

(19)日本国特許庁(JP)

(12)特許公報(B2)

(11)特許番号
特許第7567371号
(P7567371)

(45)発行日 令和6年10月16日(2024.10.16)

(24)登録日 令和6年10月7日(2024.10.7)

(51)国際特許分類		F I	
G 0 6 N	20/00 (2019.01)	G 0 6 N	20/00
G 0 6 F	17/18 (2006.01)	G 0 6 F	17/18 Z
G 0 6 N	20/20 (2019.01)	G 0 6 N	20/20
G 0 6 N	3/04 (2023.01)	G 0 6 N	3/04
G 0 6 N	3/08 (2023.01)	G 0 6 N	3/08
請求項の数 9 (全22頁) 最終頁に続く			
(21)出願番号	特願2020-182206(P2020-182206)	(73)特許権者	000002369 セイコーエプソン株式会社 東京都新宿区新宿四丁目1番6号
(22)出願日	令和2年10月30日(2020.10.30)	(74)代理人	110000028 弁理士法人明成国際特許事務所
(65)公開番号	特開2022-72648(P2022-72648A)	(72)発明者	渡邊 亮基 長野県諏訪市大和3丁目3番5号 セイ コーエプソン株式会社内
(43)公開日	令和4年5月17日(2022.5.17)	(72)発明者	倉沢 光 長野県諏訪市大和3丁目3番5号 セイ コーエプソン株式会社内
審査請求日	令和5年7月19日(2023.7.19)	審査官	真木 健彦
		最終頁に続く	

(54)【発明の名称】 機械学習モデルを用いてクラス分類処理を実行する方法、情報処理装置、及び、コンピュータプログラム

(57)【特許請求の範囲】

【請求項1】
機械学習モデルを用いて被分類データのクラス分類処理を実行する方法であって、
(a) Nを2以上の整数とするとき、N個の機械学習モデルを準備する工程であって、前記N個の機械学習モデルのそれぞれは、前記N個の機械学習モデルに共通に入力される入力データを複数のクラスのいずれかに分類するように構成されるとともに、前記N個の機械学習モデルのうちの他の機械学習モデルと異なる少なくとも1つのクラスを有するように構成される、工程と、
(b) 前記N個の機械学習モデルを用いて、前記被分類データのクラス分類処理を実行する工程と、
を含む、方法。

【請求項2】
請求項1に記載の方法であって、
任意の1個の機械学習モデルにより分類できるクラスの数には上限値が設定されており、前記工程(a)は、
(a1) 前記上限値に等しい数のクラスを有する第1機械学習モデルを準備する工程と、
(a2) 前記第1機械学習モデルを用いて前記入力データに対する前記クラス分類処理を実行したときに前記入力データが未知のクラスに属するものと判定された場合に、前記入力データに対応するクラスを有する第2機械学習モデルを追加する工程と、
を含む、方法。

【請求項 3】

請求項 2 に記載の方法であって、

前記工程 (a 2) は、前記工程 (a 2) で使用された前記入力データを含む教師データを用いて、前記第 2 機械学習モデルの学習を実行する工程を含み、

前記教師データは、更に、前記第 1 機械学習モデルに含まれている少なくとも 1 つのクラスに関する学習を行うための既存の教師データを含む、方法。

【請求項 4】

請求項 1 ~ 3 のいずれか一項に記載の方法であって、

任意の 1 個の機械学習モデルにより分類できるクラスの数には上限値が設定されており、

前記 N 個の機械学習モデルのうち、(N - 1) 個の機械学習モデルは前記上限値に等しい数のクラスを有し、他の 1 個の機械学習モデルは前記上限値以下の数のクラスを有し、

前記工程 (b) は、

前記 N 個の機械学習モデルを用いて前記被分類データに対する前記クラス分類処理を実行したときに前記被分類データが未知のクラスに属するものと判定されたときに、

(b 1) 前記他の 1 個の機械学習モデルが前記上限値未満の数のクラスを有する場合には、前記他の 1 個の機械学習モデルについて、前記被分類データを含む教師データを用いた学習を行うことによって前記被分類データに対する新たなクラスを追加し、

(b 2) 前記他の 1 個の機械学習モデルが前記上限値に等しい数のクラスを有する場合には、前記被分類データに対応するクラスを有する新たな機械学習モデルを追加する、

工程を含む、方法。

【請求項 5】

請求項 4 に記載の方法であって、

前記工程 (b 2) は、前記工程 (b) で使用された前記被分類データを含む教師データを用いて、前記新たな機械学習モデルの学習を実行する工程を含み、

前記教師データは、更に、前記 N 個の機械学習モデルに含まれている少なくとも 1 つのクラスに関する学習を行うための既存の教師データを含む、方法。

【請求項 6】

請求項 1 ~ 5 のいずれか一項に記載の方法であって、

前記 N 個の機械学習モデルのそれぞれは、複数のベクトルニューロン層を有するベクトルニューラルネットワークを含み、

前記方法は、更に、

学習済みの前記 N 個の機械学習モデルに複数の教師データが入力されたときに前記複数のベクトルニューロン層のうちの少なくとも 1 つの特定層の出力から得られる既知特徴スペクトル群を準備する工程と、

前記 N 個の機械学習モデルに前記被分類データが入力されたときに前記特定層の出力から得られる特徴スペクトルと、前記既知特徴スペクトル群とを用いて、前記被分類データが前記複数のクラスのいずれに類似するかを示す類似度を演算する工程と、

前記 N 個の機械学習モデルによる前記クラス分類処理の結果が前記類似度と整合しない場合に、前記被分類データが未知のクラスに属するものと判定する工程と、

を含む、方法。

【請求項 7】

請求項 6 に記載の方法であって、

前記特定層は、第 1 軸と第 2 軸の 2 つの軸で規定された平面に配置されたベクトルニューロンが、前記 2 つの軸とは異なる方向の第 3 軸に沿って複数のチャンネルとして配置されている構成を有し、

前記特徴スペクトルは、

(i) 前記特定層のうちの 1 つの平面位置におけるベクトルニューロンの出力ベクトルの複数の要素値を、前記第 3 軸に沿った前記複数のチャンネルにわたって配列した第 1 種の特徴スペクトルと、

(ii) 前記第 1 種の特徴スペクトルの各要素値に、前記出力ベクトルのベクトル長に相

10

20

30

40

50

当するアクティベーション値を乗じることによって得られる第2種の特徴スペクトルと、
(iii) 前記特定層のうちの1つの平面位置における前記アクティベーション値を、前記第3軸に沿った前記複数のチャンネルにわたって配列した第3種の特徴スペクトルと、
のうちのいずれかである、方法。

【請求項8】

機械学習モデルを用いて被分類データのクラス分類処理を実行する情報処理装置であって、

Nを2以上の整数とするとき、N個の機械学習モデルを記憶するメモリと、

前記N個の機械学習モデルを用いた演算を実行するプロセッサと、
を備え、

前記N個の機械学習モデルのそれぞれは、前記N個の機械学習モデルに共通に入力される入力データを複数のクラスのいずれかに分類するように構成されるとともに、前記N個の機械学習モデルのうちの他の機械学習モデルと異なる少なくとも1つのクラスを有するように構成されており、

前記プロセッサは、前記N個の機械学習モデルを用いて、前記被分類データのクラス分類処理を実行するように構成されている、情報処理装置。

【請求項9】

機械学習モデルを用いて被分類データのクラス分類処理をプロセッサに実行させるコンピュータプログラムであって、

Nを2以上の整数とするとき、前記機械学習モデルは、N個の機械学習モデルを含み、
前記N個の機械学習モデルのそれぞれは、前記N個の機械学習モデルに共通に入力される入力データを複数のクラスのいずれかに分類するように構成されるとともに、前記N個の機械学習モデルのうちの他の機械学習モデルと異なる少なくとも1つのクラスを有するように構成されており、

前記コンピュータプログラムは、

前記N個の機械学習モデルを用いて、前記被分類データのクラス分類処理を実行する処理を前記プロセッサに実行させる、コンピュータプログラム。

【発明の詳細な説明】

【技術分野】

【0001】

本開示は、機械学習モデルを用いてクラス分類処理を実行する方法、情報処理装置、及び、コンピュータプログラムに関する。

【背景技術】

【0002】

特許文献1には、VAE (Variational Autoencoder) を用いて入力データのクラス分類を行う技術が開示されている。この技術では、判別したい1クラスごとにVAEを構築し、入力データと1つのVAEから出力されたデータを比較することによって、入力データがそのVAEに対応するクラスに該当するか否かを判別する。入力データがそのVAEに対応するクラスに該当しない場合には、別のVAEを用いて再度判別を実行する。

