

(19)日本国特許庁(JP)

(12)公開特許公報(A)

(11)公開番号
特開2023-35928
(P2023-35928A)

(43)公開日 令和5年3月13日(2023.3.13)

(51)国際特許分類

G 0 6 N 3/08 (2023.01)
G 0 6 T 5/00 (2006.01)

F I

G 0 6 N 3/08
G 0 6 T 5/00テーマコード(参考)
5 B 0 5 7

7 0 5

審査請求 未請求 請求項の数 20 O L 外国語出願 (全25頁)

(21)出願番号 特願2022-132165(P2022-132165)
 (22)出願日 令和4年8月23日(2022.8.23)
 (31)優先権主張番号 17/464,036
 (32)優先日 令和3年9月1日(2021.9.1)
 (33)優先権主張国・地域又は機関
米国(US)

(特許序注:以下のものは登録商標)
1. TENSORFLOW

(71)出願人 502161508
シナプティクス インコーポレイテッド
アメリカ合衆国, 95131 カリフォルニア州, サンノゼ, マッケイ ドライブ 1109
(74)代理人 100205350
弁理士 猪野 芳正
(74)代理人 100117617
弁理士 中尾 圭策
(72)発明者 オレイフェジ、オマール
アメリカ合衆国、95131 カリフォルニア州、サンノゼ、マッケイ ドライブ 1109
F ターム(参考) 5B057 CA01 CA08 CA12 CA16
CB01 CB08 CB12 CB16
最終頁に続く

(54)【発明の名称】一貫性損失に基づくニューラルネットワークのトレーニング

(57)【要約】(修正有)

【課題】順次に連続して表示される画像の間で一貫した外観を保持しながら一連の画像のノイズ除去を行う機械学習システム及びそのトレーニング方法を提供する。

【解決手段】機械学習システムは、該一連の入力画像の第1入力画像を、ニューラルネットワークアルゴリズムに基づいて第1出力画像にマッピングし、第1出力画像と基礎真正画像との間の差に基づいて第1ネットワーク損失を決定する。システムはまた、該一連の入力画像の第2入力画像を、該ニューラルネットワークアルゴリズムに基づいて第2出力画像にマッピングし、第2出力画像と基礎真正画像との間の差に基づいて第2ネットワーク損失を決定する。システムはさらに、第1出力画像と第2出力画像との間の差に基づいて一貫性損失を決定し、第1ネットワーク損失、第2ネットワーク損失及び一貫性損失に基づいてニューラルネットワークアルゴリズムを更新する。

【選択図】図7

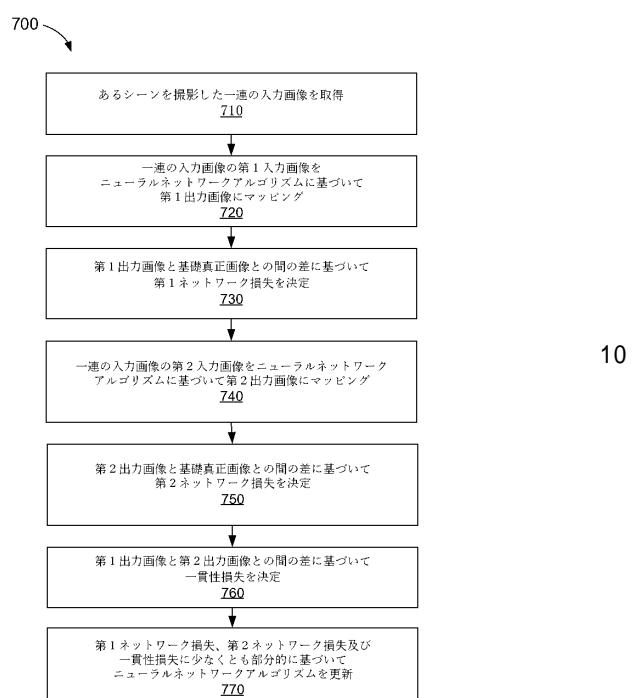


FIG. 7

【特許請求の範囲】**【請求項 1】**

ニューラルネットワークをトレーニングする方法であって、
あるシーンを撮影した一連の入力画像を取得することと、
前記一連の入力画像の第1入力画像を、ニューラルネットワークアルゴリズムに基づいて第1出力画像にマッピングすることと、
前記第1出力画像と基礎真正画像との間の差に基づいて第1ネットワーク損失を決定することと、
前記一連の入力画像の第2入力画像を、前記ニューラルネットワークアルゴリズムに基づいて第2出力画像にマッピングすることと、
前記第2出力画像と前記基礎真正画像との間の差に基づいて第2ネットワーク損失を決定することと、
前記第1出力画像と前記第2出力画像との間の差に基づいて一貫性損失を決定することと、
前記第1ネットワーク損失、前記第2ネットワーク損失及び前記一貫性損失に少なくとも部分的にに基づいて、前記ニューラルネットワークアルゴリズムを更新することと、
を含む
方法。

【請求項 2】

前記第1出力画像と前記第2出力画像のそれぞれが、複数の画素値を含み、
前記一貫性損失が、前記第1出力画像の前記複数の画素値と前記第2出力画像の前記複数の画素値に対応する平均画素値に基づいて決定される
請求項1に記載の方法。

【請求項 3】

前記第1出力画像と前記第2出力画像のそれぞれが複数の画素値を含み、
前記一貫性損失を決定することは、前記第1出力画像の前記複数の画素値と前記第2出力画像の前記複数の画素値とを含む行列を生成することを含む
請求項1に記載の方法。

【請求項 4】

前記一貫性損失が、前記行列の階数に基づいて決定される
請求項3に記載の方法。

【請求項 5】

前記基礎真正画像が前記第1入力画像と前記第2入力画像のいずれよりも高い信号対ノイズ比(SNR)を有している
請求項1に記載の方法。

【請求項 6】

前記ニューラルネットワークアルゴリズムが再帰型ニューラルネットワークアルゴリズムを備える
請求項1に記載の方法。
【請求項 7】

更に、
前記第1ネットワーク損失、前記第2ネットワーク損失及び前記一貫性損失に少なくとも部分的にに基づいて総損失を決定することを含む
請求項1に記載の方法。

【請求項 8】

更に、
前記総損失を最小化することと、
最小化された前記総損失に基づいて一以上のパラメータを決定することと、
を含み、
前記ニューラルネットワークアルゴリズムが前記一以上のパラメータに基づいて更新さ
10 20 30 40 50

れる

請求項 7 に記載の方法。

【請求項 9】

更に、

前記ニューラルネットワークアルゴリズムに基づいて前記一連の入力画像の第 3 入力画像を第 3 出力画像にマッピングすることと、

前記第 3 出力画像と前記基礎真正画像との間の差に基づいて第 3 ネットワーク損失を決定することと、

を含み、

前記ニューラルネットワークアルゴリズムが、更に、前記第 3 ネットワーク損失に基づいて更新される 10

請求項 1 に記載の方法。

【請求項 10】

前記一貫性損失が、更に、前記第 3 出力画像と前記第 2 出力画像との間の差に基づいて決定される

請求項 9 に記載の方法。

【請求項 11】

処理システムと、

命令を保存するメモリと、

を備える機械学習システムであつて、

前記命令が、前記処理システムによって実行されたときに前記機械学習システムが、あるシーンを撮影した一連の入力画像を取得し、

前記一連の入力画像の第 1 入力画像を、ニューラルネットワークアルゴリズムに基づいて第 1 出力画像にマッピングし、

前記第 1 出力画像と基礎真正画像との間の差に基づいて第 1 ネットワーク損失を決定し、

前記一連の入力画像の第 2 入力画像を、前記ニューラルネットワークアルゴリズムに基づいて第 2 出力画像にマッピングし、

前記第 2 出力画像と前記基礎真正画像との間の差に基づいて第 2 ネットワーク損失を決定し、

前記第 1 出力画像と前記第 2 出力画像との間の差に基づいて一貫性損失を決定し、

前記第 1 ネットワーク損失、前記第 2 ネットワーク損失及び前記一貫性損失に少なくとも部分的にに基づいて、前記ニューラルネットワークアルゴリズムを更新するものである機械学習システム。 30

【請求項 12】

前記第 1 出力画像と前記第 2 出力画像のそれぞれが、複数の画素値を含み、

前記一貫性損失が、前記第 1 出力画像の前記複数の画素値と前記第 2 出力画像の前記複数の画素値に対応する平均画素値に基づいて決定される

請求項 1 1 に記載の機械学習システム。

【請求項 13】

前記第 1 出力画像と前記第 2 出力画像のそれぞれが複数の画素値を含み、

前記一貫性損失を決定することは、前記第 1 出力画像の前記複数の画素値と前記第 2 出力画像の前記複数の画素値とを含む行列を生成することを含む

請求項 1 1 に記載の機械学習システム。 40

【請求項 14】

前記一貫性損失が、前記行列の階数に基づいて決定される

請求項 1 3 に記載の機械学習システム。

【請求項 15】

前記基礎真正画像が前記第 1 入力画像及び前記第 2 入力画像のいずれよりも高い解像度を有している 50

請求項 1 1 に記載の機械学習システム。

【請求項 1 6】

前記ニューラルネットワークアルゴリズムが再帰型ニューラルネットワークアルゴリズムを備える

請求項 1 1 に記載の機械学習システム。

【請求項 1 7】

ニューラルネットワークをトレーニングする方法であって、
あるシーンを撮影した一連の入力画像を取得することと、

前記一連の入力画像の第 1 入力画像を、ニューラルネットワークアルゴリズムに基づいて第 1 出力画像にマッピングすることと、

前記第 1 出力画像と第 1 基礎真正画像との間の差に基づいて第 1 ネットワーク損失を決定することと、

前記一連の入力画像の第 2 入力画像を、前記ニューラルネットワークアルゴリズムに基づいて第 2 出力画像にマッピングすることと、

前記第 2 出力画像と第 2 基礎真正画像との間の差に基づいて第 2 ネットワーク損失を決定することと、

前記第 1 出力画像と前記第 2 出力画像との間の差に基づいて一貫性損失を決定することと、

前記第 1 ネットワーク損失、前記第 2 ネットワーク損失及び前記一貫性損失に少なくとも部分的にに基づいて、前記ニューラルネットワークアルゴリズムを更新することと、
を含む

