の近くに位置することを示し、学習候補データが不良品データ NG の集団 (不良品クラスタ) に近いことを示す。

[数9]

$$E_{(NG,s)} = \frac{1}{a} \sum_{i=1}^a \min \left\{ f(x) \mid x \in \overline{d_{(NG,s)}} \right\} \cdots (9)$$

[0026] また、学習装置100（確信度評価部20）は、算出された良品距離E（OK，s）及び不良品距離E（NG，s）を用いて学習候補データにおける確信度評価値E_sを算出する。確信度評価値E_sは、例えば、良品距離E（OK，s）を不良品距離E（NG，s）で除した値であり、以下の式10のように表される。

[数10]

$$E_s = \frac{E_{(OK,s)}}{E_{(NG,s)}} \cdots (10)$$

[0027] 例えば、確信度評価値E_sが1より小さいほど、不良品距離E（NG，s）より良品距離E（OK，s）の方が小さく、学習候補データが不良品クラスタより良品クラスタに近いデータであることが示される。したがって、当該学習候補データが不良品ラベルを有するデータである場合、確信度評価値E_sが小さいほど、当該学習候補データは、現段階の学習データ群の学習結果ではモデルにおいて良品ラベル又は不良品ラベルへ分類することが難しいデータであり、モデルにとって学習効果の高いデータであることを示す。

[0028] 一方で、例えば、確信度評価値E_sが1より大きいほど、良品距離E（OK，s）より不良品距離E（NG，s）の方が小さく、学習候補データが良品クラスタより不良品クラスタに近いデータであることが示される。したがって、当該学習候補データが良品ラベルを有するデータである場合、確信度評価値E_sが大きいほど、当該学習候補データは、現段階の学習データ群の学習結果ではモデルにおいて良品ラベル又は不良品ラベルへ分類することが難しいデータであり、モデルにとって学習効果の高いデータであることを示す。

[0029] 代表画像選出処理部30は、学習候補データの中から、元画像データが共通する拡張画像群の代表を代表画像として選出する機能部である。例えば、

図3及び図4に示すように、学習候補データのうち、3つの丸形状のマークが、一つの拡張画像群であり、その3つの丸形状のマークのうち、最も確信度評価値 E_s が小さい（昇順で並べられた場合）ものがその拡張画像群の代表画像である。そして、代表画像選出処理部30は、学習候補データが確信度評価値 E_s の昇順で並べられた場合、その学習候補データの順番で1番目の丸形状と、3番目の三角形状と、6番目の菱形状と、途中挟んで n 番目の稜栗形状と、を選出する。

[0030] 学習用データ抽出部40は、学習候補データセットを母集団として、この母集団について確信度評価値 E_s を算出し、確信度評価値 E_s が所定の範囲（例えば、あらかじめ定められた確信度評価閾値 α 以下）にある学習候補データを学習用データとして抽出する抽出処理を行う機能部である。言い換えると、学習用データ抽出部40は、学習候補データの中から確信度評価値 E_s の順に学習用データを抽出する。

[0031] 学習処理部50は、所定の学習率でモデルに学習処理を行わせる機能部である。学習処理とは、モデルのパラメータを最適値に近づけるように調整する処理である。

[0032] 制御部60は、学習用データ抽出部40と学習処理部50を制御してモデルに効果的な学習処理を行わせる機能部である。

[0033] （学習方法）

次に、実施形態に係る学習方法のフローを説明する。学習方法は、学習装置100を用いて実施できる。学習方法における各ステップ（処理又は工程）は、学習装置100における対応する各部（各モジュール）によって実行できる。図2は、学習方法のフローの概要を説明する図である。図3は、学習用データの抽出を代表画像の枚数で制限した場合における学習方法のイメージを示す図である。図4は、学習用データの抽出を確信度評価閾値 α で制限した場合における学習方法のイメージを示す図である。

[0034] （1）事前に、学習装置100は、元画像データとなるデータセットを取得する。

- [0035] (2) 次に、図2に示すように、学習装置100は、データ拡張処理部10によって、元画像データに基づいて増加させた学習候補データ（学習候補データセット）を作成する（データ拡張処理ステップ）（処理A）。この処理により、画像データの質と量を向上させていわゆる水増しをすることができ、少ないデータから機械学習モデルの学習にとって質の高い効率的なデータかつ十分な大量のデータを生成でき、モデルの性能を高めることができる。
- [0036] (3) 次に、学習装置100は、確信度評価部20によって、学習候補データに、あらかじめ定められた式により算出される確信度評価値 E_s を付す（確信度評価ステップ）。そして、学習装置100は、代表画像選出処理部30によって、各学習候補データ（画像）に付される確信度評価値 E_s を用いて、学習候補データセットの中から元画像データが共通する拡張画像群の代表を代表画像として選出する（処理B）。ここで、代表画像は、共通の元画像データから拡張された複数の画像データ（拡張画像群）の中で最も小さい確信度評価値 E_s が付された画像（処理B中に同一の拡張元を持つ画像が選出されていない画像のこと）であってよい。言い換えると、処理Bでは、評価値の昇順に画像を並べた際に最も評価値が小さい画像を代表画像とし、それ以降の元画像データが同じ画像は代表画像にはしないという処理を行っている。例えば、図3に示すように、1段目の「学習候補データ」列の丸形状の画像が代表画像として選出され、元画像データが同じである2段目及び4段目の丸形状の画像は代表画像には選出されない。
- [0037] (3-1) ここで、学習用データ抽出部40は、学習用データを、学習候補データに付された確信度評価値 E_s があらかじめ設定された確信度評価閾値 α になるまで抽出してもよい（学習用データ抽出ステップ）。
- [0038] (4) 次に、処理Bで選出された代表画像の枚数を検知する。代表画像が検知された場合には、処理Dに進む。代表画像が検知されない場合には、学習終了の処理を行う（処理C）。
- [0039] (5) ここで、選出された代表画像を確信度評価値 E_s の順（例えば、昇順）にソートし、例えば、所定の値を基準に、確信度評価値 E_s が小さい方を