【先行技術文献】

【特許文献】

【0003】

【文献】特開2019-204321号公報

【発明の概要】

【発明が解決しようとする課題】

【0004】

しかしながら、上述の技術では、1クラスごとにVAEを構築する必要があるため、処理量が多く、演算に多大な時間を要するという問題があった。

【課題を解決するための手段】

【0005】

本開示の第１の形態によれば、機械学習モデルを用いて被分類データのクラス分類処理を実行する方法が提供される。この方法は、（ａ） N を２以上の整数とすると、 N 個の機械学習モデルを準備する工程であって、前記 N 個の機械学習モデルのそれぞれは、前記 N 個の機械学習モデルに共通に入力される入力データを複数のクラスのいずれかに分類するように構成されるとともに、前記 N 個の機械学習モデルのうちの他の機械学習モデルと異なる少なくとも１つのクラスを有するように構成される、工程と、（ｂ）前記 N 個の機械学習モデルを用いて、前記被分類データのクラス分類処理を実行する工程と、を含む。

【０００６】

本開示の第２の形態によれば、機械学習モデルを用いて被分類データのクラス分類処理を実行する情報処理装置が提供される。この情報処理装置は、 N を２以上の整数とすると、 N 個の機械学習モデルを記憶するメモリーと、前記 N 個の機械学習モデルを用いた演算を実行するプロセッサと、を備える。前記 N 個の機械学習モデルのそれぞれは、前記 N 個の機械学習モデルに共通に入力される入力データを複数のクラスのいずれかに分類するように構成されるとともに、前記 N 個の機械学習モデルのうちの他の機械学習モデルと異なる少なくとも１つのクラスを有するように構成されている。前記プロセッサは、前記 N 個の機械学習モデルを用いて、前記被分類データのクラス分類処理を実行するように構成されている。

【０００７】

本開示の第３の形態によれば、機械学習モデルを用いて被分類データのクラス分類処理をプロセッサに実行させるコンピュータプログラムが提供される。 N を２以上の整数とすると、前記機械学習モデルは、 N 個の機械学習モデルを含み、前記 N 個の機械学習モデルのそれぞれは、前記 N 個の機械学習モデルに共通に入力される入力データを複数のクラスのいずれかに分類するように構成されるとともに、前記 N 個の機械学習モデルのうちの他の機械学習モデルと異なる少なくとも１つのクラスを有するように構成されている。前記コンピュータプログラムは、前記 N 個の機械学習モデルを用いて、前記被分類データのクラス分類処理を実行する処理を前記プロセッサに実行させる。

【図面の簡単な説明】

【０００８】

【図１】実施形態における情報処理装置のブロック図。

【図２】制御装置のブロック図。

【図３】第１機械学習モデルの構成を示す説明図。

【図４】第２機械学習モデルの構成を示す説明図。

【図５】準備工程の処理手順を示すフローチャート。

【図６】特徴スペクトルを示す説明図。

【図７】既知特徴スペクトル群の構成を示す説明図。

【図８】クラス分類工程の処理手順を示すフローチャート。

【図９】機械学習モデルの更新処理の処理手順を示すフローチャート。

【発明を実施するための形態】

【０００９】

A．実施形態：

図１は、一実施形態における情報処理装置としてのプリンター１０の機能を示すブロック図である。プリンター１０は、制御装置２０と、印刷機構３０と、印刷媒体ホルダー４０と、分光測定器５０とを有する。印刷媒体ホルダー４０には、印刷媒体PMが収納される。分光測定器５０は、印刷媒体ホルダー４０に収納された印刷媒体PMの分光測定を行って、分光スペクトルデータを取得する。分光測定器５０は、例えば、波長可変干渉分光フィルターと、モノクロイメージセンサーとを備える。分光測定器５０で得られた分光スペクトルデータは、後述する機械学習モデルへの入力データ又は被分類データとして使用される。後述するように、制御装置２０は、機械学習モデルを用いて分光スペクトルデータのクラス分類処理を実行し、印刷媒体PMが複数のクラスのいずれに該当するかを分類する。「印刷媒体PMのクラス」とは、印刷媒体PMの種類を意味する。制御装置２０は

10

20

30

40

50

、印刷媒体PMの種類に応じた適切な印刷条件で印刷を実行するように印刷機構30を制御する。なお、本開示は、プリンター10以外の種々の情報処理装置にも適用可能である。

【0010】

図2は、制御装置20の機能を示すブロック図である。制御装置20は、プロセッサ110と、メモリ120と、インターフェイス回路130と、インターフェイス回路130に接続された入力デバイス140及び表示部150と、を有している。限定されないが例えば、プロセッサ110は、以下で詳述される処理を実行する機能を有するだけでなく、表示部150に、当該処理によって得られるデータ、および当該処理の過程で生成されるデータを表示する機能も有する。インターフェイス回路130には、分光測定器50と印刷機構30も接続されている。

10

【0011】

プロセッサ110は、印刷機構30の制御を行う印刷制御部112として機能し、また、入力データのクラス分類処理を実行するクラス分類処理部114としても機能する。これらの各部112、114は、メモリ120に格納されたコンピュータプログラムをプロセッサ110が実行することによって実現される。但し、これらの各部112、114をハードウェア回路で実現してもよい。本明細書のプロセッサは、このようなハードウェア回路をも含む用語である。また、クラス分類処理を実行するプロセッサは、ネットワークを介してプリンター10に接続されたりリモートコンピュータに含まれるプロセッサであってもよい。メモリ120には、複数の機械学習モデル201、202と、複数の教師データ群TD1、TD2と、複数の既知特徴スペクトル群KS1、KS2と、被分類データDiとが格納される。機械学習モデル201、202は、クラス分類処理部114による演算に使用される。機械学習モデル201、202の構成例や動作については後述する。教師データ群TD1、TD2は、機械学習モデル201、202の学習に使用されるラベル付きの分光スペクトルデータの集合である。既知特徴スペクトル群KS1、KS2は、学習済みの機械学習モデル201、202に教師データ群TD1、TD2を再度入力した際に得られる特徴スペクトルの集合である。特徴スペクトルについては後述する。被分類データDiは、クラス分類処理の処理対象となる新たな印刷媒体PMの分光スペクトルデータである。

20

【0012】

図3は、第1の機械学習モデル201の構成を示す説明図である。この機械学習モデル201は、入力データIMの側から順に、畳み込み層211と、プライマリーベクトルニューロン層221と、第1畳み込みベクトルニューロン層231と、第2畳み込みベクトルニューロン層241と、分類ベクトルニューロン層251とを備える。これらの5つの層211～251のうち、畳み込み層211が最も下位の層であり、分類ベクトルニューロン層251が最も上位の層である。以下の説明では、層211～251を、それぞれ「Conv層211」、「PrimeVN層221」、「ConvVN1層231」、「ConvVN2層241」、及び「ClassVN層251」とも呼ぶ。

30

【0013】

本実施形態において、入力データIMは分光スペクトルデータなので、1次元配列のデータである。例えば、入力データIMは、380nm～730nmの範囲の分光スペクトルデータから、10nm毎に36個の代表値を抽出したデータである。但し、入力データIMとして、画像などの2次元配列のデータを用いてもよい。

40

【0014】

図3の例では2つの畳み込みベクトルニューロン層231、241を用いているが、畳み込みベクトルニューロン層の数は任意であり、畳み込みベクトルニューロン層を省略してもよい。但し、1つ以上の畳み込みベクトルニューロン層を用いることが好ましい。

【0015】

図3の機械学習モデル201は、更に、類似度を生成する類似度演算部261を有している。類似度演算部261は、ConvVN1層231と、ConvVN2層241と、ClassVN層251の出力から、後述する類似度S1_ConvVN1、S1_ConvVN2、S1_ClassVNを

