(19)日本国特許庁(JP)　(12)公開特許公報(A)　(11)公開番号
特開2024-28206
(P2024-28206A)
(43)公開日　令和6年3月1日(2024.3.1)

(51)国際特許分類			FI			テーマコード（参考）
Ｇ０６Ｆ	*30/27*	*(2020.01)*	Ｇ０６Ｆ	30/27		５Ｂ１４６
Ｇ０６Ｆ	*30/10*	*(2020.01)*	Ｇ０６Ｆ	30/10	１００	

審査請求　未請求　請求項の数　15　ＯＬ　外国語出願　（全26頁）

(21)出願番号　特願2023-132744(P2023-132744)
(22)出願日　令和5年8月17日(2023.8.17)
(31)優先権主張番号　22306233.2
(32)優先日　令和4年8月17日(2022.8.17)
(33)優先権主張国・地域又は機関
欧州特許庁(EP)

(71)出願人　500102435
ダッソー システムズ
ＤＡＳＳＡＵＬＴ ＳＹＳＴＥＭＥＳ
フランス国 ７８１４０ ベリジー ビラクブレー リュ マルセル ダッソー １０
(74)代理人　110001243
弁理士法人谷・阿部特許事務所
(72)発明者　マリエム メズガニ
フランス ７８９４６ ベリジー－ビラクブレー セデックス リュ マルセル ダッソー １０ シーエス ４０５０１ ダッソー システムズ エスイー内
(72)発明者　ジュリアン ブーシェ
フランス ７８９４６ ベリジー－ビラクブレー セデックス リュ マルセル ダッ
最終頁に続く

(54)【発明の名称】　トポロジー認識ＣＡＤ検索のための機械学習

(57)【要約】
【課題】機械学習のコンピュータに実装される方法を提供する。
【解決手段】方法は、Ｂ－ｒｅｐグラフのトレーニングデータセットを取得することを含む。各Ｂ－ｒｅｐグラフは、それぞれのＢ－ｒｅｐを表しグラフノードを含み、各々がそれぞれのＢ－ｒｅｐの辺、面、または共辺を表し１つまたは複数の幾何学的特徴および／または位相幾何学的特徴に関連付けられる。各Ｂ－ｒｅｐグラフは、各々がそれぞれの共辺を表すそれぞれの第１のグラフノードとそれぞれの共辺に関連付けられた面、辺、隣り合う共辺、または対をなす共辺を表すそれぞれの第２のグラフノードとの間にあるグラフエッジを含む。方法はトレーニングデータセットに基づいてディープＣＡＤニューラルネットワークを学習させることをさらに含む。ディープＣＡＤニューラルネットワークは、入力されたＢ－ｒｅｐグラフにより表されるＢ－ｒｅｐのトポロジカルシグネチャを出力する。
【選択図】図１