学習用として大きい方をそれ以外として、学習用とそれ以外に分類する（処理D）。

[0040]（５－１）ここで、処理Dにおいて、学習装置１００は、代表画像を、確信度評価値 E_s があらかじめ設定した確信度評価閾値 α となるまで選出してよい（条件１）。これにより、学習に非効率的な学習候補データが学習用データ（教師データ）として抽出されにくくできるとともに、少なすぎず多すぎない適切な量の学習用データを抽出できる。

[0041]（５－２）または、処理Dにおいて、学習装置１００は、分類の処理を、代表画像があらかじめ定めた規定枚数に達するまで実行してよい（条件２）。言い換えると、学習装置１００の学習用データ抽出部４０は、学習用データを、代表画像の種類数があらかじめ設定された代表画像種類数閾値 β になるまで続けて抽出する。これにより、少なすぎず多すぎない適切な量の学習用データを抽出できる。

[0042]（５－３）または、処理Dにおいて、学習装置１００は、代表画像の全てを分類するまで実行してよい（条件３）。これにより、少なすぎず多すぎない適切な量の学習用データを抽出できる。

なお、上述の条件１～３は、それぞれ単独で適用されてよく、自由に組み合わせられて適用されてもよい。

[0043]（６）処理Dにより、学習用に分類された代表画像を学習用データとして抽出する（処理E）。

[0044]（６－１）ここで、代表画像よりも確信度評価値 E_s が小さい画像を学習用データとして抽出する（処理G）。言い換えると、学習用データ抽出部４０は、代表画像の中で最も大きい確信度評価値 E_s が付された学習候補データより小さな確信度評価値 E_s が付された学習候補データを学習用データに含める。これにより、代表画像と元画像データが共通する拡張画像群を全て抽出できるので、代表画像と元画像データが共通する他の学習候補データを抽出しない場合と比べて、学習用データの不足を抑制して学習効果の高い十分な量の学習用データを抽出できる。

- [0045] (7) 処理Eの後に、処理Eまでに抽出された学習用データに基づいて学習を行う(処理F)。なお、適正な学習が見込まれる所定回数を超えたら学習をやめる終了条件が設定されている。処理Fにおいて、学習を行った後は処理Bに戻る。
- [0046] (8) 適宜、処理Aと処理Bの間において、事前学習済みモデルを初期値として設定する(処理H)。
- [0047] このように、本実施形態に係る学習方法は、学習装置100を用いて、データ拡張元となる元画像データの中の代表画像を基準として所定の条件(上述の条件1～3)を満たすまで学習用データを抽出するので、学習に必要な質の高い種類の異なる学習用データを確実に抽出しながらも、学習に必要な充分かつ無駄に多すぎない量の学習用データを抽出できる。よって、学習の速い学習装置100及び学習方法を提供できる。
- [0048] (学習プログラム)
- 学習プログラムは、上述の学習方法における各ステップで行われる各処理をコンピュータに実行させる機能を備えている。具体的には、学習プログラムは、上述の学習方法における各ステップに対応して、データ拡張処理機能、確信度評価機能、学習用データ抽出機能及び学習処理機能を備えている。これにより、少ないデータから機械学習モデルの学習にとって質の高い効率的なデータかつ充分な大量のデータを生成でき、モデルの性能を高めることができる。よって、学習の速い学習プログラムを提供できる。
- [0049] なお、本発明の技術的範囲は上述の実施形態に限定されるものではなく、本発明の趣旨を逸脱しない範囲において種々の変更を加えることが可能である。
- [0050] その他、本発明の趣旨に逸脱しない範囲で、上述の実施形態における構成要素を周知の構成要素に置き換えることは適宜可能である。また、本発明の趣旨に逸脱しない範囲で、上述した変形例を適宜組み合わせてもよい。
- [0051] 以上説明したように、実施形態に係る学習装置100は、元画像データに基づいて増加させた学習候補データを作成するデータ拡張処理部10と、学