50

それぞれ算出することが可能である。但し、類似度演算部 261 を省略してもよい。

【0016】

各層 211～251 の構成は、以下のように記述できる。

＜第1の機械学習モデル 201 の構成の記述＞

- ・Conv層 211 : Conv[32,6,2]
- ・PrimeVN層 221 : PrimeVN[26,1,1]
- ・ConvVN1層 231 : ConvVN1[20,5,2]
- ・ConvVN2層 241 : ConvVN2[16,4,1]
- ・ClassVN層 251 : ClassVN[n1+1,3,1]
- ・ベクトル次元 V D : V D=16

これらの各層 211～251 の記述において、括弧前の文字列はレイヤー名であり、括弧内の数字は、順に、チャンネル数、カーネルサイズ、及び、ストライドである。例えば、Conv層 211 のレイヤー名は「Conv」であり、チャンネル数は32、カーネルサイズは1×6、ストライドは2である。図3では、各層の下にこれらの記述が示されている。各層の中に描かれているハッチングを付した矩形は、隣接する上位層の出力ベクトルを算出する際に使用されるカーネルを表している。本実施形態では、入力データ I M が1次元配列のデータなので、カーネルも1次元の配列を有する。なお、各層 211～251 の記述で用いたパラメーターの値は例示であり、任意に変更可能である。

【0017】

Conv層 211 は、スカラーニューロンで構成された層である。他の4つの層 221～251 は、ベクトルニューロンで構成された層である。ベクトルニューロンは、ベクトルを入出力とするニューロンである。上記の記述では、個々のベクトルニューロンの出力ベクトルの次元は16で一定である。以下では、スカラーニューロン及びベクトルニューロンの上位概念として「ノード」という語句を使用する。

【0018】

図3では、Conv層 211 について、ノード配列の平面座標を規定する第1軸 x 及び第2軸 y と、奥行きを表す第3軸 z とが示されている。また、Conv層 211 の x, y, z 方向のサイズが1, 16, 32であることが示されている。x方向のサイズとy方向のサイズを「解像度」と呼ぶ。本実施形態では、x方向の解像度は常に1である。z方向のサイズは、チャンネル数である。これらの3つの軸 x, y, z は、他の層においても各ノードの位置を示す座標軸として使用する。但し、図3では、Conv層 211 以外の層では、これらの軸 x, y, z の図示が省略されている。

【0019】

よく知られているように、畳み込み後の y 方向の解像度 W1 は、次式で与えられる。

$$W1 = \text{Ceil}\{(W0 - Wk + 1) / S\} \quad (1)$$

ここで、W0 は畳み込み前の解像度、Wk はカーネルサイズ、S はストライド、Ceil {X} は X を切り上げる演算を行う関数である。

図3に示した各層の解像度は、入力データ I M の y 方向の解像度を36とした場合の例であり、実際の各層の解像度は入力データ I M のサイズに応じて適宜変更される。

【0020】

ClassVN層 251 は、(n1+1) 個のチャンネルを有している。図3の例では (n1+1) = 11 である。これらのチャンネルからは、複数の既知のクラスに対する判定値 Class1-1～Class1-10 と、未知のクラスであることを示す判定値 Class1-UN が出力される。これらの判定値 Class1-1～Class1-10, Class1-UN のうちで最も大きな値を有するクラスが、入力データ I M が属するクラスに相当する。一般に、n1 は1以上の整数であり、第1の機械学習モデル 201 を用いて分類可能な既知のクラスの数である。任意の1個の機械学習モデルにおいて、分類可能な既知のクラスの数 n1 に対して、上限値 nmax が予め設定されることが好ましい。図3の例では、既知のクラスの数 n1 は、その上限値 nmax である10に等しい。上限値 nmax は、所定の分類精度を満足することのできる理論上限値であってもよいし、上記理論上限値より小さい値を有する運用上限値であってもよい。

10

20

30

40

50

い。基本的に、運用上限値の方が、理論上限値よりも、より高い分類精度をもたらす。また、上限値 $n_{\max}$ は、複数の機械学習モデル 201, 202 において独立に設定することができ、それぞれ異なる値に設定することが可能である。

【0021】

なお、未知クラスであることを示す判定値 Class1-UN は省略してもよい。この場合には、既知のクラスに対する判定値 Class1-1 ~ Class1-10 のうちで最も大きな値が予め定められた閾値未満である場合に、入力データ IM のクラスが未知であるものと判定される。

【0022】

図4は、第2の機械学習モデル202の構成を示す説明図である。この機械学習モデル202は、第1の機械学習モデル201と同様に、Conv層212と、PrimeVN層222と、ConvVN1層232と、ConvVN2層242と、ClassVN層252と、類似度演算部262とを有している。

【0023】

各層212 ~ 252の構成は、以下のように記述できる。

<第2の機械学習モデル202の構成の記述>

- Conv層212 : Conv[32,6,2]
- PrimeVN層222 : PrimeVN[26,1,1]
- ConvVN1層232 : ConvVN1[20,5,2]
- ConvVN2層242 : ConvVN2[16,4,1]
- ClassVN層252 : ClassVN[n2+1,3,1]
- ベクトル次元VD : VD=16

【0024】

図3と図4を比較すれば理解できるように、第2の機械学習モデル202の層212 ~ 252のうち、下位の4つの層212 ~ 242は第1の機械学習モデル201の層211 ~ 241と同じ構成を有する。一方、第2の機械学習モデル202の最上位層252は、第1の機械学習モデル201の最上位層251とチャンネル数のみが異なる。図4の例では、ClassVN層252は $(n2+1)$ 個のチャンネルを有しており、 $(n2+1) = 3$ である。これらのチャンネルからは、複数の既知のクラスに対する判定値 Class2-1 ~ Class2-2 と、未知のクラスであることを示す判定値 Class2-UN が出力される。第2の機械学習モデル202においても、既知のクラスの数 $n2$ に、第1の機械学習モデル201と同じ上限値 $n_{\max}$ が設定されることが好ましい。図4の例では、既知のクラスの数 $n2$ が上限値 $n_{\max}$ よりも小さい。この場合に、第2の機械学習モデル202は、「上限値 $n_{\max}$ 未満の数のクラスを有する」と表現される。但し、クラス数の上限値 $n_{\max}$ は、複数の機械学習モデル201, 202において、それぞれ異なる値に設定することも可能である。

【0025】

第2の機械学習モデル202は、第1の機械学習モデル201と異なる少なくとも1つの既知のクラスを有するように構成される。また、第1の機械学習モデル201と第2の機械学習モデル202では、分類可能なクラスが異なるので、カーネルの要素の値も互いに異なる。本開示では、 N を2以上の整数としたとき、 N 個の機械学習モデルのうちの任意の1個の機械学習モデルは、他の機械学習モデルと異なる少なくとも1つの既知のクラスを有するように構成される。

【0026】

図5は、機械学習モデルの準備工程の処理手順を示すフローチャートである。ステップ S110 では、ユーザーが、クラス分類処理に使用する機械学習モデルを作成し、そのパラメータを設定する。本実施形態では、図3と図4に示す2つの機械学習モデル201, 202 が作成されてそれらのパラメータが設定される。但し、ステップ S110 では、1つの機械学習モデルのみを作成にしてもよく、或いは、3つ以上の機械学習モデルを作成してもよい。ステップ S120 では、クラス分類処理部114が、教師データ群 TD1, TD2 を用いて機械学習モデル201, 202 の学習を実行する。個々の教師データには、予めラベルが付与されている。例えば、第1の機械学習モデル201は、10個の

既知のクラスを有するので、その教師データには、1～10のいずれかの値のラベルが付与される。学習が修了すると、学習済みの機械学習モデル201、202がメモリー120に保存される。

【0027】

ステップS130では、クラス分類処理部114が、学習済みの機械学習モデル201、202に複数の教師データ群TD1、TD2を再度入力して、既知特徴スペクトル群KS1、KS2を生成する。既知特徴スペクトル群KS1、KS2は、以下で説明する特徴スペクトルの集合である。以下では、主として機械学習モデル201に対応付けられた既知特徴スペクトル群KS1を生成する方法を説明する。

【0028】

図6は、学習済みの機械学習モデル201に任意の入力データを入力することによって得られる特徴スペクトルSpを示す説明図である。ここでは、ConvVN1層231の出力から得られる特徴スペクトルSpについて説明する。図6の横軸は、ConvVN1層231の1つの平面位置(x, y)におけるノードの出力ベクトルの要素番号NDと、チャンネル番号NCとの組み合わせで表されるスペクトル位置である。本実施形態では、ノードのベクトル次元が16なので、出力ベクトルの要素番号NDは0から15までの16個である。また、ConvVN1層231のチャンネル数は20なので、チャンネル番号NCは0から19までの20個である。