方法。

【請求項 1 8】

前記第 1 出力画像と前記第 2 出力画像のそれぞれが、複数の画素値を含み、

前記一貫性損失が、前記第 1 出力画像の前記複数の画素値と前記第 2 出力画像の前記複数の画素値に対応する平均画素値に基づいて決定される

請求項 1 7 に記載の方法。

【請求項 1 9】

前記第 1 出力画像と前記第 2 出力画像のそれぞれが複数の画素値を含み、

前記一貫性損失を決定することは、前記第 1 出力画像の前記複数の画素値と前記第 2 出力画像の前記複数の画素値とを含む行列を生成することを含む

請求項 1 7 に記載の方法。

【請求項 2 0】

前記一貫性損失が、前記行列の階数に基づいて決定される

請求項 1 9 に記載の方法。

【発明の詳細な説明】

【技術分野】

【0 0 0 1】

本実装は、一般に、ニューラルネットワークに関しており、特に、一貫性損失 (consistency loss) に基づくニューラルネットワークのトレーニングに関するもの。

【背景技術】

【0 0 0 2】

画像撮影装置がシーンの一連の画像（又は動画）を撮影するとき、各画像はノイズを発現することがある。画像が機械学習モデルによって処理され、その後、動画のように順次に提示されるとき、当該動画は、ノイズの変化のためにちらつくように見える場合がある。即ち、シーン中の物体又は光が、連続する処理後画像の間のノイズの差により、不安定であるように又はムラがあるように見えることがある。

【発明の概要】

【0 0 0 3】

本要約は、発明を実施するための形態において下記で更に説明する概念の選択を簡潔な

10

20

30

40

50

形態で紹介するために提供されている。本要約は、請求された主題の主要な特徴又は必要不可欠な特徴を特定する意図はなく、請求された主題の範囲を限定する意図もない。

【0004】

本開示の主題の革新的な態様の一つは、ニューラルネットワークをトレーニングする方法において実施可能である。当該方法は、あるシーンを撮影した一連の入力画像を取得するステップと、該一連の入力画像の第1入力画像をニューラルネットワークアルゴリズムに基づいて第1出力画像にマッピングするステップと、第1出力画像と基礎真正画像との間の差に基づいて第1ネットワーク損失を決定するステップと、該一連の入力画像の第2入力画像を該ニューラルネットワークアルゴリズムに基づいて第2出力画像にマッピングするステップと、第2出力画像と基礎真正画像との間の差に基づいて第2ネットワーク損失を決定するステップと、第1出力画像と第2出力画像との間の差に基づいて一貫性損失を決定するステップと、該第1ネットワーク損失、該第2ネットワーク損失及び該一貫性損失に少なくとも部分的に基づいて、該ニューラルネットワークアルゴリズムを更新するステップとを含んでいる。

10

【0005】

本開示の主題の他の革新的な態様は、処理システムとメモリとを備える機械学習システムにおいて実施可能である。該メモリは、処理システムによって実行されたときに、機械学習システムが、あるシーンを撮影した一連の入力画像を取得し、該一連の入力画像の第1入力画像をニューラルネットワークアルゴリズムに基づいて第1出力画像にマッピングし、第1出力画像と基礎真正画像との間の差に基づいて第1ネットワーク損失を決定し、該一連の入力画像の第2入力画像を該ニューラルネットワークアルゴリズムに基づいて第2出力画像にマッピングし、第1出力画像と基礎真正画像との間の差に基づいて第2ネットワーク損失を決定し、第1出力画像と第2出力画像との間の差に基づいて一貫性損失を決定し、該第1ネットワーク損失、該第2ネットワーク損失及び該一貫性損失に少なくとも部分的に基づいて、該ニューラルネットワークアルゴリズムを更新するような命令を保存している。

20

【0006】

本開示の主題の他の革新的な態様は、ニューラルネットワークをトレーニングする方法において実施可能である。当該方法は、あるシーンを撮影した一連の入力画像を取得することと、該一連の入力画像の第1入力画像をニューラルネットワークアルゴリズムに基づいて第1出力画像にマッピングするステップと、第1出力画像と第1基礎真正画像との間の差に基づいて第1ネットワーク損失を決定するステップと、該一連の入力画像の第2入力画像を該ニューラルネットワークアルゴリズムに基づいて第2出力画像にマッピングするステップと、第2出力画像と第2基礎真正画像との間の差に基づいて第2ネットワーク損失を決定するステップと、第1出力画像と第2出力画像との間の差に基づいて一貫性損失を決定するステップと、該第1ネットワーク損失、該第2ネットワーク損失及び該一貫性損失に少なくとも部分的に基づいて、該ニューラルネットワークアルゴリズムを更新するステップとを含んでいる。

30

【図面の簡単な説明】

【0007】

本実施形態は、例として図示されたものであり、添付図面の図によって限定される意図はない。

40

【0008】

【図1】図1は、いくつかの実装による、ニューラルネットワークモデルを用いることがある例示的な画像撮影及び表示システムのブロック図を図示している。

【0009】

【図2】図2は、いくつかの実装による、ニューラルネットワークモデルを用いる画像プロセッサの例示的な動作のブロック図を図示している。

【0010】

【図3】図3は、いくつかの実装による、例示的な機械学習システムのブロック図を図示

50

している。

【0011】

【図4】図4は、いくつかの実装による、例示的な損失算出器のブロック図を図示している。

【0012】

【図5】図5は、ピラミッド損失に関連する例示的なピラミッドレベルを示す例示的なチャートを図示している。

【0013】

【図6】図6は、いくつかの実装による、例示的な機械学習システムを図示している。

【0014】

【図7】図7は、いくつかの実装による、ニューラルネットワークをトレーニングするための例示的な動作を示す例示的なフローチャートを図示している。

【0015】

【図8】図8は、いくつかの実装による、ニューラルネットワークをトレーニングするための例示的な動作を示す例示的なフローチャートを図示している。

【発明を実施するための形態】

【0016】

以下の説明には、本開示の深い理解を提供するために、具体的なコンポーネント、回路及び処理の例のような数多くの具体的な詳細が提示されている。本明細書において使用される「結合されている」という用語は、直接に接続されているか、又は、一以上の介在するコンポーネント又は回路を介して接続されていることを意味している。「電子システム」及び「電子デバイス」という用語は、互換的に使用されており、電子的に情報を処理する能力を有する任意のシステムをいうことがある。また、以下の説明において説明の目的で、本開示の態様の深い理解を提供するために特定の用語体系が提示されている。しかしながら、これらの具体的な詳細が例示的な実施形態を実施するために必要でないかもしれないということは、当業者には明らかであろう。他の事例としては、本開示を不明確にすることを避けるために、周知の回路及び装置は、ブロック図の形態で示されている。以下の詳細な説明のいくつかの部分は、手順、論理ブロック、処理、及び、コンピュータメモリ内のデータビットに対する演算の他の象徴的な表現という形態で提示されている。

【0017】

これらの説明及び表現は、データ処理の技術における当業者の成果物の内容を最も効率的に他の当業者に伝搬するために当該当業者によって使用される手段である。本開示において、手順、論理ブロック、処理等は、所望の結果に導く自己整合的な一連の工程又は命令であるように考え出されたものである。当該工程は、物理量の物理的な操作を必要とするものである。必須ではないものの、通常、これらの量は、コンピュータシステムにおいて保存され、転送され、組み合わされ、比較され、そして、その他の処理がなされ得る電気的又は磁気的な信号の形態をとる。しかしながら、これらの及び類似の用語のすべては、適切な物理量に対応付けられるべきであり、単に、これらの量に適用される便利なラベルに過ぎないことに留意すべきである。

【0018】

下記の議論から明確であるように、特に別段の記載がない限り、本出願を通じ、「アクセスする」、「受け取る」、「送る」、「用いる」、「選択する」、「決定する」、「正規化する」、「乗算する」、「平均化する」、「監視する」、「比較する」、「適用する」、「更新する」、「測定する」、「導き出す」のような用語を用いた議論は、コンピュータシステムのレジスタ及びメモリ内で物理（電子的）量として表現されているデータを処理し、コンピュータシステムのメモリ又はレジスタや、他のそのような情報ストレージ、伝送又は表示装置内で物理量として同様に表現されている他のデータに変換するコンピュータシステム又は類似の電子的コンピューティングデバイスの動作及び処理を参照していると理解される。

【0019】

10

20

30

40

50

図において、単一のブロックは、一の機能又は複数の機能を実行すると記載されることがある。しかしながら、実際の実施においては、そのブロックによって実行される該一の機能又は複数の機能は、単一のコンポーネントにおいて実行されることがあり、また、複数のコンポーネントに渡って実行されることがある。及び／又は、そのブロックによって実行される該一の機能又は複数の機能は、ハードウェアを用いて、ソフトウェアを用いて、又は、ハードウェアとソフトウェアの組み合わせを用いて実行されることがある。このハードウェアとソフトウェアの互換性を明確に図示するために、様々な例示的なコンポーネント、ブロック、モジュール、回路及び工程は、以下において、一般的に、その機能という観点で記載されている。そのような機能がハードウェア又はソフトウェアのいずれとして実装されるかは、具体的な用途とシステム全体に課せられた設計制約に依存している。当業者は、説明された機能を、各個別の用途のために様々な方法で実装し得るが、このような実装上の決定が、本発明の技術的範囲からの乖離を生じさせるとして解釈すべきではない。また、例示的な入力装置は、プロセッサ、メモリ等の周知のコンポーネントを含む、図示されているもの以外のコンポーネントを含み得る。

10

【0020】

本明細書に記載されている技術は、特定の方法で実装されると具体的に記載されていない限り、ハードウェア、ソフトウェア、ファームウェア又はそれらの任意の組み合わせで実装され得る。モジュール又はコンポーネントとして記載されている如何なる構成も、集積化された論理デバイスに纏めて実装されてもよいし、個別でありながら、協働可能な論理デバイスとして分離して実装されてもよい。ソフトウェアにおいて実装される場合、当該技術は、実行されたときに上述された一以上の方法を実行する命令を含む非一時的プロセッサ読み取り可能記録媒体によって少なくとも部分的に実現されてもよい。非一時的プロセッサ読み取り可能データ記録媒体は、梱包材を含むことがある、コンピュータプログラム製品の一部を構成することがある。

20

【0021】

該非一時的プロセッサ読み取り可能記録媒体は、シンクロナスダイナミックランダムメモリ（SDRAM）のようなランダムアクセスメモリ（RAM）、リードオンリーメモリ（ROM）、不揮発性ランダムアクセスメモリ（NVRAM）、電気的消去可能プログラム可能リードオンリーメモリ（EEPROM）、フラッシュメモリ、及び、他の公知の記録媒体等を備えていてもよい。当該技術は、加えて、又は、それに代えて、命令又はデータ構造の形態でコードを伝送又は通信し、コンピュータ又は他のプロセッサによってアクセス、読み取り及び／又は実行可能なプロセッサ読み取り可能通信媒体によって少なくとも部分的に実現されてもよい。