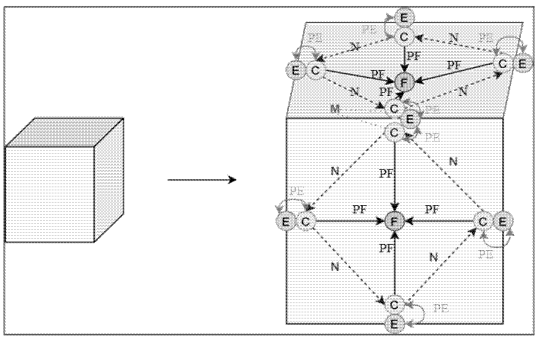

【特許請求の範囲】
【請求項１】
機械学習のコンピュータに実装される方法であって、
－　Ｂ－ｒｅｐグラフのトレーニングデータセットを取得することであって、各Ｂ－ｒｅｐグラフはそれぞれのＢ－ｒｅｐを表し、および各Ｂ－ｒｅｐグラフは、
○　グラフノードであって、各々が、前記それぞれのＢ－ｒｅｐの辺、面、または共辺（co-edge）を表し、１つまたは複数の幾何学的特徴および／または位相幾何学的特徴に関連付けられる、グラフノードと、
○　グラフエッジであって、各々が、それぞれの共辺を表すそれぞれの第１のグラフノードと、前記それぞれの共辺に関連付けられた面、辺、隣り合う共辺、または対をなす共辺を表すそれぞれの第２のグラフノードとの間にある、グラフエッジと
を含む、ことと、
－　前記トレーニングデータセットに基づいて、Ｂ－ｒｅｐグラフを入力として得て、前記入力されたＢ－ｒｅｐグラフにより表される前記Ｂ－ｒｅｐのトポロジカルシグネチャを出力するように構成されるディープＣＡＤニューラルネットワークに学習させることと
を備えることを特徴とする方法。
【請求項２】
前記ディープＣＡＤニューラルネットワークは、前記ニューラルネットワークのカーネルに従って、隣接しているＢ－ｒｅｐ要素の特徴ベクトルにより各共辺の前記特徴ベクトルをコンカチネートするカーネルコンカチネーションを行うように構成される畳み込みユニットを含むことを特徴とする請求項１に記載の方法。
【請求項３】
前記畳み込みユニットは、前記カーネルコンカチネーションに起因する共辺の各々コンカチネートされた特徴ベクトルを、稠密なニューラルネットワークへの入力として渡すようにさらに構成されることを特徴とする請求項２に記載の方法。
【請求項４】
前記畳み込みユニットは、共辺についての入力されているコンカチネートされた特徴ベクトルに関して前記稠密なニューラルネットワークによって出力された各ベクトルに対する、新しい辺特徴ベクトル、新しい面特徴ベクトル、および新しい共辺特徴ベクトルを計算するようにさらに構成されることを特徴とする請求項３に記載の方法。
【請求項５】
前記稠密なニューラルネットワークは、前記カーネルコンカチネーション
【数１】

$$\psi_c^{(i)} = \mathrm{MLP}\left(\phi_c{}^{(i)}\right) = \left[\ \psi_{CC}^{(i)} \middle| \psi_{CF}^{(i)} \middle| \psi_{CE}^{(i)}\ \right],$$

に起因する共辺ｃについての入力されているコンカチネートされた特徴ベクトルΦｃ（ｉ）に関して出力し、
ただし、ΨＣＣ（ｉ）、ΨＣＦ（ｉ）、ΨＣＥ（ｉ）は、Ψｃ（ｉ）の次元が３＊ｈであるような同一の次元ｈを有し、各共辺ｃ、各面Ｆ、および各辺Ｅ、前記新しい特徴ベクトルは、次のとおりであり、
【数２】

$$\begin{cases} X_c^{(i+1)} = \psi_{CC}^{(i)} \\ X_E^{(i+1)} = \mathrm{MaxPool}\left(\psi_{CE1}^{(i)}, \psi_{CE2}^{(i)}\right) \\ X_F^{(i+1)} = \mathrm{MaxPool}\left(\psi_{CF1}^{(i)}, \cdots, \psi_{CFk}^{(i)}\right) \end{cases}$$

ただし、
●　Ｘｃ（ｉ＋１）は、共辺ｃに対する前記稠密なニューラルネットワークの前記出力Ψ

$c^{(i)}$のために前記計算された新しい共辺特徴であり、

● $X_E^{(i+1)}$は、辺Ｅに対する前記計算された新しい辺特徴であり、ただし、$\Psi_{CE1}^{(i)}$および$\Psi_{CE2}^{(i)}$は、２つの関連している共辺の前記特徴ベクトルに対応し、

● $X_F^{(i+1)}$は、面Ｆに対する前記計算された新しい面特徴であり、ただし、$\Psi_{CF1}^{(i)}$，．．．，$\Psi_{CFk}^{(i)}$は、ｋ個の関連している共辺の前記特徴に対応する

ことを特徴とする請求項４に記載の方法。

【請求項６】

前記ディープＣＡＤニューラルネットワークは、予め決められた回数繰り返して前記畳み込みユニットを適用するように構成されることを特徴とする請求項２または５に記載の方法。

【請求項７】

前記ディープＣＡＤニューラルネットワークは、面特徴ベクトルのアグリゲーションを行うことによって、大域的な特徴ベクトルを計算するようにさらに構成され、前記アグリゲーションは、最大プーリングの手法またはアテンションメカニズムの手法に基づくことを特徴とする請求項２ないし６のいずれか一項に記載の方法。

【請求項８】

前記ディープＣＡＤニューラルネットワークの前記学習は、大域的な特徴ベクトルのトポロジカルシグネチャを計算するために前記ディープＣＡＤニューラルネットワークを訓練する対照学習を行うことを含むことを特徴とする請求項７に記載の方法。