【0029】

図6の縦軸は、各スペクトル位置での特徴値Cvを示す。この例では、特徴値Cvは、出力ベクトルの各要素の値VNDである。なお、特徴値Cvとしては、出力ベクトルの各要素の値VNDと、後述するアクティベーション値とを乗算した値を使用してもよく、或いは、アクティベーション値をそのまま使用してもよい。後者の場合には、特徴スペクトルSpに含まれる特徴値Cvの数はチャンネル数に等しく、20個である。なお、アクティベーション値は、そのノードの出力ベクトルのベクトル長さに相当する値である。

【0030】

1つの入力データに対してConvVN1層231の出力から得られる特徴スペクトルSpの数は、ConvVN1層231の平面位置(x, y)の数に等しいので、 $1 \times 6 = 6$ 個である。同様に、1つの入力データに対して、ConvVN2層241の出力から3個の特徴スペクトルSpが得られ、ClassVN層251の出力から1個の特徴スペクトルSpが得られる。

【0031】

類似度演算部261は、学習済みの機械学習モデル201に教師データ群TD1が再度入力されたときに、図6に示す特徴スペクトルSpを算出して、既知特徴スペクトル群KS1に登録する。

【0032】

図7は、既知特徴スペクトル群KS1の構成を示す説明図である。この例では、既知特徴スペクトル群KS1は、ConvVN1層231の出力から得られた既知特徴スペクトル群KS1_ConvVN1と、ConvVN2層241の出力から得られた既知特徴スペクトル群KS1_ConvVN2と、ClassVN層251の出力から得られた既知特徴スペクトル群KS1_ConvVN1とを含んでいる。

【0033】

既知特徴スペクトル群KS1_ConvVN1の個々のレコードは、レコード番号と、レイヤ名と、ラベルLbと、既知特徴スペクトルKSpとを含んでいる。既知特徴スペクトルKSpは、教師データの入力に応じて得られた図6の特徴スペクトルSpと同じものである。図7の例では、教師データ群TD1を学習済みの機械学習モデル201に入力することによって、ConvVN1層231の出力から、個々のラベルLbの値に関連付けられた既知特徴スペクトルKSpが生成されて登録されている。例えば、ラベルLb=1に関連付けられてN1_1max個の既知特徴スペクトルKSpが登録され、ラベルLb=2に関連付けられてN1_2max個の既知特徴スペクトルKSpが登録され、ラベルLb=n1に関連

10

20

30

40

50

づけられて $N1_n1max$ 個の既知特徴スペクトル KS_p が登録されている。 $N1_1max$, $N1_2max$, $N1_n1max$ は、それぞれ 2 以上の整数である。前述したように、個々のラベル L_b は、互いに異なる既知のクラスに対応する。従って、既知特徴スペクトル群 $KS1_ConvVN1$ における個々の既知特徴スペクトル KS_p は、複数の既知のクラスのうちの 1 つのクラスに関連付けられて登録されていることが理解できる。他の既知特徴スペクトル群 $KS1_ConvVN2$, $KS1_ConvVN1$ も同様である。

【0034】

なお、ステップ $S130$ で使用される教師データは、ステップ $S120$ で使用された複数の教師データ群 $TD1$, $TD2$ と同じものである必要は無い。但し、ステップ $S130$ においても、ステップ $S120$ で使用された複数の教師データ群 $TD1$, $TD2$ の一部又は全部を利用すれば、新たな教師データを準備する必要が無いという利点がある。

【0035】

図 8 は、学習済みの機械学習モデルを用いたクラス分類工程の処理手順を示すフローチャートである。ステップ $S120$ では、クラス分類処理部 114 が、印刷媒体ホルダー 40 が開閉されたか否かを判定し、開閉があるまで待機する。この判定は、印刷媒体ホルダー 40 に設置された図示しない開閉スイッチからの出力信号に応じて行われる。印刷媒体ホルダー 40 が開閉された場合には、ステップ $S130$ に進み、クラス分類処理部 114 が、分光測定器 50 に印刷媒体 PM の分光測定を実行させることによって、分光スペクトルデータを取得する。この分光スペクトルデータは、クラス分類処理の対象である被分類データ Di となる。

【0036】

ステップ $S230$ では、クラス分類処理部 114 が、既存の学習済みの機械学習モデル 201, 202 に被分類データ Di を入力して、被分類データ Di のクラス分類処理を実行する。この場合に、複数の機械学習モデル 201, 202 を 1 個ずつ順次使用する第 1 の処理方法と、複数の機械学習モデル 201, 202 を同時に使用する第 2 の処理方法とのいずれかを利用可能である。第 1 の処理方法では、まず、1 個の機械学習モデル 201 を使用してクラス分類処理を実行し、その結果として被分類データ Di が未知のクラスに属するものと判定された場合に、他の機械学習モデル 202 を使用してクラス分類処理を実行する。第 2 の処理方法では、2 つの機械学習モデル 201, 202 を同時に用いて同じ被分類データ Di に対するクラス分類処理を並行して実行し、クラス分類処理部 114 がそれらの処理結果を統合する。本開示の発明者の実験によれば、第 2 の処理方法の方が第 1 の処理方法に比べて処理時間がより短くなるので、より好ましい。

【0037】

ステップ $S240$ では、クラス分類処理部 114 が、ステップ $S230$ におけるクラス分類処理の結果から、被分類データ Di が未知のクラスに属するか、既知のクラスに属するかを判定する。被分類データ Di が未知のクラスに属する場合には、後述するステップ $S300$ に進み、機械学習モデルの更新処理が実行される。一方、被分類データ Di が既知のクラスに属する場合には、ステップ $S250$ に進む。

【0038】

ステップ $S250$ では、複数の機械学習モデル 201, 202 のうちで、被分類データ Di が既知のクラスに属するものと判定した 1 つの機械学習モデルを用いて、既知特徴スペクトル群との類似度が算出される。例えば、第 1 の機械学習モデル 201 の処理によって被分類データ Di が既知のクラスに属するものと判定された場合には、その類似度演算部 261 が、 $ConvVN1$ 層 231 と、 $ConvVN2$ 層 241 と、 $ClassVN$ 層 251 の出力から、既知特徴スペクトル群 $KS1$ との類似度 $S1_ConvVN1$, $S1_ConvVN2$, $S1_ClassVN$ をそれぞれ算出する。一方、第 2 の機械学習モデル 202 の処理によって被分類データ Di が既知のクラスに属するものと判定された場合には、その類似度演算部 262 が、既知特徴スペクトル群 $KS2$ との類似度 $S2_ConvVN1$, $S2_ConvVN2$, $S2_ClassVN$ をそれぞれ算出する。以下では、第 1 の機械学習モデル 201 の $ConvVN1$ 層 231 の出力から類似度 $S1_ConvVN1$ を算出する方法を説明する。

【0039】

類似度 $S1_ConvVN1$ は、例えば次式を用いて算出できる。

$$S1_ConvVN1(Class) = \max[G\{Sp(i,j), KSp(Class,k)\}]$$

ここで、"Class" は複数のクラスに対する序数、 $G\{a, b\}$ は a と b の類似度を求める関数、 $Sp(i, j)$ は被分類データ D_i に応じて得られるすべての平面位置 (i, j) での特徴スペクトル、 $KSp(Class, k)$ は、ConvVN1層231と特定の"Class"とに関連付けられたすべての既知特徴スペクトル、 $\max[X]$ は X の最大値を取る論理演算を示す。すなわち、類似度 $S1_ConvVN1$ は、ConvVN1層231のすべての平面位置 (i, j) における特徴スペクトル $Sp(i, j)$ のそれぞれと、特定のクラスに対応するすべての既知特徴スペクトル $KSp(k)$ のそれぞれとの間で算出された類似度のうちの最大値である。このような類似度 $S1_ConvVN1$ は、複数のラベル L_b に対応する複数のクラスのそれぞれに対して求められる。類似度 $S1_ConvVN1$ は、被分類データ D_i が、各クラスの特徴に類似している程度を表している。