30

【0022】

本明細書に開示されている実施形態に関連して説明されている様々な例示的な論理ブロック、モジュール、回路及び命令は、一以上のプロセッサ（又は処理システム）によって実行され得る。本明細書で使用されている「プロセッサ」という用語は、メモリに記憶された一以上のソフトウェアプログラムのスクリプト又は命令を実行可能な任意の汎用プロセッサ、特殊目的プロセッサ、従来のプロセッサ、コントローラ、マイクロコントローラ及び／又はステートマシンをいうことがある。

40

【0023】

本開示の態様は、（例えば、動画として）順次に表示される画像の間のフリッカを低減しながら、画像のノイズ除去を行うためのシステム及び方法を提供する。いくつかの実施形態では、ニューラルネットワーク（例えば、再帰型ニューラルネットワーク）は、シーンの一連の画像（「バッチ」ともいう）のノイズ除去された表現を推論するようにトレーニングされることがある。より具体的には、ニューラルネットワーク（「ニューラルネットワークアルゴリズム」又は「ニューラルネットワークモデル」ともいう）は、順次に連続して表示される画像間で一貫性がある外観を維持しながら各画像におけるノイズを低減するようにトレーニングされ得る。

【0024】

50

トレーニングの間、機械学習システムは、あるシーンを撮影した一連の入力画像を取得することがある。機械学習システムは、また、一以上の基礎真正画像も取得することがある。基礎真正画像とは、ノイズを少ししか含まない、又は、ノイズがない当該シーンの参照画像である。いくつかの実施形態では、基礎真正画像は、当該一連の入力画像の任意のものよりも信号対ノイズ比（S/NR）が高い任意の画像であってもよい。いくつかの他の実施形態では、基礎真正画像は、当該一連の入力画像の任意のものよりも解像度（例えば、画素解像度）が高い任意の画像であってもよい。更に、いくつかの実施形態では、該機械学習システムは、該一連の入力画像の第1入力画像を、ニューラルネットワークアルゴリズムに基づいて第1出力画像にマッピングすることがある。該機械学習システムは、また、第1出力画像と基礎真正画像との間の差に基づいて第1ネットワーク損失を決定することがある。該機械学習システムは、更に、該一連の入力画像の第2入力画像を、該ニューラルネットワークアルゴリズムに基づいて第2出力画像にマッピングし、第2出力画像と基礎真正画像との間の差に基づいて第2ネットワーク損失を決定することがある。第1ネットワーク損失及び第2ネットワーク損失のそれぞれは、それぞれ、第1出力画像及び第2出力画像と、基礎真正画像との間の差を表していることがある。例えば、このような差は、各出力画像における誤差又はノイズの量を反映していることがある。機械学習システムは、更に、第1出力画像と第2出力画像との間の差に基づいて一貫性損失を決定することがある。従って、一貫性損失は、第1出力画像と第2出力画像との差を表すことがある。例えば、このような差は、一連の、順次の又は連続した画像に渡る、ノイズ又は外観の変化量を反映していることがある。

10

20

30

40

50

【0025】

いくつかの実施形態では、機械学習システムが、例えばトレーニング処理の各イテレーションの終了時に、第1ネットワーク損失、第2ネットワーク損失及び一貫性損失に少なくとも部分的にに基づいてニューラルネットワークアルゴリズムを更新することがある。いくつかの態様では、機械学習システムは、ある収束基準が満たされるまでトレーニング処理を繰り返してもよい。いくつかの実施形態では、トレーニングされたニューラルネットワークモデルが、例えば、画像撮影及び表示システムに展開され、画像のノイズ除去された表現をリアルタイムで推論するために使用されてもよい。一貫性損失に基づいてニューラルネットワークをトレーニングすることにより、ニューラルネットワークモデルは、順次に表示される画像におけるノイズの変化を最小化し得る。従って、例えば動画においてノイズ除去された画像が順次に表示されたときに、動画は、フリッカが最小化され、又は、フリッカが無くなつてスムーズかつ一貫しているように見える。

【0026】

図1は、いくつかの実装による、ニューラルネットワークモデルを使用することがある例示的な画像撮影及び表示システム100のブロック図を図示している。システム100は、画像撮影装置110と画像プロセッサ120と表示装置130とを備えている。画像撮影装置110（例えば、カメラ）は、シーンからの光101（「シーン光101」ともいう）の一連のパターンを撮影し、シーン光110をデジタル画像撮影データ102（「画像撮影データ102」ともいう）に変換する。画像撮影データ102は、該一連の光の各パターンについて、シーンのデジタル画像を表す画素のアレイ（又は画素値）を含んでいることがある。表示装置130（例えば、テレビ、コンピュータモニタ、スマートフォン又は電子ディスプレイを含む任意の他のデバイス）は、該一連の光パターンを関連する画面表面に再生することにより、デジタル画像をレンダリング又は表示する。

【0027】

画像プロセッサ120は、画像撮影データ102を、表示装置130に表示されたときに少しのフリッカしかない又はフリッカがない動画として画像撮影装置110によって撮影された元のシーンを反映していることがある画像レンダリングデータ103に変換する。例えば、画像プロセッサ120は、画像撮影データ102に関連する様々な画素歪みを補正し、スムージングするように構成されることがある。言い換えれば、画像プロセッサ120は、デジタル画像に関連するノイズの変化を低減し、最小化するように構成される

ことがある。図1では独立したブロックとして示されているが、実際の実装では、画像プロセッサ120は、画像撮影装置110、表示装置130又はこれらの組み合わせに組み込まれ、そうでなければ含まれていてもよい。

【0028】

いくつかの実施形態では、画像プロセッサ120は、機械学習によってトレーニングされたニューラルネットワークモデル123に基づいて画像撮影データ102のノイズ除去された表現（例えば、画像レンダリングデータ103）を生成することがある。機械学習は、あるタスクを実行するためのコンピュータシステム又はアプリケーションの能力を向上するための技術である。トレーニング段階では、機械学習システムは、複数の「解答」と各解答にマッピングされるべき一以上のセットの生データとが与えられることがある。例えば、機械学習システムは、（生データを表す）あるシーンを低照度条件で撮影した一連の短露光画像と、（解答を表す）少しのノイズしか含まない又はノイズがない同じシーンの一以上の典型画像（又は基礎真正画像）とを該システムに提供することにより、一連の低照度画像に対してノイズ除去演算を行うようにトレーニングされることがある。機械学習システムは、その後、生データを解析して解答を再生するために使用可能な一組のルールを「学習」することがある。例えば、機械学習システムは、生データに対して統計分析を行って、生データに関連するノイズ又はノイズの変化に関連する共通の特徴の組（「ルール」とも呼ばれる）を決定することがある。

【0029】

いくつかの態様では、機械学習システムは、ディープラーニングを使用することがある。ディープラーニングとは、トレーニングされるモデルが多層ニューラルネットワークである機械学習の特定の形態である。ディープラーニングアーキテクチャは、（生物の神経システムに類似した）情報を処理する方法のために、しばしば、人工ニューラルネットワークと呼ばれることがある。例えば、ディープラーニングアーキテクチャの各層は、多数の人工ニューロンを備えることがある。ニューロンは、入力データ（又は生データ）が一の層から他の層に渡され得るように様々な層に渡って内部接続されている。より具体的には、ニューロンの各層は、究極的には所望の出力を生成する、異なる種類の変換を入力データに対して行うことがある。ニューロンの内部接続された構造は、ニューラルネットワークモデルと呼ばれることがある。従って、ニューラルネットワークモデル123は、画像撮影データ102のノイズ除去した表現を「推論」するために使用可能な一組のルールを含んでいることがある。その結果、画像プロセッサ120は、ニューラルネットワークモデル123を用いて画像撮影データ102に関連するノイズの変化を低減し、最小化することがある。

【0030】

図2は、いくつかの実装による、ニューラルネットワークモデルを使用する画像プロセッサの例示的な動作200のブロック図を図示している。画像プロセッサ220は、図1の画像プロセッサ120の実施形態であり得る。従って、画像プロセッサ220は、画像202を受け取り、ノイズ除去後画像203を出力するように構成されることがある。図1を参照して、画像202は、画像撮影データ102の一例である場合があり、ノイズ除去後画像203は、画像レンダリングデータ103の一例である場合がある。

【0031】

いくつかの実施形態では、画像プロセッサ220が、ニューラルプロセッサ221とニューラルネットワークモデル223とを備えることがある。ニューラルプロセッサ221は、ニューラルネットワーク推論を加速するように構成された一以上のプロセッサを備えていてもよい。例えば、ニューラルプロセッサ221のハードウェアアーキテクチャは、汎用プロセッサよりも高速又は効率的にニューラルネットワークを横断するように設計されてもよい。ニューラルプロセッサ221は、ニューラルネットワークモデル223に基づいてニューラルネットワークを実施してもよい。いくつかの実施形態では、ニューラルネットワークモデル223は、図1のニューラルネットワークモデル123の一例であってもよい。従って、ニューラルネットワークモデル223は、撮影画像のノイズ除去後の

10

20

30

40

50

表現を推論するために使用可能な一組のルールを備える場合がある。

【 0 0 3 2 】

図 2 に図示されているように、画像 2 0 2 は、ノイズが多く、又は、粒子が粗いように見える。例えば、画像 2 0 2 における画素の分布は、輝度及び色における「スパイク」(例えば、シーンの明るい領域における暗い画素やシーンの暗い領域における明るい画素)を含んでいる。一方、ノイズ除去後画像 2 0 3 の画素の色及び輝度は、実質的に滑らかな分布に従っている。例えば、ノイズ除去後画像 2 0 3 ではシーンの暗い領域は暗く見え、シーンの明るい領域は明るく見える。図 2 は、画像プロセッサ 2 2 0 で処理される単一のノイズが多い画像 2 0 2 しか図示していないが、実際の実装では、一連のノイズが多い画像(又は動画)が画像プロセッサ 2 2 0 によって処理されることがある。更に、画像プロセッサ 2 2 0 は、表示スクリーンに表示されたときに滑らかな又は安定した動画として見える一連のノイズ除去後画像を出力するためにニューラルプロセッサ 2 2 1 とニューラルネットワークモデル 2 2 3 とを用いることがある。