【請求項９】

前記対照学習は、

－　恒等変換、

－　確率による辺へのランダムなジオメトリの割り当て、

－　確率による面へのランダムなジオメトリの割り当て、

－　確率による面の前記特徴ベクトルの零との置き換え、

－　確率ｐによる辺の削除であって、前記削除は、前記入力されたＢ－ｒｅｐグラフから面を切り離すならば適用されない、削除

を含むポジティブトランスフォーメーションに基づくことを特徴とする請求項８に記載の方法。

【請求項１０】

前記対照学習は、前記コサイン類似度に基づく正規化温度スケール交差エントロピー損失を最小にすることを含み、前記損失は、タイプ

【数３】

$$L(i,j) = -\log \frac{e^{sim(Z_i,Z_j)}}{\sum_{k=1}^{2N} 1_{[k\neq i]}\, e^{sim(Z_i,Z_k)}},$$

の損失であり、ただし、（ｉ，ｊ）は正のペアを表し、（Z_i，Z_j）は前記ディープＣＡＤニューラルネットワークによる前記正のペアの埋め込みを表し、および、ただし、ｓｉｍは

【数４】

$$x, y \in \mathbb{R}^h$$

に対して、式

【数５】

$$sim(x,y) = \frac{x.y}{\|x\|\|y\|} = \frac{\sum_{i=1}^{h} x_i y_i}{\sqrt{\sum_{i=1}^{h} x_i^2}\sqrt{\sum_{i=1}^{h} y_i^2}}$$

により定義される前記コサイン類似度であることを特徴とする請求項８または９に記載の方法。
【請求項１１】
請求項１ないし１０のいずれか一項に記載の方法に従う学習可能なニューラルネットワーク。
【請求項１２】
請求項１１に係るニューラルネットワークの使用の方法であって、
－ Ｂ－ｒｅｐを表すＢ－ｒｅｐグラフを取得することと、
－ 前記Ｂ－ｒｅｐグラフに前記ニューラルネットワークを適用することによって、前記Ｂ－ｒｅｐのトポロジカルシグネチャを取得することと
を備えることを特徴とする方法。
【請求項１３】
コンピュータにより実行されると、前記コンピュータに、請求項１ないし１０のいずれか一項に記載の方法および／または請求項１２に記載の方法を行わせる命令を含むことを特徴とするコンピュータプログラム。
【請求項１４】
請求項１３に記載のコンピュータプログラムおよび／または請求項１１に記載のニューラルネットワークを記録したことを特徴とするコンピュータ読取り可能データ記録媒体。
【請求項１５】
メモリーに結合されたプロセッサーを備えたコンピューターシステムであって、前記メモリーは、請求項１３に記載のコンピュータプログラムおよび／または請求項１１に記載のニューラルネットワークを記録したことを特徴とするコンピューターシステム。
【発明の詳細な説明】
【技術分野】
【０００１】
本開示は、コンピュータプログラムおよびシステムの分野に関し、より具体的には、機械学習の方法、システム、およびプログラムに関する。
【背景技術】
【０００２】
複数のシステムおよびプログラムが、物体の設計、エンジニアリング、および製造の市場に出ている。ＣＡＤは、Ｃｏｍｐｕｔｅｒ－Ａｉｄｅｄ Ｄｅｓｉｇｎの頭字語であり、例えば、物体を設計するためのソフトウェアソリューションに関する。ＣＡＥは、Ｃｏｍｐｕｔｅｒ－Ａｉｄｅｄ Ｅｎｇｉｎｅｅｒｉｎｇの頭字語であり、例えば、将来の製品の物理的挙動をシミュレーションするためのソフトウェアソリューションに関する。ＣＡＭは、Ｃｏｍｐｕｔｅｒ－Ａｉｄｅｄ Ｍａｎｕｆａｃｔｕｒｉｎｇの頭字語であり、例えば、製造プロセスおよび操作を定義するためのソフトウェアソリューションに関する。上記のコンピュータ支援設計システムでは、グラフィカルユーザーインターフェースが、技法の効率に関して、重要な役割を果たす。今述べた技法は、製品ライフサイクル管理（ＰＬＭ）システム内に埋め込まれることがある。ＰＬＭは、拡張された企業体（ｅｘｔｅｎｄｅｄ ｅｎｔｅｒｐｒｉｓｅ）の概念にわたって、会社が、製品の開発に対して着想から耐用期間の終わりまで、製品のデータを共有し、共通のプロセスを適用し、企業の知識をレバレッジするのに役に立つ事業戦略に言及する。ダッソー・システムズによって提供されるＰＬＭソリューション（商標ＣＡＴＩＡ、ＥＮＯＶＩＡ、およびＤＥＬＭＩＡのもとに）は、製品エンジニアリングの知識を体系づける「エンジニアリングハブ」、製造エンジニアリングの知識を管理する「マニュファクチャリングハブ」、およびエンジニアリングハブとマニュファクチャリングハブとの両方への企業の統合および連結を可能にする「エンタープライズハブ」を提供する。すべて合わせてシステムは、製品、プロセス、リソースを結びつけるオープンなオブジェクトモデルを提供して、ダイナミックなナレッジベースの製品作成と、最適化された製品定義、製造準備、生産、およびサービスを促進する決断支援とを可能にする。