10

【0040】

ConvVN2層241とClassVN層251の出力に関する類似度 $S1_ConvVN2$ 、 $S1_ClassVN$ も、類似度 $S1_ConvVN1$ と同様に生成される。なお、これらの3つの類似度 $S1_ConvVN1$ 、 $S1_ConvVN2$ 、 $S1_ClassVN$ をすべて生成する必要はないが、これらのうちの1つ以上を生成することが好ましい。本開示において、類似度の生成に使用された層を、「特定層」とも呼ぶ。

【0041】

ステップS260では、クラス分類処理部114が、ステップS250で得られた類似度をユーザーに提示し、ユーザーは、その類似度がクラス分類処理の結果と整合しているか否かを確認する。類似度 $S1_ConvVN1$ 、 $S1_ConvVN2$ 、 $S1_ClassVN$ は、被分類データ D_i が、各クラスの特徴に類似している程度を表しているため、これらの類似度 $S1_ConvVN1$ 、 $S1_ConvVN2$ 、 $S1_ClassVN$ の少なくとも1つから、クラス分類処理の結果の良否を確認することができる。例えば、3つの類似度 $S1_ConvVN1$ 、 $S1_ConvVN2$ 、 $S1_ClassVN$ のうちの少なくとも1つが、クラス分類処理の結果と一致していない場合に、両者が整合しないものと判定できる。他の実施形態では、3つの類似度 $S1_ConvVN1$ 、 $S1_ConvVN2$ 、 $S1_ClassVN$ のすべてが、クラス分類処理の結果と一致していない場合に、両者が整合しないものと判定してもよい。一般には、複数の層の出力から生成された複数の類似度のうちの予め定められた数の類似度がクラス分類処理の結果と一致していない場合に、両者が整合しないものと判定してもよい。なお、ステップS260の判定は、クラス分類処理部114が行ってもよい。

20

【0042】

類似度がクラス分類処理の結果と整合している場合には、図8のクラス分類処理を終了する。一方、類似度がクラス分類処理の結果と整合していない場合には、以下で説明するステップS300に進み、機械学習モデルの更新処理が実行される。

30

【0043】

図9は、機械学習モデルの更新処理の処理手順を示すフローチャートである。ステップS310では、既存の機械学習モデルの中に、クラス数が上限値未満の機械学習モデルが存在するか否かを判定する。Nを2以上の整数としたとき、N個の既存の機械学習モデルが存在する場合には、その中で、クラス数が上限値未満の機械学習モデルが存在するか否かが判定される。但し、既存の機械学習モデルの数Nは、1としてもよい。本実施形態では、図3と図4に示す2つの既存の機械学習モデル201、202が存在しており、第1の機械学習モデル201はクラス数が上限値に等しく、第2の機械学習モデル202はクラス数が上限値未満である。既存の機械学習モデルの中にクラス数が上限値未満の機械学習モデルが存在しない場合には、後述するステップS340に進み、新たな機械学習モデルが追加される。一方、クラス数が上限値未満の機械学習モデルが存在する場合には、ステップS320に進み、その機械学習モデルが更新される。

40

【0044】

50

ステップS320では、クラス分類処理部114が、クラス数が上限値未満の機械学習モデルについて、その最上位層のチャンネル数を1つ増加するようにその機械学習モデルを更新する。本実施形態では、第2の機械学習モデル202の最上位層のチャンネル数($n2+1$)が、3から4に変更される。ステップS330では、クラス分類処理部114が、ステップS320で更新した機械学習モデルの学習を実行する。この学習の際には、それまでに使用されていた第2の機械学習モデル202用の教師データ群TD2とともに、図8のステップS220で取得された被分類データDiが新たな教師データとして使用される。なお、新たな教師データとしては、ステップS220で取得された被分類データDiに加えて、同じ印刷媒体PMの分光測定から得られた他の複数の分光スペクトルデータも使用することが好ましい。このため、分光測定器50は、1つの印刷媒体PMの複数の位置において分光スペクトルデータをそれぞれ取得するように構成されていることが好ましい。こうして学習が終了すると、更新された機械学習モデル202が、被分類データDiに対応する既知のクラスを有するものとなる。従って、更新された機械学習モデル202を用いて、この印刷媒体PMの種類を認識することが可能となる。

【0045】

ステップS340では、クラス分類処理部114が、被分類データDiに対応するクラスを有する新たな機械学習モデルを追加し、そのパラメータを設定する。この新たな機械学習モデルは、最上位層のチャンネル数を除いて、図3に示した第1の機械学習モデル201と同じ構成を有することが好ましい。この新たな機械学習モデルは、例えば、図4に示す第2の機械学習モデル202と同様に、2つ以上の既知クラスを有するものとする。2つ以上の既知クラスのうちの1つは、被分類データDiに対応するクラスである。また、2つ以上の既知クラスのうちの少なくとも1つは、既存の機械学習モデルの少なくとも1つの既知クラスと同じものとする。新たな機械学習モデルの1つのクラスを既存の機械学習モデルの既知クラスと同じにすることは、その既知クラスのために既存の機械学習モデルの学習で使用されていた教師データと同じ教師データを用いて、新たな機械学習モデルの学習を行うことによって実現される。新たな機械学習モデルに2つ以上の既知クラスを設ける理由は、既知クラスを1つだけとすると、その学習を十分な精度で行えない可能性があるからである。

【0046】

新たな機械学習モデルに採用する既存の機械学習モデルのクラスとしては、例えば、以下のクラスの中から選択することが好ましい。

(a) 既存の機械学習モデルにおける複数の既知クラスの中で、被分類データDiと最も類似度が高い光学スペクトルデータに対応するクラス。

(b) 既存の機械学習モデルにおける複数の既知クラスの中で、被分類データDiと最も類似度が低い光学スペクトルデータに対応するクラス。

(c) 既存の機械学習モデルにおける複数の既知クラスの中で、図7のステップS240において被分類データDiが属するものと誤判別されたクラス。

このうち、上記(a)又は(c)のクラスを採用すれば、新たな機械学習モデルにおける誤判別を少なくすることができる。また、上記(b)のクラスを採用すれば、新たな機械学習モデルの学習時間を短くすることがかとうとなる。

【0047】

ステップS350では、クラス分類処理部114が、追加した機械学習モデルの学習を実行する。この学習では、図8のステップS220で取得された被分類データDiが新たな教師データとして使用される。また、新たな教師データとしては、ステップS220で取得された被分類データDiに加えて、同じ印刷媒体PMの分光測定から得られた他の複数の分光スペクトルデータも使用することが好ましい。また、新たな機械学習モデルの1つ以上のクラスを既存の機械学習モデルの既知クラスと同じにする場合には、その既知クラスのために既存の機械学習モデルの学習で使用されていた教師データも使用される。

【0048】

なお、第2の機械学習モデル202の既知のクラスの数が増え、上限値に達すると、図8の

10

20

30

40

50

テップ S 3 4 0, S 3 5 0 によって、3 番目の機械学習モデルが追加される。4 番目以降の機械学習モデルも同様である。このように、本実施形態では、N を 2 以上の整数としたとき、(N - 1) 個の機械学習モデルは上限値に等しい数のクラスを有し、他の 1 個の機械学習モデルは上限値以下の数のクラスを有するものとなる。また、N 個の機械学習モデルを用いて被分類データ D i に対するクラス分類処理を実行したときに被分類データ D i が未知のクラスに属するものと判定されたときには、以下のいずれかの処理が実行される。

(1) 他の 1 個の機械学習モデルが上限値未満の数のクラスを有する場合には、ステップ S 3 2 0, S 3 3 0 の処理により、他の 1 個の機械学習モデルについて、被分類データ D i を含む教師データを用いた学習を行うことによって被分類データ D i に対する新たなクラスを追加する。

(2) 他の 1 個の機械学習モデルが上限値に等しい数のクラスを有する場合には、ステップ S 3 4 0, S 3 5 0 の処理により、被分類データ D i に対応するクラスを有する新たな機械学習モデルを追加する。

これらの処理によれば、N 個の機械学習モデルで被分類データ D i のクラス分類がうまくできなかった場合にも、その被分類データ D i に対応するクラスへのクラス分類を行うことが可能となる。