【 0 0 3 3 】

一連のノイズ除去後画像を生成するために、ニューラルネットワークモデル 2 2 3 が画像プロセッサ 2 2 0 に組み込まれる前にトレーニングされてもよい。より具体的には、ニューラルネットワークモデル 2 2 3 は、機械学習システムにより、シーンを撮影した一連のノイズが多い入力画像のノイズを除去した表現を推論するようにトレーニングされることがある。いくつかの実施形態では、トレーニングは、一連の入力画像の第 1 入力画像を、ニューラルネットワークアルゴリズムを用いて第 1 出力画像にマッピングすることと、第 1 出力画像と基礎真正画像との間の差に基づいて第 1 ネットワーク損失を決定することとを含むことがある。第 1 ネットワーク損失は、基礎真正画像を基準とした第 1 出力画像におけるノイズの量を表すことがある。いくつかの実施形態では、トレーニングは、更に、該一連の入力画像の第 2 入力画像を、該ニューラルネットワークアルゴリズムを用いて第 2 出力画像にマッピングすることと、第 2 出力画像と基礎真正画像との間の差に基づいて第 2 ネットワーク損失を決定することとを含むことがある。第 2 ネットワーク損失は、基礎真正画像を基準とした第 2 出力画像におけるノイズの量を表すことがある。

【 0 0 3 4 】

いくつかの実施形態では、一貫性損失を決定するために第 1 出力画像が第 2 出力画像と比較されることがある。一貫性損失は、第 1 出力画像と第 2 出力画像との間の差を表すことがある。例えば、このような差は、第 1 出力画像と第 2 出力画像とに渡るノイズ又は外観における変化量を反映していることがある。いくつかの実施形態では、第 1 ネットワーク損失と第 2 ネットワーク損失と一貫性損失とが、ニューラルネットワークアルゴリズムの重みを更新するために使用されることがある。更に、いくつかの実施形態では、機械学習システムは、ある収束基準が満たされるまで、上述されたトレーニング処理を繰り返すことがある。

【 0 0 3 5 】

第 1 ネットワーク損失及び第 2 ネットワーク損失に基づいてニューラルネットワークアルゴリズムを更新することにより、ニューラルネットワークアルゴリズムは、一連の出力画像におけるノイズを低減するように構成されることがある。更に、一貫性損失に基づいてニューラルネットワークアルゴリズムを更新することにより、ニューラルネットワークアルゴリズムは、出力画像が動画として表示されるときに、フリッカが少ない又はフリッカがない滑らかな又は安定した動画として見えるように、一連の出力画像の間のノイズの変化量を低減するように構成されることがある。

【 0 0 3 6 】

図 3 は、いくつかの実装による例示的な機械学習システム 3 0 0 のブロック図を図示している。機械学習システム 3 0 0 は、ニューラルネットワーク 3 2 2 と損失算出器 3 2 6 とネットワーク最適化器 3 2 8 とを備えている。いくつかの態様では、機械学習システム 3 0 0 は、ニューラルネットワーク 3 2 2 をトレーニングしてニューラルネットワークモデル 3 2 3 を生成するために使用される。ニューラルネットワークモデル 3 2 3 は、それ

10

20

30

40

50

それ図 1 及び図 2 のニューラルネットワークモデル 1 2 3 及び / 又は 2 2 3 の実施形態であり得る。

【 0 0 3 7 】

図 3 に図示されているように、機械学習システム 3 0 0 は、一連の入力画像 3 0 2 (「入力画像 3 0 2」ともいう) と一以上の基礎真正画像 3 2 5 を取得することがある。いくつかの実施形態では、各入力画像 3 0 2 の S N R は、該一以上の基礎真正画像 3 2 5 の S N R よりも低いことがある。例えば、いくつかの実施形態では、入力画像 3 0 2 のそれぞれは、低照度条件での、あるシーンのノイズが多く露光が短い画像を表していることがあり、一以上の基礎真正画像 3 2 5 のそれぞれは、ノイズが少ない又はノイズがない、該低照度条件での該シーンの露光が長い画像を表していることがある。更に、いくつかの実施形態では、各入力画像 3 0 2 の解像度(例えば、画素解像度)は、該一以上の基礎真正画像 3 2 5 の解像度よりも低いことがある。このような実施形態では、機械学習システム 3 0 0 は、一以上の基礎真正画像 3 2 5 を用いて入力画像 3 0 2 のそれぞれをアップスケールする(又は、超解像処理を実施する)ことがある。

10

【 0 0 3 8 】

いくつかの実施形態では、入力画像 3 0 2 のそれぞれと一以上の基礎真正画像 3 2 5 のそれぞれは、個別の輝度レベルを有していることがある。例えば、ある画像の輝度レベルは、画像に描写されたシーンの照明(又は照度)、画像の露光、及び / 又は、画像の撮影に用いられる画像撮影装置のフォトセンサーの利得(又は感度)を反映していることがある。いくつかの実施形態では、入力画像 3 0 2 のそれぞれが、各入力画像 3 0 2 の輝度レベルが基礎真正画像 3 2 5 の輝度レベルと同じであり得るように前処理されてもよい。

20

【 0 0 3 9 】

図 3 に図示されているように、ニューラルネットワーク 3 2 2 は、各入力画像 3 0 2 を受け取り、受け取った入力画像 3 0 2 に基づいて個別の出力画像 3 0 3 を生成するように構成されることがある。より具体的には、ニューラルネットワーク 3 2 2 は、一以上の基礎真正画像 3 2 5 を再生成しようとすることにより、入力画像 3 0 2 のノイズ除去後の表現を生成することができる。いくつかの実施形態では、ニューラルネットワーク 3 2 2 は、一連の入力画像 3 0 2 におけるノイズの時間的動態を学習するように構成された再帰型ニューラルネットワークであってもよい。いくつかの態様では、ニューラルネットワーク 3 2 2 は、一連の入力画像 3 0 2 で始まりノイズ除去された一連の出力画像 3 0 3 をもたらす人工ニューロンの複数の層に渡る重み付け接続のネットワークを構成することができる。いくつかの実施形態では、ニューラルネットワーク 3 2 2 は、ノイズ除去された一連の出力画像 3 0 3 の各画像を損失算出器 3 2 6 に供給するように構成されることがある。

30

【 0 0 4 0 】

図 3 に図示されているように、損失算出器 3 2 6 は、ノイズ除去された一連の出力画像 3 0 3 をニューラルネットワーク 3 2 2 から受け取るように構成されることがある。損失算出器 3 2 6 は、また、一以上の基礎真正画像 3 2 5 を受け取るように構成されることがある。いくつかの態様では、損失算出器 3 2 6 が、一以上の基礎真正画像 3 2 5 を基準とした一連の出力画像 3 0 3 の各画像におけるネットワーク損失(又は、誤差又はノイズ)の量を決定するように構成されることがある。例えば、第 1 ネットワーク損失を決定するために、損失算出器 3 2 6 は、第 1 出力画像 3 0 3 を基礎真正画像 3 2 5 と比較することができる。また、第 2 ネットワーク損失を決定するために、損失算出器 3 2 6 は、第 2 出力画像 3 0 3 を基礎真正画像 3 2 5 と比較することができる。また、損失算出器 3 2 6 は、一連の出力画像 3 0 3 の残りの任意の出力画像のそれぞれを基礎真正画像 3 2 5 と比較することにより、追加のネットワーク損失を決定するようにも構成されてもよい。

40

【 0 0 4 1 】

いくつかの態様では、損失算出器 3 2 6 が一連の出力画像 3 0 3 の間の一貫性損失(又はノイズの変化量)を決定するようにも構成されることがある。例えば、一貫性損失を決定するために、損失算出器 3 2 6 が第 1 出力画像 3 0 3 を第 2 出力画像 3 0 3 と比較することができる。ここで、第 1 出力画像 3 0 3 と第 2 出力画像 3 0 3 とは、一連の出力画像 3

50

0 3において連続する画像である。いくつかの実施形態では、損失算出器 3 2 6 が、更に、一連の出力画像 3 0 3 の残りの任意の連続する画像に基づいて一貫性損失を決定するように構成されてもよい。いくつかの態様では、損失算出器 3 2 6 が、一貫性損失と第 1 ネットワーク損失と第 2 ネットワーク損失と任意の追加のネットワーク損失とを組み合わせて総損失 3 0 5 を決定するように構成されることがある。損失算出器 3 2 6 は、更に、総損失 3 0 5 をネットワーク最適化器 3 2 8 に出力するように構成されることがある。

【 0 0 4 2 】

いくつかの態様では、ネットワーク最適化器 3 2 8 が、総損失 3 0 5 を受け取り、総損失 3 0 5 に基づいてニューラルネットワーク 3 2 2 の一以上の重み（「パラメータ」ともいう）3 0 7 を調整するように構成されることがある。より具体的には、ネットワーク最適化器 3 2 8 が、総損失 3 0 5 を低減する態様で重み 3 0 7 を調整することがある。機械学習システム 3 0 0 は、ある収束基準が満たされるまで、一以上のイテレーションに渡って上述のトレーニング処理を繰り返すことがある。例えば、ノイズがある新しい一連の画像がニューラルネットワーク 3 2 2 に入力として提供されることがあり、損失算出器 3 2 6 がニューラルネットワーク 3 2 2 の出力に基づいて総損失 3 0 5 を決定することがあり、そして、ネットワーク最適化器 3 2 8 が、更に、総損失 3 0 5 に基づいて重み 3 0 7 を更新することがある。

【 0 0 4 3 】

図 4 は、いくつかの実装による例示的な損失算出器 4 0 0 のブロック図を図示している。損失算出器 4 0 0 は、図 3 の損失算出器 3 2 6 の実施形態であり得る。図 4 に図示されているように、損失算出器 4 0 0 は、ネットワーク損失算出器 4 3 2 と、一貫性損失算出器 4 3 4 と、総損失算出器 4 3 6 とを備えている。

【 0 0 4 4 】

ネットワーク損失算出器 4 3 2 は、一連の出力画像 4 0 3 （「出力画像 4 0 3 」ともいう）の各画像を、ニューラルネットワーク、例えば、図 3 のニューラルネットワーク 3 2 2 から受け取るように構成されることがある。ネットワーク損失算出器 4 3 2 は、また、一以上の基礎真正画像 4 2 5 を受け取るように構成されることがある。