【０００３】
今述べた状況内に、および他の状況内に、ＣＡＤオブジェクト検索（CAD object retrieval）と、ＣＡＤオブジェクトの間の類似度評価（similarity evaluation）とのために改良されたソリューションが必要である。
【発明の概要】
【０００４】
それゆえ、機械学習に関する、コンピュータに実装される方法が提供される。本方法は、Ｂ－ｒｅｐグラフのトレーニングデータセット（training dataset）を取得することを含む。各Ｂ－ｒｅｐグラフは、それぞれのＢ－ｒｅｐを表す。各Ｂ－ｒｅｐグラフは、グラフノードを含み、各々が、それぞれのＢ－ｒｅｐの辺、面、または共辺（co-edge）を表し、１つまたは複数の幾何学的特徴および／または位相幾何学的特徴に関連付けられる。各Ｂ－ｒｅｐグラフは、各々が、それぞれの共辺を表すそれぞれの第１のグラフノードと、それぞれの共辺に関連付けられた面、辺、隣り合う共辺（adjacent co-edge,）、または対をなす共辺（mating co-edge）を表すそれぞれの第２のグラフノードとの間にあるグラフエッジ（graph edge）を含む。本方法は、トレーニングデータセットに基づいて、ディープＣＡＤニューラルネットワーク（Deep CAD neural network）を学習させることをさらに含む。ディープＣＡＤニューラルネットワークは、Ｂ－ｒｅｐグラフを入力として得て、入力されたＢ－ｒｅｐグラフにより表されるＢ－ｒｅｐのトポロジカルシグネチャを出力するように構成される。
【０００５】
本方法は、下記のうちの１つまたは複数を含むことがある。
－　ディープＣＡＤニューラルネットワークは、ニューラルネットワークのカーネルに従って、隣接しているＢ－ｒｅｐ要素の特徴ベクトルにより各共辺の特徴ベクトルをコンカチネートするカーネルコンカチネーション（kernel concatenation）を行うように構成される畳み込みユニット（convolution unit）を含む、
－　畳み込みユニットは、さらに、カーネルコンカチネーションに起因する共辺の各々のコンカチネートされた特徴ベクトルを、稠密なニューラルネットワークへの入力として渡すように構成される、
－　畳み込みユニットは、さらに、共辺についての入力されているコンカチネートされた特徴ベクトルに関しての稠密なニューラルネットワークによって出力された各ベクトルに対する、新しい辺特徴ベクトル（edge feature vector）、新しい面特徴ベクトル（face feature vector）、および新しい共辺特徴ベクトル（co-edge feature vector）を計算するように構成される、
－　稠密なニューラルネットワークは、カーネルコンカチネーションに起因する共辺ｃについての入力されているコンカチネートされた特徴ベクトル$\Phi_c^{(i)}$に関して出力し、
【０００６】
【数１】

$$\psi_c^{(i)} = \mathrm{MLP}\left(\phi_c^{(i)}\right) = \left[\ \psi_{CC}^{(i)} \middle| \psi_{CF}^{(i)} \middle| \psi_{CE}^{(i)}\ \right],$$