【0049】

なお、図 9 に示した機械学習モデルの更新処理は、既存の機械学習モデルの数が 1 個の場合にも実行することができる。既存の機械学習モデルの数が 1 個の場合とは、例えば、図 4 に示した第 2 の機械学習モデル 2 0 2 が準備されておらず、図 8 の処理が、図 3 に示した第 1 の機械学習モデル 2 0 1 のみを用いて実行される場合である。この場合には、図 9 のステップ S 3 4 0, S 3 5 0 は、第 2 の機械学習モデル 2 0 2 を新たな機械学習モデルとして追加する処理となる。このように、第 1 の機械学習モデル 2 0 1 のみを用いて行ったクラス分類処理において、その入力データが未知のクラスに属すると判定された場合に第 2 の機械学習モデル 2 0 2 を新たな機械学習モデルとして追加する処理は、2 個の機械学習モデル 2 0 1, 2 0 2 を準備する処理の一例として理解することも可能である。

【0050】

ステップ S 3 6 0 では、クラス分類処理部 1 1 4 が、更新または追加した機械学習モデルに教師データを再度入力して既知特徴スペクトル群を生成する。この処理は、図 8 のステップ S 2 3 0 の処理と同じなので、説明を省略する。

【0051】

以上のように、本実施形態では、N を 2 以上の整数としたとき、N 個の機械学習モデルを用いてクラス分類処理を実行するので、1 個の機械学習モデルで多数のクラスへの分類処理を行う場合に比べて、処理を高速に実行できる。また、既存の機械学習モデルでは被分類データのクラス分類がうまくできない場合に、既存の機械学習モデルにクラスを追加するか、又は、新たな機械学習モデルを追加することによって、その被分類データに対応するクラスへのクラス分類を行うことが可能となる。

【0052】

なお、上記実施形態では、ベクトルニューロンを用いるベクトルニューラルネットワーク型の機械学習モデルを用いていたが、この代わりに、通常の畳み込みニューラルネットワークのようにスカラーニューロンを用いる機械学習モデルを使用してもよい。但し、ベクトルニューラルネットワーク型の機械学習モデルは、スカラーニューロンを用いる機械学習モデルに比べてクラス分類処理の精度がより高い点で好ましい。

【0053】

B. 機械学習モデルの各層の出力ベクトルの演算方法：

図 3 に示した第 1 の機械学習モデル 2 0 1 における各層の出力の演算方法は、以下の通りである。第 2 の機械学習モデル 2 0 2 も同様である。

【0054】

PrimeVN 層 2 2 1 の各ノードは、Conv 層 2 1 1 の $1 \times 1 \times 32$ 個のノードのスカラー出力を 32 次元のベクトルとみなして、このベクトルに変換行列を乗ずることによってそ

10

20

30

40

50

のノードのベクトル出力を得る。この変換行列は、 1×1 のカーネルの要素であり、機械学習モデル201の学習によって更新される。なお、Conv層211とPrimeVN層221の処理を統合して、1つのプライマリーベクトルニューロン層として構成することも可能である。

【0055】

PrimeVN層221を「下位層L」と呼び、その上位側に隣接するConvVN1層231を「上位層L+1」と呼ぶとき、上位層L+1の各ノードの出力は、以下の式を用いて決定される。

【数1】

[Math. 1]

10

$$v_{ij} = W_{ij}^L M_i^L \quad (2)$$

$$u_j = \sum_i v_{ij} \quad (3)$$

$$a_j = F(\|u_j\|) \quad (4)$$

$$M_j^{L+1} = a_j \times \frac{1}{\|u_j\|} u_j \quad (5)$$

20

ここで、

M_i^L は、下位層Lにおけるi番目のノードの出力ベクトル、

M_j^{L+1} は、上位層L+1におけるj番目のノードの出力ベクトル、

v_{ij} は、出力ベクトル M_j^{L+1} の予測ベクトル、

W_{ij}^L は、下位層Lの出力ベクトル M_i^L から予測ベクトル v_{ij} を算出するための予測行列、

u_j は、予測ベクトル v_{ij} の和、すなわち線形結合、である和ベクトル、

a_j は、和ベクトル u_j のノルム $\|u_j\|$ を正規化することによって得られる正規化係数であるアクティベーション値、

30

$F(X)$ は、Xを正規化する正規化関数である。

【0056】

正規化関数 $F(X)$ としては、例えば以下の(4a)式または(4b)式を使用できる。

【数2】

[Math.2]

$$a_j = F(\|u_j\|) = \text{softmax}(\|u_j\|) = \frac{\exp(\beta\|u_j\|)}{\sum_k \exp(\beta\|u_k\|)} \quad (4a)$$

$$a_j = F(\|u_j\|) = \frac{\|u_j\|}{\sum_k \|u_k\|} \quad (4b)$$

40

ここで、

kは、上位層L+1のすべてのノードに対する序数、

β は、任意の正の係数である調整パラメーターであり、例えば $\beta = 1$ である。

【0057】

上記(4a)式では、上位層L+1のすべてのノードに関して和ベクトル u_j のノルム $\|u_j\|$ をソフトマックス関数で正規化することによってアクティベーション値 a_j が得られる。

一方、(4b)式では、和ベクトル u_j のノルム $\|u_j\|$ を、上位層L+1のすべてのノードに

50

関するノルム $\|y\|$ の和で除算することによってアクティベーション値 a_j が得られる。なお、正規化関数 $F(X)$ としては、(4 a) 式や (4 b) 式以外の他の関数を用いてもよい。

【0058】

上記 (3) 式の序数 i は、上位層 $L+1$ における j 番目のノードの出力ベクトル M^{L+1}_j を決めるために使用される下位層 L のノードに便宜上割り振られるものであり、 $1 \sim n$ の値をとる。また、整数 n は、上位層 $L+1$ における j 番目のノードの出力ベクトル M^{L+1}_j を決めるために使用される下位層 L のノードの数である。従って、整数 n は次式で与えられる。

$$n = N_k \times N_c \quad (6)$$

ここで、 N_k はカーネルの要素数であり、 N_c は下位層である PrimeVN 層 221 のチャンネル数である。図 3 の例では $N_k = 3$ 、 $N_c = 26$ なので、 $n = 78$ である。

【0059】

ConvVN1 層 231 の出力ベクトルを求めるために使用される 1 つのカーネルは、カーネルサイズ 1×3 を表面サイズとし、下位層のチャンネル数 26 を深さとする $1 \times 3 \times 26 = 78$ 個の要素を有しており、これらの要素のそれぞれは予測行列 W^{L}_{ij} である。また、ConvVN1 層 231 の 20 個のチャンネルの出力ベクトルを生成するためには、このカーネルが 20 組必要である。従って、ConvVN1 層 231 の出力ベクトルを求めるために使用されるカーネルの予測行列 W^{L}_{ij} の数は、 $78 \times 20 = 1560$ 個である。これらの予測行列 W^{L}_{ij} は、機械学習モデル 201 の学習により更新される。

【0060】

上述した (2) ~ (5) 式から分かるように、上位層 $L+1$ の個々のノードの出力ベクトル M^{L+1}_j は、以下の演算によって求められる。

- (a) 下位層 L の各ノードの出力ベクトル M^L_i に予測行列 W^{L}_{ij} を乗じて予測ベクトル v_{ij} を求め、
- (b) 下位層 L の各ノードから得られた予測ベクトル v_{ij} の和、すなわち線形結合、である和ベクトル u_j を求め、
- (c) 和ベクトル u_j のノルム $\|u_j\|$ を正規化することによって正規化係数であるアクティベーション値 a_j を求め、
- (d) 和ベクトル u_j をノルム $\|u_j\|$ で除算し、更に、アクティベーション値 a_j を乗じる。

【0061】

なお、アクティベーション値 a_j は、上位層 $L+1$ のすべてのノードに関してノルム $\|u_j\|$ を正規化することによって得られる正規化係数である。従って、アクティベーション値 a_j は、上位層 $L+1$ 内の全ノードの中における各ノードの相対的な出力強度を示す指標と考えることができる。(4) 式、(4 a) 式、(4 b) 式、及び (5) 式で使用されるノルムは、典型的な例ではベクトル長さを表す $L2$ ノルムである。このとき、アクティベーション値 a_j は、出力ベクトル M^{L+1}_j のベクトル長さに相当する。アクティベーション値 a_j は、上述した (4) 式と (5) 式で使用されるだけなので、ノードから出力される必要は無い。但し、アクティベーション値 a_j を外部に出力するように上位層 $L+1$ を構成することも可能である。