【 0 0 4 5 】

いくつかの態様では、一連の出力画像 4 0 3 は、次の 4 つの次元：(i) バッチサイズ N 、(i i) 高さ H 、(i i i) 幅 W 、及び、(i v) チャンネル C で特徴付けられることがある。バッチサイズ N は、一連の出力画像 4 0 3 における画像の総数を表すことがある。高さ H は、一連の出力画像 4 0 3 の各画像の高さを画素で表すことがある。幅 W は、一連の出力画像 4 0 3 の各画像の幅を画素で表すことがある。チャネル C は、一連の出力画像 4 0 3 の各画像における、各画素の色（例えば、赤、緑、青、及び / 又は不透過率）又は各画素の値を表すことがある。いくつかの実施形態では、チャネル C は、一以上の数値によって表されることがある。なお、一連の出力画像 4 0 3 と同様に、一以上の基礎真正画像 4 2 5 及び一連の入力画像（例えば、図 3 の一連の入力画像 3 0 2 ）も、4 つの次元 N 、 H 、 W 及び C で特徴付けられることがある。

【 0 0 4 6 】

いくつかの態様では、ネットワーク損失算出器 4 3 2 が、総ネットワーク損失 4 3 3 （「ネットワーク損失 4 3 3 」ともいう）を決定するように構成されることがある。ここで、総ネットワーク損失 4 3 3 は、一以上の基礎真正画像 4 2 5 を基準とした一連の出力画像 4 0 3 における誤差又はノイズの量を表すことがある。ネットワーク損失算出器 4 3 2 は、一連の出力画像 4 0 3 の各画像の画素値と一以上の基礎真正画像 4 2 5 の画素値との差に基づいてネットワーク損失 4 3 3 を決定することができる。例えば、いくつかの実施形態では、ネットワーク損失算出器 4 3 2 が、第 1 出力画像 4 0 3 の画素値を基礎真正画像 4 2 5 の画素値と比較することにより第 1 ネットワーク損失を決定することができる。ネットワーク損失算出器 4 3 2 は、また、第 2 出力画像 4 0 3 の画素値を基礎真正画像 4 2 5 の画素値と比較することにより第 2 ネットワーク損失を決定することができる。第 1 及び第 2 出力画像 4 0 3 が一連の出力画像 4 0 3 の各画像を表している場合には、ネットワー-

10

20

30

40

50

ク損失算出器 4 3 2 は、第 1 ネットワーク損失と第 2 ネットワーク損失とを組み合わせて総ネットワーク損失 4 3 3 を生成することがある。

【 0 0 4 7 】

いくつかの実施形態では、ネットワーク損失算出器 4 3 2 は、一以上のピラミッド損失に基づいてネットワーク損失 4 3 3 を決定するように構成されることがある。ピラミッド損失は、様々なピラミッドレベル（又はスケール）における基礎真正画像 4 2 5 の画素値を基準とした出力画像 4 0 3 の画素値における誤差の総量を表すことがある。ピラミッドレベル（又はスケール）は、例えば出力画像 4 0 3 又は基礎真正画像 4 2 5 のような画像の画素粒度をいうことがある。例えば、より高いピラミッドレベルは、より粗い画素粒度又はより少数の画素値に対応付けられることがある。そのため、画像が、より低いピラミッドレベルの同じ画像と比較して、「ズームアウト」されて見える（よって詳細を少ししか示さない）ことがある。いくつかの実施形態では、ネットワーク損失 4 3 3 が、少なくとも一の出力画像 4 0 3 についてのピラミッド損失を含むことがある。更に、いくつかの実施形態では、ネットワーク損失 4 3 3 が一連の出力画像 4 0 3 の各画像についてのピラミッド損失を含むことがある。

10

【 0 0 4 8 】

一貫性損失算出器 4 3 4 は、ネットワーク損失算出器 4 3 2 と同様に、一連の出力画像 4 0 3 の各画像を受け取るように構成されることがある。いくつかの態様では、一貫性損失算出器 4 3 4 は、一貫性損失 4 3 5 を決定するように構成されることがある。ここで、一貫性損失 4 3 5 は、一連の出力画像 4 0 3 の 2 以上の連続する画像間のノイズの変化量を表すことがある。別の言い方をすれば、一貫性損失 4 3 5 は、一連の出力画像 4 0 3 の 2 以上の連続する画像間の不一致性の大きさ又は程度を表すことがある。いくつかの態様では、一貫性損失 4 3 5 は、標準偏差に基づいていることがあり、下記のように表されることがある：

20

【 数 1 】

$$\text{一貫性損失} = \sum_{n=0}^N \sum_{h=0}^H \sum_{w=0}^W \sum_{c=0}^C (p_{cwhn} - m_{cwh})^2 \quad (\text{式 1A})$$

30

【 0 0 4 9 】

式 1 Aにおいて、N、H、W 及び C は、一連の出力画像 4 0 3 の 4 つの次元を表しており、n、h、w 及び c は、それぞれ、次元 N、H、W 及び C に対応するインデックスである。 p_{cwhn} は、チャネル c、幅 w、高さ h 及びバッチインデックス（「画像インデックス」ともいう）n における画素値を表している。 m_{cwh} は、チャネル c、幅 w 及び高さ h に位置する画素の、バッチ次元に渡って（例えば、画像インデックス n = 0 から n = N まで）算出された平均値を表している。更に、 m_{cwh} は、下記のように表現され得る：

40

【 数 2 】

$$m_{cwh} = \frac{\sum_{n=0}^N p_{cwhn}}{N} \quad (\text{式 1B})$$

【 0 0 5 0 】

上述の式 1 A 及び式 1 B は、機械学習システム（例えば、図 3 の機械学習システム 3 0 0）がトレーニング処理の複数のイテレーションを経ているときに一連の出力画像 4 0 3（又は対応する一連の入力画像）のバッチサイズ N が一定のままであるときに、使用に適していることに留意されたい。

【 0 0 5 1 】

50

いくつかの他の実施形態では、一貫性損失 4 3 5 が、一連の出力画像 4 0 3 に基づく行列（B）（「行列 B」ともいう）の階数を表すことがある。より具体的には、行列 B は、一連のベクトルを含んでいることがある。ここで、各ベクトルは一連の出力画像 4 0 3 の画像に対応している。更に、各ベクトルは、一連の出力画像 4 0 3 の所与の画像について次元 H、W 及び C のそれぞれを表す单一の次元に平坦化又は縮小されることがある。いくつかの態様では、行列 B は、下記のように表され得る：

【数 3】

$$\text{行列 } B = [\text{vec}(\text{出力画像}_1), \text{vec}(\text{出力画像}_2), \dots, \text{vec}(\text{出力画像}_N)]$$

10

行列 B は、2 次元であり、一方の次元は H、W 及び C を含んでおり、他方の次元は N を含んでいる。本開示の態様は、行列 B の階数が行列 B において線形独立な出力画像 4 0 3 の最大数を表しており、行列 B の階数が高くなるほど、一連の出力画像 4 0 3 の間の不一致性（又はノイズの変化）の大きさが大きくなるということを認識している。

【0 0 5 2】

一貫性損失 4 3 5 は、行列 B 又は（上記の式 1 A 及び式 1 B に示されているような）平均画素値に基づいているが、いくつかの実施形態では、一貫性損失 4 3 5 は、一連の出力画像 4 0 3 の画像の間の、ある関係性に基づいていてもよい。例えば、いくつかの実施形態では、一連の出力画像 4 3 0 が、動いている物体を描写するシーンのように動きのあるシーンを描写していることがある。該一連の出力画像 4 0 3 の第 1 画像が該シーンにおける物体の第 1 の位置に対応する一以上の画素を含んでおり、該一連の出力画像 4 0 3 の第 2 画像が該シーンにおける物体の第 2 の位置に対応する一以上の画素を含んでいることがある。いくつかの態様では、物体の動きが、第 1 画像における該物体の位置に対応する一以上の画素と第 2 画像における該物体の位置に対応する一以上の画素とに基づいて規定されることがある。一旦、動きが規定されると、該一連の出力画像 4 0 3 の第 1 画像及び／又は第 2 画像が修正又は歪まされ、一貫性損失 4 3 5 は、規定された動き、及び／又は、修正された第 1 画像及び第 2 画像に基づいて決定されることがある。運動（又は規定された動き）に基づく関係が上述されているが、いくつかの実施形態では、該関係が、一連の出力画像 4 0 3 の間の画素値（例えば、画素強度）の変化に基づいていてもよい。

20

30

30

【0 0 5 3】

図 4 に図示されているように、ネットワーク損失 4 3 3 と一貫性損失 4 3 5 は、総損失算出器 4 3 6 に提供される。総損失算出器 4 3 6 は、ネットワーク損失 4 3 3 と一貫性損失 4 3 5 とを組み合わせて総損失 4 0 5 を決定するように構成されることがある。総損失 4 0 5 は、下記のように表現され得る：

【数 4】

$$\text{総損失} = \alpha * \text{ネットワーク損失} + (1 - \alpha) * y * \text{一貫性損失} \quad (\text{式 2})$$

40

式 2 において、 α は、ネットワーク損失 4 3 3 と一貫性損失 4 3 5 との間のバランスをとるために使用されるスカラー量であり、 y は、一連の出力画像 4 0 3 の内容に依存して 0 又は 1 の値に設定される。いくつかの実施形態では、一連の入力画像（例えば、図 3 の一連の入力画像 3 0 2）が、静止しているシーン、動きがあるシーン、又は、静止しているシーンと動きがあるシーンの両方を描写しているとしてラベリング（又は分類）されることがある。該ラベリングは、任意の適切な手作業による又は自動の方法によって実行され得る。更に、該ラベリングは、トレーニング動作の間、一連の入力画像から対応する一連の出力画像（例えば、それぞれ図 3 及び図 4 の一連の出力画像 3 0 3 及び／又は 4 0 3

50

)に伝達されることがある。

【 0 0 5 4 】

一連の出力画像 4 0 3 が静止しているシーンを描写しているいくつかの実施形態では、
 y が 1 に設定されることがある。一連の出力画像 4 0 3 が、動きがあるシーンを描写して
いるいくつかの他の実施形態では y が 0 に設定されることがある。更に、一連の出力画像
4 0 3 が静止しているシーンと動きがあるシーンの両方を描写しているいくつかの他の実
施形態では、 y は、サイズ N (一連の出力画像 4 0 3 のバッチサイズ) のベクトルであつ
てもよい。即ち、 y が、N 個の要素を持つベクトルであってもよい。ここで、各要素は一
連の出力画像 4 0 3 の各画像に対応している。更に、ある要素は、該要素が静止して
いるシーンの一部である出力画像 4 0 3 に対応しているならば 1 に設定され、該要素が、動き
があるシーンの一部である出力画像 4 0 3 に対応しているならば 0 に設定されてもよい。
10