【０００７】
ただし、$\Psi_{CC}^{(i)}$、$\Psi_{CF}^{(i)}$、$\Psi_{CE}^{(i)}$は、$\Psi_c^{(i)}$の次元が３＊ｈであるような同一の次元ｈを有し、各共辺ｃ、各面Ｆ、および各辺Ｅ、新しい特徴ベクトルは、次のとおりであり、
【０００８】
【数２】

$$\begin{cases} X_c^{(i+1)} = \psi_{CC}^{(i)} \\ X_E^{(i+1)} = \mathrm{MaxPool}\left(\psi_{CE1}^{(i)}, \psi_{CE2}^{(i)}\right) \\ X_F^{(i+1)} = \mathrm{MaxPool}\left(\psi_{CF1}^{(i)}, \ldots, \psi_{CFk}^{(i)}\right) \end{cases}$$

【０００９】
ただし、
○　$X_c^{(i+1)}$は、共辺ｃに対する稠密なニューラルネットワークの出力$\Psi_c^{(i)}$のために計算された新しい共辺特徴であり、
○　$X_E^{(i+1)}$は、辺Ｅに対する計算された新しい辺特徴であり、ただし、$\Psi_{CE1}^{(i)}$および$\Psi_{CE2}^{(i)}$は、２つの関連している共辺の特徴ベクトルに対応し、
○　$X_F^{(i+1)}$は、面Ｆに対する計算された新しい面特徴であり、ただし、$\Psi_{CF1}^{(i)}, \ldots, \Psi_{CFk}^{(i)}$は、ｋ個の関連している共辺の特徴に対応する、
－　ディープＣＡＤニューラルネットワークは、畳み込みユニットを、予め決められた回数繰り返し適用するように構成される、
－　ディープＣＡＤニューラルネットワークは、さらに、面特徴ベクトルのアグリゲーションを行うことによって、大域的な特徴ベクトルを計算するように構成され、アグリゲーションは最大プーリング（Max Pooling）の手法またはアテンションメカニズム（Attention Mechanism）の手法に基づく、
－　ディープＣＡＤニューラルネットワークの学習は、大域的な特徴ベクトルのトポロジカルシグネチャを計算するためにディープＣＡＤニューラルネットワークを訓練する対照学習（contrastive learning）を行うことを含む、
－　対照学習は、次を含むポジティブトランスフォーメーション（positive transformation）に基づく、
○　恒等変換、
○　確率による辺へのランダムなジオメトリの割り当て、
○　確率による面へのランダムなジオメトリの割り当て、
○　確率による面の特徴ベクトルの零との置き換え、
○　確率ｐによる辺の削除、削除は、入力されたＢ－ｒｅｐグラフから面を切り離すならば適用されない、および／または
○　対照学習は、コサイン類似度に基づく正規化温度スケール交差エントロピー損失（normalized temperature-scaled cross entropy loss）を最小にすることを含み、損失は、次のタイプであり、

【００１０】
【数３】

$$L(i,j) = -\log \frac{e^{\mathrm{sim}(Z_i,Z_j)}}{\sum_{k=1}^{2N} 1_{[k\neq i]}\, e^{\mathrm{sim}(Z_i,Z_k)}},$$

【００１１】
ただし、（ｉ，ｊ）は正のペアを表し、（Z_i，Z_j）はディープＣＡＤニューラルネットワークによる正のペアの埋め込みを表し、および、ただし、ｓｉｍは、

【００１２】
【数４】

$$x, y \in \mathbb{R}^h$$

【００１３】
に対して、式

【００１４】
【数５】

$$\mathrm{sim}(x,y) = \frac{x.y}{\|x\|\|y\|} = \frac{\sum_{i=1}^{h} x_i y_i}{\sqrt{\sum_{i=1}^{h} x_i^2}\sqrt{\sum_{i=1}^{h} y_i^2}}$$