【0062】

ベクトルニューラルネットワークの構成は、カプセルネットワークの構成とほぼ同じであり、ベクトルニューラルネットワークのベクトルニューロンがカプセルネットワークのカプセルに相当する。但し、ベクトルニューラルネットワークで使用される上述の (2) ~ (5) 式による演算は、カプセルネットワークで使用される演算と異なる。両者の最も大きな違いは、カプセルネットワークでは、上記 (3) 式の右辺の予測ベクトル v_{ij} にそれぞれ重みが乗じられており、その重みが、動的ルーティングを複数回繰り返すことによって探索される点である。一方、本実施形態のベクトルニューラルネットワークでは、上述した (2) ~ (5) 式を順番に 1 回計算することによって出力ベクトル M^{L+1}_j が得られるので、動的ルーティングを繰り返す必要が無く、演算がより高速であるという利点がある。また、本実施形態のベクトルニューラルネットワークは、カプセルネットワークより

も演算に必要とするメモリー量がカプセルネットワークより少なく、本開示の発明者の実験によれば、約 $1/2 \sim 1/3$ のメモリー量で済むという利点もある。

【0063】

ベクトルを入出力とするノードを使用するという点では、ベクトルニューラルネットワークはカプセルネットワークと同じである。従って、ベクトルニューロンを使用する利点もカプセルネットワークと共通している。また、複数の層 211 ~ 251 は、上位に行くほどより大きな領域の特徴を表現し、下位に行くほどより小さな領域の特徴を表現する、という点は、通常の畳み込みニューラルネットワークと同じである。ここで、「特徴」とは、ニューラルネットワークへの入力データに含まれている特徴的な部分を意味する。ベクトルニューラルネットワークやカプセルネットワークでは、或るノードの出力ベクトルが、そのノードが表現する特徴の空間的な情報を表す空間情報を含む点で、通常の畳み込みニューラルネットワークよりも優れている。すなわち、或るノードの出力ベクトルのベクトル長さは、そのノードが表現する特徴の存在確率を表し、ベクトル方向がその特徴の方向やスケール等の空間情報を表している。従って、同じ層に属する2つのノードの出力ベクトルのベクトル方向は、それぞれの特徴の位置関係を表す。あるいは、当該2つのノードの出力ベクトルのベクトル方向は、特徴のバリエーションを表わすとも言える。例えば、「目」の特徴に対応するノードなら、出力ベクトルの方向は、目の細さ、吊り上がり方、などのバリエーションを表し得る。通常の畳み込みニューラルネットワークでは、プーリング処理によって特徴の空間情報が消失してしまうと言われている。この結果、ベクトルニューラルネットワークやカプセルネットワークは、通常の畳み込みニューラルネットワークに比べて入力データを識別する性能に優れているという利点がある。

【0064】

ベクトルニューラルネットワークの利点は、以下のように考えることも可能である。すなわち、ベクトルニューラルネットワークでは、ノードの出力ベクトルが、入力データの特徴を連続空間内の座標として表現すること、に利点がある。従って、ベクトル方向が近ければ特徴が似ている、というように出力ベクトルを評価できる。また、入力データに含まれている特徴が教師データではカバーできていなくても、補間してその特徴を判別できる、などの利点もある。一方、通常の畳み込みニューラルネットワークは、プーリング処理によって無秩序な圧縮がかかるため、入力データの特徴を連続空間内の座標として表現できない、という欠点がある。

【0065】

ConvVN層 241 と ClassVN層 251 の各ノードの出力も、上述した(2) ~ (5)式を用いて同様に決定されるので、詳細な説明は省略する。最上位層であるClassVN層 251 の解像度は 1×1 であり、チャンネル数は $(n1 + 1)$ である。

【0066】

ClassVN層 251 の出力は、既知のクラスに対する複数の判定値Class1-1 ~ Class1-2と、未知のクラスであることを示す判定値Class1-UNとに変換される。これらの判定値は、通常はソフトマックス関数によって正規化された値である。具体的には、例えば、ClassVN層 251 の各ノードの出力ベクトルから、その出力ベクトルのベクトル長さを算出し、更に、各ノードのベクトル長さをソフトマックス関数で正規化する、という演算を実行することによって、個々のクラスに対する判定値を得ることができる。上述したように、上記(4)式で得られるアクティベーション値 a_j は、出力ベクトル M^{L+1}_j のベクトル長さに相当する値であり、正規化されている。従って、ClassVN層 251 の各ノードのそれぞれにおけるアクティベーション値 a_j を出力して、そのまま各クラスに対する判定値として使用してもよい。

【0067】

上述の実施形態では、機械学習モデル 201, 202 として、上記(2)式 ~ (5)式の演算によって出力ベクトルを求めるベクトルニューラルネットワークを用いていたが、この代わりに、米国特許第 5210798 号公報や国際公開 2019/083553 号公報に開示されているカプセルネットワークを用いてもよい。また、スカラーニューロンの

みを用いるニューラルネットワークを用いてもよい。

【0068】

・他の実施形態：

本開示は、上述した実施形態に限られるものではなく、その趣旨を逸脱しない範囲において種々の形態で実現することができる。例えば、本開示は、以下の形態（aspect）によっても実現可能である。以下に記載した各形態中の技術的特徴に対応する上記実施形態中の技術的特徴は、本開示の課題の一部又は全部を解決するために、あるいは、本開示の効果の一部又は全部を達成するために、適宜、差し替えや、組み合わせを行うことが可能である。また、その技術的特徴が本明細書中に必須なものとして説明されていなければ、適宜、削除することが可能である。

【0069】

（1）本開示の第1の形態によれば、機械学習モデルを用いて被分類データのクラス分類処理を実行する方法が提供される。この方法は、（a）Nを2以上の整数とすると、N個の機械学習モデルを準備する工程であって、前記N個の機械学習モデルのそれぞれは、入力データを複数のクラスのいずれかに分類するように構成されるとともに、前記N個の機械学習モデルのうちの他の機械学習モデルと異なる少なくとも1つのクラスを有するように構成される、工程と、（b）前記N個の機械学習モデルを用いて、前記被分類データのクラス分類処理を実行する工程と、を含む。

この方法によれば、N個の機械学習モデルを用いてクラス分類処理を実行するので、1個の機械学習モデルで多数のクラスへの分類処理を行う場合に比べて、処理を高速に実行できる。

【0070】

（2）上記方法において、任意の1個の機械学習モデルにより分類できるクラスの数には上限値が設定されており、前記工程（a）は、（a1）前記上限値に等しい数のクラスを有する第1機械学習モデルを準備する工程と、（a2）前記第1機械学習モデルを用いて前記入力データに対する前記クラス分類処理を実行したときに前記入力データが未知のクラスに属するものと判定された場合に、前記入力データに対応するクラスを有する第2機械学習モデルを追加する工程と、を含むものとしてもよい。

この方法によれば、第1機械学習モデルでは入力データのクラス分類がうまくできない場合に、第2機械学習モデルを追加することによって、その入力データに対応するクラスへのクラス分類を行うことが可能となる。

【0071】

（3）上記方法において、前記工程（a2）は、前記工程（a2）で使用された前記入力データを含む教師データを用いて、前記第2機械学習モデルの学習を実行する工程を含み、前記教師データは、更に、前記第1機械学習モデルに含まれている少なくとも1つのクラスに関する学習を行うための既存の教師データを含むものとしてもよい。

この方法によれば、新たなクラスの学習を行うための教師データに加えて、既存のクラスの学習を行うための既存の教師データも用いて第2機械学習モデルの学習を行うので、第2機械学習モデルでより正確なクラス分類を行うことが可能となる。

【0072】

（4）上記方法において、任意の1個の機械学習モデルにより分類できるクラスの数には上限値が設定されており、前記N個の機械学習モデルのうち、（N-1）個の機械学習モデルは前記上限値に等しい数のクラスを有し、他の1個の機械学習モデルは前記上限値以下の数のクラスを有し、前記工程（b）は、前記N個の機械学習モデルを用いて前記被分類データに対する前記クラス分類処理を実行したときに前記被分類データが未知のクラスに属するものと判定されたときに、（b1）前記他の1個の機械学習モデルが前記上限値未満の数のクラスを有する場合には、前記他の1個の機械学習モデルについて、前記被分類データを含む教師データを用いた学習を行うことによって前記被分類データに対する新たなクラスを追加し、（b2）前記他の1個の機械学習モデルが前記上限値に等しい数のクラスを有する場合には、前記被分類データに対応するクラスを有する新たな機械学習モ