【 0 0 5 5 】

総損失 4 0 5 がひとたび決定されると、ネットワーク最適化器 (例えば、図 3 のネット
ワーク最適化器 3 2 8) は、総損失 4 0 5 を、ある収束基準が満たされているかを判断す
るために使用することがある。例えば、総損失 4 0 5 が閾値レベルよりも小さくなつてお
り、及び / 又は、所定数のトレーニングイテレーションが完了した場合、ネットワーク最
適化器は、ニューラルネットワーク (例えば、図 3 のニューラルネットワーク 3 2 2) が最
適化されていると判断することがある。従って、ネットワーク最適化器は、ニューラル
ネットワークの重み (例えば、図 3 の重み 3 0 7) を更新しないことがある。他の例とし
て、総損失 4 0 5 が閾値レベルより大きく、及び / 又は、所定数のトレーニングイテレー
ションが未だ完了していない場合、ネットワーク最適化器は、ニューラルネットワークが未
だ最適化されていないと判断することがある。従って、ネットワーク最適化器は、ニュ
ーラルネットワークの重みを更新するために、総損失 4 0 5 を最小化する一以上の重みを
決定することができる。
20

【 0 0 5 6 】

いくつかの態様では、ネットワーク最適化器が、総損失 4 0 5 を最小化して一以上の重
みを決定するために確率的勾配降下法を用いてもよい。確率的勾配降下法に加え、ネット
ワーク最適化器は、総損失 4 0 5 の一貫性損失の成分を最小化するために追加の手法を用
いてもよい。例えば、一貫性損失 4 3 5 が上述の式 1 A 及び式 1 B を用いて算出される場
合、一貫性損失 4 3 5 を最小化するために、テンソルフロー (Tensorflow) 又はケラ
ス (Keras) ソフトウェアライブラリが使用されてもよい。一貫性損失 4 3 5 が行列 B
の階数で表現される他の例としては、(非凸である) 階数をその非凸サロゲートである核
型ノルムに置き換え、L 1 ノルムスパース分解と拡張ラグランジュ乗数 (ALM) 法を用
いることにより該階数が最小化されてもよい。
30

【 0 0 5 7 】

図 5 は、ピラミッド損失に関連する例示的なピラミッドレベル (又はスケール) を示す
例示的な図 5 0 0 を図示している。いくつかの態様では、ピラミッド損失は、異なるピラ
ミッドレベル (例えば、図 5 のピラミッドレベル 1 及び 0) における出力画像 (例えば、
図 5 の出力画像 5 0 3 又は 5 0 4) と基礎真正画像 (例えば、図 5 の基礎真正画像 5 2 5)
との間の差を表している。いくつかの実施形態では、ピラミッド損失は、ネットワーク
損失算出器 (例えば、図 4 のネットワーク損失算出器 4 3 2) によって決定され得る。
40

【 0 0 5 8 】

ピラミッドレベル (又はスケール) は、例えば出力画像又は基礎真正画像のような画像
の画素粒度をいうことがある。例えば、より高いピラミッドレベルは、より粗い画素粒度
又はより少数の画素値に対応していることがある。従って、画像は、より低いピラミッド
レベルの同じ画像よりもズームアウトされて見える (又は、詳細を少ししか示さない)
ことがある。例えば、より高いピラミッドレベルに対応する各画素値は、より低いピラミッ
ドレベルに対応する (例えば、2 以上の隣接する画素の) 2 以上の画素値の平均を表す
ことがある。一方、より低いピラミッドレベルは、より細かい画素粒度又はより多数の画素
値に関連していることがある。したがって、画像は、より高いピラミッドレベルの同じ画
50

像よりもズームインして見える（又は、より多くの詳細を示す）ことがある。例えば、最低のピラミッドレベル（例えば、図5におけるピラミッドレベル0）に対応する画素値は、出力画像又は基礎真正画像の生の（又はスケーリングしていない）画素値を表すことがある。

【0059】

いくつかの実施形態では、ネットワーク損失算出器は、例えば（上述されているような）平均ブーリング、最大ブーリング又は最小ブーリング等のブーリング（「ダウンスケーリング」ともいう）を用いて、最低ピラミッドレベルを除く各ピラミッドレベルに対応する、スケーリング後の数の画素値を生成するように構成されることがある。例えば、ネットワーク損失算出器は、最低のピラミッドレベル（例えば、図5のピラミッドレベル0）に対応する画素値をプールして次に低いピラミッドレベル（例えば、図5のピラミッドレベル1）に対応するスケーリング後の画素値を生成することがある。いくつかの実施形態では、ネットワーク損失算出器は、所定のブーリングサイズに基づいて画像のピラミッド損失を計算するように構成されることがある。ここで、ブーリングサイズは、2以上の画素を含んでいる。例えば、図5を参照して、ネットワーク損失算出器は、4つの画素値の所定のブーリングサイズに基づいて出力画像503についてピラミッド損失を計算することがある。即ち、ネットワーク損失算出器は、出力画像503についてピラミッドレベル0に対応する4つの画素値をプールして出力画像503についてピラミッドレベル1に対応するスケーリング後の画素値を生成することがある。更に、いくつかの実施形態では、ネットワーク損失算出器は、所定数のピラミッドレベル（例えば、図5のピラミッドレベル0及び1のような2つのピラミッドレベル）に基づいて画像のピラミッド損失を算出するように構成されることがある。更に、いくつかの実施形態では、ネットワーク損失算出器は、最高のピラミッドレベルについての所定数の（又は対象の数の）画素値に少なくとも部分的にに基づいて画像のピラミッド損失を算出するように構成されることがある。例えば、図5を参照して、ネットワーク損失算出器は、出力画像503のピラミッドレベル1に対応する単一の画素値に少なくとも部分的にに基づいて出力画像503のピラミッド損失を算出することがある。

【0060】

図5に図示されているように、ピラミッドレベル0とピラミッドレベル1とは、出力画像503及び504のそれぞれについてピラミッド損失を決定するために使用され得る。上述されているように、ピラミッドレベル0は、図5に示されている最低のピラミッドレベルである。従って、ピラミッドレベル0は、出力画像503、出力画像504及び基礎真正画像525の各画素の生の（又はスケーリングされていない）画素値を表す画素値に関連している。別の言い方をすれば、図5は、出力画像503、出力画像504及び基礎真正画像525のそれぞれのピラミッドレベル0における4つの画素のサブセットを示している。即ち、ピラミッドレベル0では、図5は、出力画像503の画素（又は画素値）P01、P02、P03及びP04と、出力画像504の画素（又は画素値）P01'、P02'、P03'及びP04'、と、基礎真正画像525の画素（又は画素値）P01''、P02''、P03''及びP04''を図示している。図5には図示されていないが、いくつかの実施形態では、2つの画素値、3つの画素値、又は5以上の画素値のサブセットが、ピラミッドレベル0における出力画像503、出力画像504及び基礎真正画像525の各画素の生の画素値を表していることがある。

【0061】

出力画像503のピラミッド損失を決定するために、ネットワーク損失算出器は、まず、出力画像503についてのピラミッドレベル0に対応する損失量（「L0損失」ともいう）と、出力画像503についてのピラミッドレベル1に対応する損失量（「L1損失」ともいう）とを算出することがある。出力画像503のL0損失を算出するために、ネットワーク損失算出器は、下記の式3に示すように、出力画像503と基礎真正画像525のピラミッドレベル0における対応する画素値の間の差の絶対値の和をとることがある。

【数5】

10

20

30

40

50

$$L_0 \text{ 損失} = |P_{01} - P_{01}''| + |P_{02} - P_{02}''| + |P_{03} - P_{03}''| + |P_{04} - P_{04}''| \quad (\text{式 } 3)$$

図 5 に図示されているように、ピラミッドレベル 0 における出力画像 5 0 3 の画素は、次の画素値 : $P_{01} = 0$ 、 $P_{02} = 0.5$ 、 $P_{03} = 0.5$ 、 $P_{04} = 0$ を有している。更に、基礎真正画像 5 2 5 の画素 P_{01}'' 、 P_{02}'' 、 P_{03}'' 及び P_{04}'' のそれぞれは、 0.25 の画素値を有している。出力画像 5 0 3 と基礎真正画像 5 2 5 のピラミッドレベル 0 における画素値を式 3 に代入すると、下記に示すように、 L_0 損失が 1 であると得られる :

10

【数 6】

$$L_0 \text{ 損失} = |0 - 0.25| + |0.5 - 0.25| + |0.5 - 0.25| + |0 - 0.25| = 1$$

【0 0 6 2】

出力画像 5 0 3 についての L_1 損失が計算可能になる前に、ネットワーク損失算出器は、出力画像 5 0 3 と基礎真正画像 5 2 5 についてピラミッドレベル 1 の画素値を生成するためにプーリングを用いることがある。例えば、図 5 に図示されているように、ネットワーク損失算出器は、出力画像 5 0 3 のピラミッドレベル 0 での画素値を 4 つの隣接する画素に渡って（例えば、 P_{01} 、 P_{02} 、 P_{03} 及び P_{04} ）平均することによって平均プーリングを用いて出力画像 5 0 3 のピラミッドレベル 1 における個別の画素値 P_1 を生成することがある。 P_1 の値は、下記に示すように算出可能である :

20

【数 7】

$$P_1 = \frac{P_{01} + P_{02} + P_{03} + P_{04}}{4} = \frac{0 + 0.5 + 0.5 + 0}{4} = 0.25$$

30

【0 0 6 3】

同様に、ネットワーク損失算出器は、基礎真正画像 5 2 5 のピラミッドレベル 0 での画素値を平均化する平均プーリングを用いて基礎真正画像 5 2 5 のピラミッドレベル 1 における個別の画素値 P_1'' を決定することがある。 P_1'' の値は、下記に示すように算出可能である :

【数 8】

$$P_1'' = \frac{P_{01}'' + P_{02}'' + P_{03}'' + P_{04}''}{4} = \frac{0.25 + 0.25 + 0.25 + 0.25}{4} = 0.25$$

40

【0 0 6 4】

出力画像 5 0 3 の L_1 損失を算出するために、ネットワーク損失算出器は、下記の式 4 に示すように、ピラミッドレベル 1 における出力画像 5 0 3 の画素 P_1 と基礎真正画像 5 2 5 の画素 P_1'' の間の差の絶対値を決定することがある。

【数 9】

$$L_1 \text{ 損失} = |P_1 - P_1''| \quad (\text{式 } 4)$$

50

【 0 0 6 5 】

ピラミッドレベル 1 における出力画像 5 0 3 と基礎真正画像 5 2 5 の画素値を式 4 に代入すると、下記に示すように L_1 損失が 0 として得られる。