習候補データに、確信度評価値 E_s を付す確信度評価部 20 と、学習候補データの中から確信度評価値 E_s の順に学習用データを抽出する学習用データ抽出部 40 と、学習用データに基づく学習を行う学習処理部 50 と、を備える。学習用データ抽出部 40 は、学習用データを、学習候補データに付された確信度評価値 E_s があらかじめ設定された確信度評価閾値 α になるまで抽出する。これにより、少ないデータから機械学習モデルの学習にとって質の高い効率的なデータかつ十分な大量のデータを生成でき、モデルの性能を高めることができる。よって、学習の速い学習装置 100 を提供できる。

[0052] 実施形態に係る学習方法は、元画像データに基づいて増加させた学習候補データを作成するデータ拡張処理ステップと、学習候補データに、確信度評価値 E_s を付す確信度評価ステップと、前記学習候補データの中から確信度評価値 E_s の順に学習用データを抽出する学習用データ抽出ステップと、前記学習用データに基づく学習を行う学習処理ステップと、を備える。学習方法は、学習用データ抽出ステップにおいて、学習用データを、学習候補データに付された確信度評価値 E_s があらかじめ設定された確信度評価閾値 α になるまで抽出する。これにより、少ないデータから機械学習モデルの学習にとって質の高い効率的なデータかつ十分な大量のデータを生成でき、モデルの性能を高めることができる。よって、学習の速い学習方法を提供できる。

[0053] 実施形態に係る学習プログラムは、コンピュータに、元画像データに基づいて増加させた学習候補データを作成するデータ拡張処理機能と、学習候補データに、確信度評価値 E_s を付す確信度評価機能と、学習候補データの中から確信度評価値 E_s の順に学習用データを抽出する学習用データ抽出機能と、学習用データに基づく学習を行う学習処理機能と、を実行させる学習プログラムである。学習プログラムは、学習用データ抽出機能において、学習用データを、学習候補データに付された確信度評価値 E_s があらかじめ設定された確信度評価閾値 α になるまで抽出する。これにより、少ないデータから機械学習モデルの学習にとって質の高い効率的なデータかつ十分な大量のデータを生成でき、モデルの性能を高めることができる。よって、学習の速

い学習プログラムを提供できる。

符号の説明

[0054] 100 学習装置、10 データ拡張処理部、20 確信度評価部、30
代表画像選出処理部、40 学習用データ抽出部、50 学習処理部、60
制御部、 α 確信度評価閾値、 β 代表画像種類数閾値

請求の範囲

- [請求項1] 元画像データに基づいて増加させた学習候補データを作成するデータ拡張処理部と、
前記学習候補データに、確信度評価値を付す確信度評価部と、
前記学習候補データの中から前記確信度評価値の順に学習用データを抽出する学習用データ抽出部と、
前記学習用データに基づく学習を行う学習処理部と、
前記学習候補データの中から、前記元画像データが共通する拡張画像群の代表を代表画像として選出して前記学習データとして抽出する代表画像選出処理部と、を備え、
前記学習用データ抽出部は、前記学習用データを、前記学習候補データに付された前記確信度評価値があらかじめ設定された確信度評価閾値になるまで抽出する
学習装置。
- [請求項2] 前記学習用データ抽出部は、前記学習用データを、前記代表画像の種類数があらかじめ設定された代表画像種類数閾値になるまで抽出する
請求項1に記載の学習装置。
- [請求項3] 前記学習用データ抽出部は、前記代表画像の中で最も大きい前記確信度評価値が付された学習候補データより小さな前記確信度評価値が付された学習候補データを学習用データに含める
請求項1に記載の学習装置。
- [請求項4] 元画像データに基づいて増加させた学習候補データを作成するデータ拡張処理ステップと、
前記学習候補データに、確信度評価値を付す確信度評価ステップと、
、
前記学習候補データの中から前記確信度評価値の順に学習用データを抽出する学習用データ抽出ステップと、

前記学習用データに基づく学習を行う学習処理ステップと、

前記学習候補データの中から、前記元画像データが共通する拡張画像群の代表を代表画像として選出して前記学習データとして抽出する代表画像選出処理ステップと、を備え、

前記学習用データ抽出ステップにおいて、前記学習用データを、前記学習候補データに付された前記確信度評価値があらかじめ設定された確信度評価閾値になるまで抽出する学習方法。

[請求項5]

コンピュータに、

元画像データに基づいて増加させた学習候補データを作成するデータ拡張処理機能と、

前記学習候補データに、確信度評価値を付す確信度評価機能と、

前記学習候補データの中から前記確信度評価値の順に学習用データを抽出する学習用データ抽出機能と、

前記学習用データに基づく学習を行う学習処理機能と、

前記学習候補データの中から、前記元画像データが共通する拡張画像群の代表を代表画像として選出して前記学習データとして抽出する代表画像選出処理機能と、

を実行させる学習プログラムであって、

前記学習用データ抽出機能において、前記学習用データを、前記学習候補データに付された前記確信度評価値があらかじめ設定された確信度評価閾値になるまで抽出する学習プログラム。