10

20

30

40

50

デルを追加する、
工程を含むものとしてもよい。

この方法によれば、N個の機械学習モデルでは被分類データのクラス分類がうまくできない場合に、既存の機械学習モデルにクラスを追加するか、又は、新たな機械学習モデルを追加することによって、その被分類データに対応するクラスへのクラス分類を行うことが可能となる。

【0073】

(5) 上記方法において、前記工程(b2)は、前記工程(b)で使用された前記被分類データを含む教師データを用いて、前記新たな機械学習モデルの学習を実行する工程を含み、前記教師データは、更に、前記N個の機械学習モデルに含まれている少なくとも1つのクラスに関する学習を行うための既存の教師データを含むものとしてもよい。

10

この方法によれば、新たなクラスの学習を行うための教師データに加えて、既存のクラスの学習を行うための既存の教師データも用いて新たな機械学習モデルの学習を行うので、新たな機械学習モデルでより正確なクラス分類を行うことが可能となる。

【0074】

(6) 上記方法において、前記N個の機械学習モデルのそれぞれは、複数のベクトルニューロン層を有するベクトルニューラルネットワークを含み、前記方法は、更に、学習済みの前記N個の機械学習モデルに複数の教師データが入力されたときに前記複数のベクトルニューロン層のうちの少なくとも1つの特定層の出力から得られる既知特徴ベクトル群を準備する工程と、前記N個の機械学習モデルに前記被分類データが入力されたときに前記特定層の出力から得られる特徴ベクトルと、前記既知特徴ベクトル群とを用いて、前記被分類データが前記複数のクラスのいずれに類似するかを示す類似度を演算する工程と、前記N個の機械学習モデルによる前記クラス分類処理の結果が前記類似度と整合しない場合に、前記被分類データが未知のクラスに属するものと判定する工程と、を含むものとしてもよい。

20

この方法によれば、特徴ベクトルの類似度を利用して、N個の機械学習モデルによるクラス分類処理の結果が正しいか否かを確認できる。

【0075】

(7) 上記方法において、前記特定層は、第1軸と第2軸の2つの軸で規定された平面に配置されたベクトルニューロンが、前記2つの軸とは異なる方向の第3軸に沿って複数のチャンネルとして配置されている構成を有するものとしてもよい。前記特徴ベクトルは、

30

(i) 前記特定層のうちの1つの平面位置におけるベクトルニューロンの出力ベクトルの複数の要素値を、前記第3軸に沿った前記複数のチャンネルにわたって配列した第1種の特徴スペクトルと、(ii) 前記第1種の特徴スペクトルの各要素値に、前記出力ベクトルのベクトル長に相当するアクティベーション値を乗じることによって得られる第2種の特徴スペクトルと、(iii) 前記特定層のうちの1つの平面位置における前記アクティベーション値を、前記第3軸に沿った前記複数のチャンネルにわたって配列した第3種の特徴スペクトルと、のうちのいずれかであるものとしてもよい。

この方法によれば、特徴ベクトルを容易に求めることができる。

【0076】

40

(8) 本開示の第2の形態によれば、機械学習モデルを用いて被分類データのクラス分類処理を実行する情報処理装置が提供される。この情報処理装置は、Nを2以上の整数とするとき、N個の機械学習モデルを記憶するメモリと、前記N個の機械学習モデルを用いた演算を実行するプロセッサと、を備える。前記N個の機械学習モデルのそれぞれは、入力データを複数のクラスのいずれかに分類するように構成されるとともに、前記N個の機械学習モデルのうちの他の機械学習モデルと異なる少なくとも1つのクラスを有するように構成されている。前記プロセッサは、前記N個の機械学習モデルを用いて、前記被分類データのクラス分類処理を実行するように構成されている。

この情報処理装置によれば、N個の機械学習モデルを用いてクラス分類処理を実行するので、1個の機械学習モデルで多数のクラスへの分類処理を行う場合に比べて、処理を高

50

速に実行できる。

【0077】

(9) 本開示の第3の形態によれば、機械学習モデルを用いて被分類データのクラス分類処理をプロセッサに実行させるコンピュータプログラムが提供される。Nを2以上の整数とするとき、前記機械学習モデルは、N個の機械学習モデルを含み、前記N個の機械学習モデルのそれぞれは、入力データを複数のクラスのいずれかに分類するように構成されるとともに、前記N個の機械学習モデルのうちの他の機械学習モデルと異なる少なくとも1つのクラスを有するように構成されている。前記コンピュータプログラムは、前記N個の機械学習モデルを用いて、前記被分類データのクラス分類処理を実行する処理を前記プロセッサに実行させる。

10

このコンピュータプログラムによれば、N個の機械学習モデルを用いてクラス分類処理を実行するので、1個の機械学習モデルで多数のクラスへの分類処理を行う場合に比べて、処理を高速に実行できる。

【0078】

本開示は、上記以外の種々の形態で実現することも可能である。例えば、クラス分類装置の機能を実現するためのコンピュータプログラム、そのコンピュータプログラムを記録した一時的でない記録媒体(non-transitory storage medium)等の形態で実現することができる。

【符号の説明】

【0079】

20

10…プリンター、20…制御装置、30…印刷機構、40…印刷媒体ホルダー、50…分光測定器、110…プロセッサ、112…印刷制御部、114…クラス分類処理部、120…メモリー、130…インターフェイス回路、150…表示部、201, 202…機械学習モデル、211, 212…畳み込み層、221, 222…プライマリーベクトルニューロン層、231, 232…第1畳み込みベクトルニューロン層、241, 242…第2畳み込みベクトルニューロン層、251, 252…分類ベクトルニューロン層、261, 262…類似度演算部


30

40

50


【図面】
【図 1】

Fig.1




【図 2】

Fig.2




【図 3】

Fig. 3



【図 4】

Fig. 4



10

20


30

40

50


【図 5】

Fig.5



【図 6】

Fig. 6




【図 7】

Fig.7

KS1_ConvVN1				KS1_ConvVN2				KS1_ClassVN			
No.	レイヤー名	ラベルLb	既知特徴スペクトルKSp	No.	レイヤー名	ラベルLb	既知特徴スペクトルKSp	No.	レイヤー名	ラベルLb	既知特徴スペクトルKSp
1	ConvVN1	1		1	ConvVN1	1		1	ConvVN1	1	
2	ConvVN1	1		2	ConvVN1	1		2	ConvVN1	1	
...	...	...		...	...	...		...	...	...	
N1_1max	ConvVN1	1		N1_1max	ConvVN1	1		N1_1max	ConvVN1	1	
1	ConvVN1	2		1	ConvVN1	2		1	ConvVN1	2	
2	ConvVN1	2		2	ConvVN1	2		2	ConvVN1	2	
...	...	...		...	...	...		...	...	...	
N1_2max	ConvVN1	2		N1_2max	ConvVN1	2		N1_2max	ConvVN1	2	
...	...	...		...	...	...		...	...	...	
N1_n1max	ConvVN1	n1		N1_n1max	ConvVN1	n1		N1_n1max	ConvVN1	n1	

【図 8】

Fig.8



10

20


30

40

50

【図 9】

Fig.9



10

20

30

40

50

フロントページの続き

(51)国際特許分類		F I		
G 0 6 T	7/00 (2017.01)	G 0 6 T	7/00	3 5 0 C
H 0 4 N	1/00 (2006.01)	H 0 4 N	1/00	5 6 7 H
(56)参考文献		米国特許出願公開第 2 0 2 0 / 0 2 1 0 7 2 1 (U S , A 1)		
		特開 2 0 2 0 - 0 3 2 3 9 4 (J P , A)		
		米国特許出願公開第 2 0 2 0 / 0 2 8 5 9 3 4 (U S , A 1)		
		特開 2 0 1 5 - 1 7 2 5 7 0 (J P , A)		
		特開 2 0 1 9 - 0 3 9 7 7 3 (J P , A)		
		特開 2 0 2 0 - 0 6 4 2 5 3 (J P , A)		
(58)調査した分野		(Int.Cl., D B 名)		
		G 0 6 N 2 0 / 0 0		
		G 0 6 N 3 / 0 2		
		G 0 6 N 3 / 0 4		
		G 0 6 N 3 / 0 8		
		G 0 6 T 7 / 0 0		
		G 0 1 N 2 1 / 2 5		
		H 0 4 N 1 / 0 0		
		G 0 6 F 1 7 / 1 8		