【 数 1 0 】

$$L_1 \text{ 損失} = |P1 - P1''| = |0.25 - 0.25| = 0$$

【 0 0 6 6 】

より一般的には、ネットワーク損失算出器は、任意の数 (N') の画素を有する出力画像の任意の数 (i) のピラミッドレベルに渡るピラミッド損失を、下記式 5 A を用いて決定してもよい。

【 数 1 1 】

$$\text{ピラミッド損失(出力画像)} = \sum_i \frac{|Pool_i(\text{出力画像}) - Pool_i(\text{基礎真正画像})|}{N'_i} \quad (\text{式 5A})$$

式 5 Aにおいて、 $Pool_i(\text{画像 } x)$ は、画像 x (例えば、出力画像又は基礎真正画像) を倍率 i でブーリング又はダウンサンプリングしたものを表している。 i 番目のピラミッドレベルに関連する損失量は、下記のように表され得る :

【 数 1 2 】

$$L_i = |Pool_i(\text{出力画像}) - Pool_i(\text{基礎真正画像})|$$

L_i についての上記式を式 5 A に代入すると、ピラミッド損失について、下記の代替的な式が得られる。

【 数 1 3 】

$$\text{ピラミッド損失(出力画像)} = \frac{L_0}{N'_0} + \frac{L_1}{N'_1} + \dots + \frac{L_{z-1}}{N'_{z-1}} \quad (\text{式 5B})$$

式 5 Bにおいて、(z) は、ピラミッドレベルの総数を表しており、 i は、0 から $z - 1$ まで (例えば、0 $\leq i \leq z - 1$) の範囲の整数として表される。出力画像 5 0 3 についてのピラミッドレベル 0 及び 1 に関連する損失量と画素の数を式 5 B に代入すると、下記に示すように、ピラミッド損失が 0 . 2 5 として得られる。

【 数 1 4 】

$$\text{ピラミッド損失(出力画像 503A)} = \frac{L_0}{N'_0} + \frac{L_1}{N'_1} = \frac{1}{4} + \frac{0}{1} = 0.25$$

【 0 0 6 7 】

上述した処理を用いて、出力画像 5 0 4 についてピラミッド損失が 0 . 5 と算出され得る。いくつかの実施形態では、ピラミッド損失を算出するときに、異なるピラミッドレベルに対応する損失量 (「損失項」ともいう) L_0 、 L_1 、 \dots 、 L_{z-1} に異なる重みが適用されてもよい。例えば、いくつかの用途では、より低いピラミッドレベルに対応す

10

20

30

40

50

る損失項には、より高いピラミッドレベルに対応する損失項よりも重く重み付けがなされてもよい。いくつかの他の用途では、より高いピラミッドレベルに対応する損失項には、より低いピラミッドレベルに対応する損失項よりも重く重み付けがなされてもよい。更に、いくつかの実施形態では、一連の出力画像の一以上の出力画像についてのピラミッド損失が、ニューラルネットワークアルゴリズムの重みの更新に使用されてもよい。

【 0 0 6 8 】

図 6 は、いくつかの実装による例示的な機械学習システム 6 0 0 を図示している。いくつかの実施形態では、機械学習システム 6 0 0 は、図 3 の機械学習システム 3 0 0 の一例であり得る。従って、機械学習システム 6 0 0 は、一連の入力画像 6 0 2 (入力画像 6 0 2 ともいう) と一以上の基礎真正画像 6 2 5 とに基づいてニューラルネットワークモデル 6 2 3 を生成するように構成されることがある。いくつかの実施形態では、機械学習システム 6 0 0 は、処理システム 6 4 0 とメモリ 6 5 0 とを備えていることがある。

【 0 0 6 9 】

メモリ 6 5 0 は、少なくとも下記のソフトウェア (SW) モジュールを格納することがある (例えば E P R O M 、 E E P R O M 、フラッシュメモリ、ハードドライブ等のような一以上の不揮発性メモリ要素を含む) 非一時的コンピュータ読み取り可能媒体を備えることがある :

- ・ニューラルネットワークモデル 6 2 3 をトレーニングするために、一以上の基礎真正画像 6 2 5 を再生成しようすることにより、一連の入力画像 6 0 2 のノイズ除去した表現 (例えば、一連の出力画像) を生成するように構成されたニューラルネットワーク SW モジュール 6 5 2
- ・一連の出力画像と一以上の基礎真正画像 6 2 5 とに基づいて総損失量を決定するように構成された損失算出器 SW モジュール 6 5 4 (ここで、損失算出器 SW モジュール 6 5 4 は、更に、一連の出力画像と一以上の基礎真正画像 6 2 5 とに基づいてネットワーク損失の総量を決定するネットワーク損失サブモジュール 6 5 5 と、一連の出力画像に基づいて一貫性損失の量を決定する一貫性損失サブモジュール 6 5 6 とを備えている) 、及び、
- ・総損失量に基づいてニューラルネットワーク SW モジュール 6 5 2 の一以上の更新後の重みを決定するように構成されたネットワーク最適化器 SW モジュール 6 5 8

各ソフトウェアモジュールは、処理システム 6 4 0 によって実行されたときに、対応する機能を機械学習システム 6 0 0 に実行させる命令を含んでいる。

【 0 0 7 0 】

処理システム 6 4 0 は、機械学習システム 6 0 0 に (例えばメモリ 6 5 0 に) 保存された一以上のソフトウェアプログラムのスクリプト又は命令を実行することができる一以上の適切なプロセッサを備えていてもよい。例えば、処理システム 6 4 0 は、一以上の基礎真正画像 6 2 5 を再生成しようすることにより一連の入力画像 6 0 2 のノイズ除去した表現を生成するためにニューラルネットワーク SW モジュール 6 5 2 を実行することがある。言い換えれば、処理システム 6 4 0 は、一連の入力画像 6 0 2 を一連の出力画像にマッピングするためにニューラルネットワーク SW モジュール 6 5 2 を実行することがある。

【 0 0 7 1 】

処理システム 6 4 0 は、更に、総損失を決定するために損失算出器 SW モジュール 6 5 4 を実行することができる。損失算出器 SW モジュール 6 5 4 を実行する際、処理システム 6 4 0 は、更に、ネットワーク損失サブモジュール 6 5 5 と一貫性損失サブモジュール 6 5 6 とを実行することができる。例えば、処理システム 6 4 0 は、一以上の基礎真正画像 6 2 5 を基準とした一連の出力画像におけるネットワーク損失 (又はノイズ) の総量を決定するためにネットワーク損失サブモジュール 6 5 5 を実行することができる。処理システム 6 4 0 は、更に、一連の出力画像の間のノイズの変化量を決定するために一貫性損失サブモジュール 6 5 6 を実行することができる。いくつかの実施形態では、処理システム 6 4 0 は、更に、総損失に基づいてニューラルネットワーク SW モジュール 6 5 2 の更新後の重みを決定するためにネットワーク最適化器 SW モジュール 6 5 8 を実行することができる。

10

20

30

40

50

【 0 0 7 2 】

図 7 は、いくつかの実装による、ニューラルネットワークをトレーニングするための例示的な動作 700 を示す例示的なフローチャートを図示している。例示的な動作 700 は、一連の入力画像のノイズが除去された表現を推論するようにニューラルネットワークをトレーニングするために機械学習システム（例えば、それぞれ図 3 及び図 6 の機械学習システム 300 及び / 又は 600）によって実行されることがある。

【 0 0 7 3 】

機械学習システムは、あるシーンを撮影した一連の入力画像を取得することがある（710）。機械学習システムは、また、ニューラルネットワークアルゴリズムに基づいて一連の入力画像の第 1 入力画像を第 1 出力画像にマッピングすることがある（720）。いくつかの実施形態では、一連の入力画像は、静止しているシーンの画像を表すことがある。更に、いくつかの実施形態では、ニューラルネットワークアルゴリズムは、再帰型ニューラルネットワークアルゴリズムを含むことがある。

10

【 0 0 7 4 】

機械学習システムは、更に、第 1 出力画像と基礎真正画像との間の差に基づいて第 1 ネットワーク損失を決定することがある（730）。機械学習システムは、また、該ニューラルネットワークアルゴリズムに基づいて一連の入力画像の第 2 入力画像を第 2 出力画像にマッピングすることがある（740）。いくつかの実施形態では、基礎真正画像の SNR は、第 1 入力画像の SNR 及び第 2 入力画像の SNR よりも大きいことがある。いくつかの他の実施形態では、基礎真正画像の解像度は、第 1 入力画像の解像度及び第 2 入力画像の解像度よりも大きいことがある。

20

【 0 0 7 5 】

機械学習システムは、更に、第 2 出力画像と基礎真正画像との間の差に基づいて第 2 ネットワーク損失を決定することがある（750）。機械学習システムは、また、第 1 出力画像と第 2 出力画像との間の差に基づいて一貫性損失を決定することがある（760）。いくつかの態様では、第 1 出力画像と第 2 出力画像のそれぞれは、複数の画素値を含むことがある。いくつかの実施形態では、機械学習システムは、第 1 出力画像の複数の画素値と第 2 出力画像の複数の画素値に対応する平均画素値に基づいて一貫性損失を決定することがある。いくつかの他の実施形態では、機械学習システムは、第 1 出力画像の複数の画素値と第 2 出力画像の複数の画素値とを含む行列を生成し、該行列の階数を決定することによって一貫性損失を決定することがある。

30

【 0 0 7 6 】

機械学習システムは、更に、第 1 ネットワーク損失、第 2 ネットワーク損失及び一貫性損失に少なくとも部分的にに基づいてニューラルネットワークアルゴリズムを更新することがある（770）。いくつかの実施形態では、機械学習システムが、更に、第 1 ネットワーク損失、第 2 ネットワーク損失及び一貫性損失に少なくとも部分的にに基づいて総損失を決定することがある。機械学習システムは、更に、総損失を最小化し、最小化した総損失に基づいて一以上のパラメータを決定してニューラルネットワークアルゴリズムを更新することがある。

40

【 0 0 7 7 】

図 8 は、いくつかの実装による、ニューラルネットワークをトレーニングするための例示的な動作 800 を示す例示的なフローチャートを図示している。いくつかの実施形態では、例示的な動作 800 は、一連の画像のノイズ除去した表現を推論するようにニューラルネットワークをトレーニングするために機械学習システム（例えば、それぞれ図 3 及び図 6 の機械学習システム 300 及び / 又は 600）によって実行されることがある。

【 0 0 7 8 】

機械学習システムは、あるシーンを撮影した一連の入力画像を取得することがある（810）。機械学習システムは、また、ニューラルネットワークアルゴリズムに基づいて一連の入力画像の第 1 入力画像を第 1 出力画像にマッピングすることがある（820）。いくつかの実施形態では、一連の入力画像は、静止しているシーン及び / 又は動きがあるシ