【００１５】
により定義されるコサイン類似度である。
【００１６】
さらに、本方法に従って学習可能なニューラルネットワークが、つまり、本方法によって学習されたニューラルネットワークの重みを有するコンピュータに実装されるニューラルネットワークデータ構造が提供される。例えば、提供されるニューラルネットワークは、本方法の学習ステップによって固定された重みにより、本方法によって直に学習されていることがある。
【００１７】
さらに、ニューラルネットワークの使用の方法が提供される。使用の方法は、Ｂ－ｒｅｐを表すＢ－ｒｅｐグラフを取得することを含む。使用の方法は、さらに、ニューラルネットワークをＢ－ｒｅｐグラフに適用することによって、Ｂ－ｒｅｐのトポロジカルシグネチャを取得することを含む。
【００１８】
さらに、方法および／または使用の方法を行うための命令を含むコンピュータプログラムが提供される。
【００１９】
さらに、コンピュータプログラムおよび／またはニューラルネットワークを記録したコンピュータ読取り可能記録媒体が提供される。
【００２０】
さらに、メモリーに結合されたプロセッサーを含むコンピューターシステムが提供され、メモリーは、コンピュータプログラムおよび／またはニューラルネットワークを記録している。
【図面の簡単な説明】
【００２１】
【図１】方法を例示する。
【図２】方法を例示する。
【図３】方法を例示する。
【図４】方法を例示する。
【図５】方法を例示する。
【図６】方法を例示する。
【図７】方法を例示する。
【図８】方法を例示する。
【図９】方法を例示する。
【図１０】方法を例示する。
【図１１】方法を例示する。
【図１２】方法を例示する。
【図１３】方法を例示する。
【図１４】システムの例を示す。
【発明を実施するための形態】
【００２２】
機械学習に関する、コンピュータに実装される方法が提案される。本方法は、Ｂ－ｒｅｐグラフのトレーニングデータセット（training dataset）を取得することを含む。各Ｂ－ｒｅｐグラフは、それぞれのＢ－ｒｅｐを表す。各Ｂ－ｒｅｐグラフは、グラフノードを含み、各々が、それぞれのＢ－ｒｅｐの辺、面、または共辺（co-edge）を表し、１つまたは複数の幾何学的特徴および／または位相幾何学的特徴に関連付けられる。各Ｂ－ｒｅｐグラフは、各々が、それぞれの共辺を表すそれぞれの第１のグラフノードと、それぞれの共辺に関連付けられた面、辺、隣り合う共辺（adjacent co-edge,）、または対をなす共辺（mating co-edge）を表すそれぞれの第２のグラフノードとの間にあるグラフエッジ（graph edge）を含む。本方法は、トレーニングデータセットに基づい

て、ディープＣＡＤニューラルネットワーク（Deep CAD neural network）を学習させることをさらに含む。ディープＣＡＤニューラルネットワークは、Ｂ－ｒｅｐグラフを入力として得て、入力されたＢ－ｒｅｐグラフにより表されるＢ－ｒｅｐのトポロジカルシグネチャを出力するように構成される。本方法は「学習メソッド（learning method）」と呼ばれることがある。

【００２３】

学習メソッドは、ＣＡＤオブジェクト検索のために改良されたソリューションを形成する。

【００２４】

明白に、学習メソッドは、入力として、Ｂ－ｒｅｐグラフを、つまり、製品のＢ－ｒｅｐモデル（すなわち境界表現モデル）のトポロジーをキャプチャするグラフを得て、Ｂ－ｒｅｐのトポロジカルシグネチャを計算するように構成されたディープＣＡＤニューラルネットワークに学習させる。Ｂ－ｒｅｐのトポロジカルシグネチャは、ニューラルネットワークの層による入力されたＢ－ｒｅｐグラフの処理にさらに付け加えられたディープＣＡＤニューラルネットワークによって出力されるベクトルであり、それによって、入力されたＢ－ｒｅｐグラフのベクトル表現を形成する。ただちに、ベクトルは、ディープＣＡＤニューラルネットワークの層が、入力されたＢ－ｒｅｐグラフを処理することによって取得される。グラフは、Ｂ－ｒｅｐの要素（辺、面、共辺）を表すグラフノードと、辺によって連結されたノードによって表される要素の間の位相幾何学的関係を表すグラフエッジとを含むように、Ｂ－ｒｅｐのジオメトリとトポロジーとの両方を表す。さらに、グラフは、基礎をなすＢ－ｒｅｐの位相幾何学的特徴および／または幾何学的特徴、つまり位相幾何学的情報および／または幾何学的情報をカプセル化する特徴ベクトルを含む。入力されたＢ－ｒｅｐグラフは、言い換えると、Ｂ－ｒｅｐのジオメトリおよびトポロジーを記述するデータ構造であり、本方法により学習されるニューラルネットワークは、上記のグラフを入力として得て、Ｂ－ｒｅｐトポロジカルシグネチャを抽出する（ネットワークがそうするように訓練／学習されるので）。言い換えると、学習メソッドは、トポロジーをキャプチャするＢ－ｒｅｐのコンパクトトポロジカルシグネチャベクトル（compact topological signature vector）へＢ－ｒｅｐグラフをエンコードするように構成されたニューラルネットワークに学習させる。