50

ーンの画像を表すことがある。更に、いくつかの実施形態では、ニューラルネットワークアルゴリズムは、再帰型ニューラルネットワークアルゴリズムを含むことがある。

【0079】

機械学習システムは、更に、第1出力画像と第1基礎真正画像との間の差に基づいて第1ネットワーク損失を決定することがある(830)。いくつかの実施形態では、第1基礎真正画像のSNRが第1入力画像のSNRよりも大きいことがある。いくつかの他の実施形態では、第1基礎真正画像の解像度が第1入力画像の解像度よりも高いことがある。

【0080】

機械学習システムは、また、該ニューラルネットワークアルゴリズムに基づいて一連の入力画像の第2入力画像を第2出力画像にマッピングすることがある(840)。機械学習システムは、また、第2出力画像と第2基礎真正画像との間の差に基づいて第2ネットワーク損失を決定することがある(850)。いくつかの実施形態では、第2基礎真正画像のSNRが第2入力画像のSNRよりも大きいことがある。いくつかの他の実施形態では、第2基礎真正画像の解像度が第2入力画像の解像度よりも高いことがある。

10

【0081】

機械学習システムは、また、第1出力画像と第2出力画像との間の差に基づいて一貫性損失を決定することがある(860)。いくつかの態様では、第1出力画像と第2出力画像のそれぞれは、複数の画素値を含むことがある。いくつかの実施形態では、機械学習システムは、第1出力画像の複数の画素値と第2出力画像の複数の画素値に対応する平均画素値に基づいて一貫性損失を決定することがある。いくつかの他の実施形態では、機械学習システムは、第1出力画像の複数の画素値と第2出力画像の複数の画素値とを含む行列を生成し、該行列の階数を決定することによって一貫性損失を決定することがある。

20

【0082】

機械学習システムは、更に、第1ネットワーク損失、第2ネットワーク損失及び一貫性損失に少なくとも部分的にに基づいてニューラルネットワークアルゴリズムを更新することがある(870)。

【0083】

当業者は、情報及び信号が、様々な異なる技術及び手法の任意のものを用いて表現され得ることを理解しよう。例えば、上記の説明において言及されているかもしれないデータ、命令、コマンド、情報、信号、ビット、シンボル及びチップは、電圧、電流、電磁波、磁界又は磁性粒子、光学場又は光学的粒子、又は、それらの任意の組み合わせによって表現され得る。

30

【0084】

更に、当業者は、本明細書に開示された態様に関連して説明されている様々な例示的な論理ブロック、モジュール、回路及びアルゴリズム工程が、電子ハードウェア、コンピュータソフトウェア又はそれらの組み合わせとして実装され得ることを理解しよう。このハードウェアとソフトウェアの互換性を明確に図示するために、上記では、様々な例示的なコンポーネント、ブロック、モジュール、回路及び工程が概してその機能の観点から説明されている。このような機能が、ハードウェアとして実装されるかソフトウェアとして実装されるかは、個別の用途及び全体システムに課せられている設計制約に依存する。当業者は、各個別の用途のために記載された機能を様々な方法で実施することがある。しかしながら、このような実施上の決定は、本開示の範囲からの逸脱を生じさせるものとして解釈すべきではない。

40

【0085】

本明細書に開示された態様に関連して説明された方法、シーケンス又はアルゴリズムは、直接にハードウェアで具現化されてもよく、プロセッサによって実行されるソフトウェアモジュールにおいて具現化されてもよく、又は、これらの2つの組み合わせで具現化されてもよい。ソフトウェアモジュールは、RAMメモリ、フラッシュメモリ、ROMメモリ、EPROMメモリ、EEPROMメモリ、レジスタ、ハードディスク、リムーバブルディスク、CD-ROM又は本技術分野において知られる他の任意の形態の記録媒体に存

50

在し得る。例示的な記録媒体は、プロセッサが該記録媒体から情報を読み出し、該記録媒体に情報を書き込むことができるようプロセッサに結合される。その代わりに、記録媒体がプロセッサに組み込まれてもよい。

【0086】

上記の明細書において、実施形態は、その具体的な例を参照して説明されている。しかしながら、添付の特許請求の範囲に提示されているような開示のより広い範囲から逸脱しなければ、様々な修正及び変更がなされることは明らかであろう。したがって、明細書と図面は、制限的な意味というよりむしろ、例示的な意味で評価されるべきである。

【図面】

【図1】

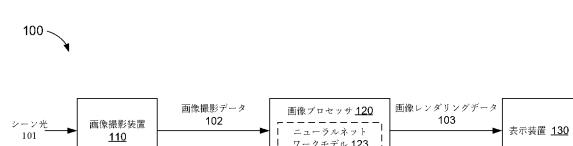


FIG. 1

【図2】



10



20



30

FIG. 2

40

50

【図3】

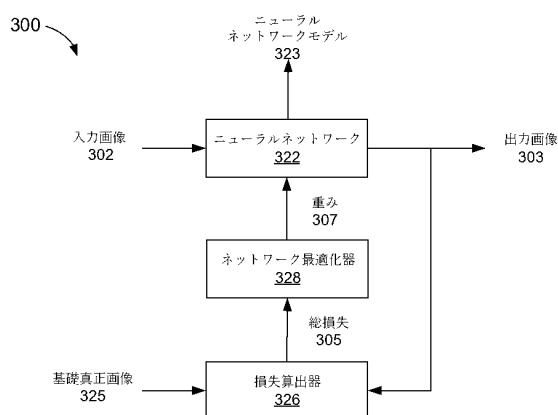


FIG. 3

【図4】

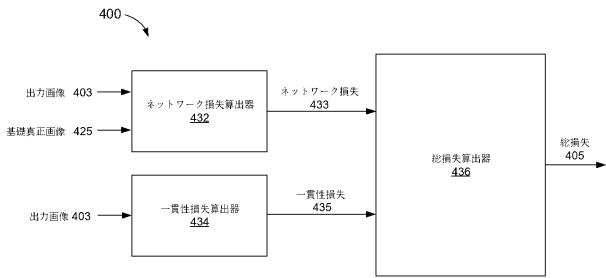


FIG. 4

10

【図5】

	出力画像 503	出力画像 504	基礎真正画像 525
ピラミッドレベル 1	$P_1 \wedge 0.25$ $L_1 \text{ 損失}=0$	$P_1' \wedge 0$ $L_1 \text{ 損失}=0.25$	$P_1'' \wedge 0.25$
ピラミッドレベル 0	$\begin{matrix} P_{01} & P_{02} \\ 0 & 0.5 \\ 0.5 & 0 \end{matrix}$ $L_0 \text{ 損失}=1$	$\begin{matrix} P_{01'} & P_{02'} \\ 0 & 0 \\ 0 & 0 \end{matrix}$ $L_0 \text{ 損失}=1$	$\begin{matrix} P_{03''} & P_{04''} \\ 0.25 & 0.25 \\ 0.25 & 0.25 \end{matrix}$

FIG. 5

20

【図6】

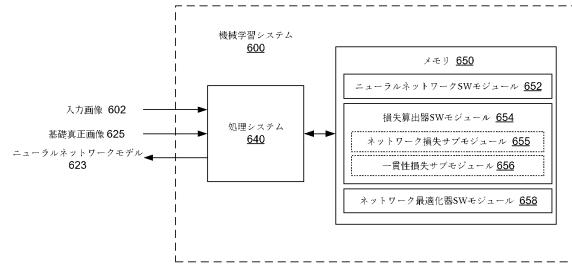


FIG. 6

30

40

50

【図7】

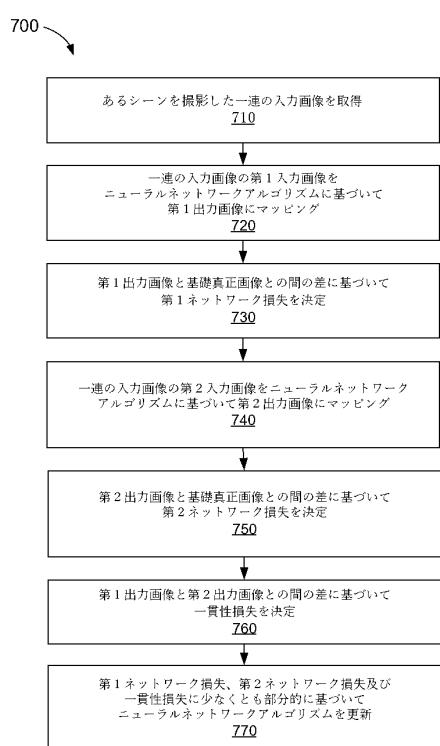


FIG. 7

【図8】

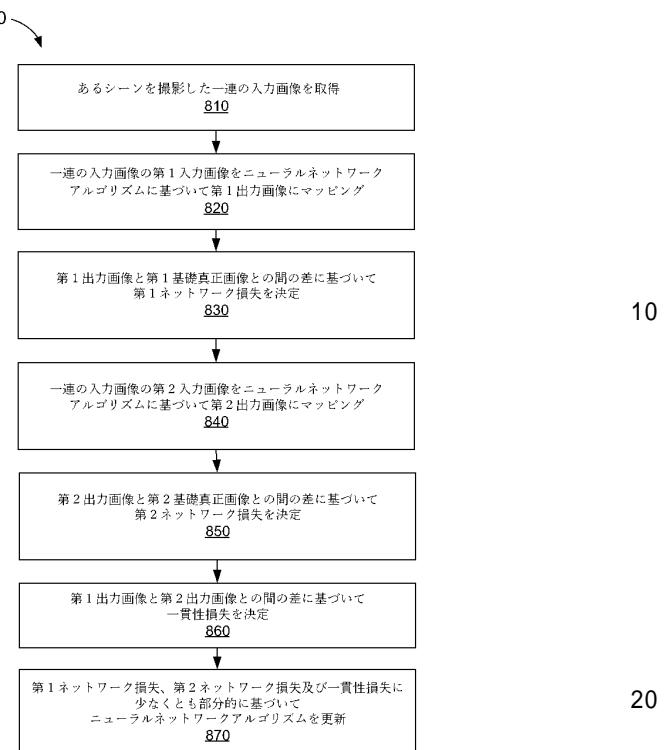


FIG. 8

【外国語明細書】

2023035928000024.pdf

フロントページの続き

F ターム (参考) CD05 CE02 DA16 DB02 DB06 DB09 DC40