【００２５】

それによって、学習メソッドは、ＣＡＤオブジェクト検索、もしくはＣＡＤオブジェクトの間の類似度評価のために、または、より一般的には、ＣＡＤオブジェクトのトポロジカルシグネチャの使用を通じてＣＡＤオブジェクトのマニピュレーションために用いられることがある。言い換えると、学習されたディープＣＡＤニューラルネットワークは、上記タスクに関して使用可能である。実際、ＣＡＤモデルまたはオブジェクトは、モデルのＢ－ｒｅｐ表現が生成されることがある特徴ツリーによって（すなわち、特徴ツリーを実行することによって）表現された特徴ベースのオブジェクトである。ニューラルネットワークは、上記ＣＡＤモデルの（すなわち具体的にはＢ－ｒｅｐグラフの）トポロジカルシグネチャを見つけるように訓練され、ゆえに、シグネチャの使用を通じてＣＡＤモデルのマニピュレーションを可能にする。例えば、ニューラルネットワークは、２つのＣＡＤモデルを比較し、２つのＣＡＤモデルの間のトポロジー的な類似度を査定するために、２つのＣＡＤモデルのシグネチャを見つけるのに用いられることがある。例えば、今述べたことは、データベースのＣＡＤモデルのトポロジカルシグネチャを既に含むＣＡＤモデルデータベースにおいてＣＡＤモデルを検索するために用いられることがあり、興味の与えられたＣＡＤモデルに関して、学習されたニューラルネットワークは、ＣＡＤモデルのトポロジカルシグネチャを抽出し、今述べたシグネチャに基づいてデータベースに問い合わせるのに用いられることがある。今述べたことは、与えられたＣＡＤモデルの検索に最も近いトポロジカルシグネチャを有するデータベースのＣＡＤモデル（複数可）の検索を可能にする。シグネチャを用いることが、データベースの高速な問い合わせを可能にし、ゆえに、類似するＣＡＤモデルの高速な効率的な検索を可能にするので、上記検索は、ＣＡＤ

モデル設計（すなわち、本方法の下流にて製造されることがある製造製品を表すＣＡＤモデルの設計）の間、位相幾何学的に類似する１つによるＣＡＤモデルの高速な取替えを実行するのに用いられることがある。実際、トポロジカルシグネチャは、メモリー要件（ストレージ、メモリーフットプリント）の観点から、および使用／マニピュレーションの間のＣＰＵリソースの観点から、対応するＢ－ｒｅｐモデルまたはグラフよりもコストがかからないＣＡＤモデルの表現であり、トポロジカルシグネチャを、ＣＡＤモデルについてのＣＰＵ効率のよいおよびメモリー効率のよいマニピュレーションを可能にするコンピュータオブジェクトにする。例えば、シグネチャは、相対的に小さい次元（例えば６４）のベクトルであり得るが、入力されたＢ－ｒｅｐグラフが位相幾何学的に正確であるので依然として良い性能を提供する。言い換えると、それによって、本方法は、メモリーおよびＣＰＵの観点から、マニピュレーションに関してＢ－ｒｅｐ自体よりも効率的である、与えられたＢ－ｒｅｐのコンパクトトポロジカルベクトル表現（compact topological vector representation）を見つけるための機械学習メソッドである。

【００２６】

ゆえに、学習メソッドは、Ｂ－ｒｅｐについてのトポロジー的なオブジェクト検索を効率的におよび一般的に行うフレームワークを提供する。オブジェクト検索は、目標が、類似度に関して、３Ｄオブジェクトデータの検索、順位付け、およびクラスタリングを可能にする効果的な効率的な類似度関数を見つけることであるタスクを意味する。今述べたことは、通常、オブジェクトが、異なった材料特性および機能特性に加え、多くの異なったジオメトリ、構造、トポロジー、および目にみえる外観特性を含むので、困難である。その上さらに、類似度の概念は、目標タスクに依存する領域特有であることがあり、局所的、大域的、位相幾何学的、幾何学的、および／または機能的であることが可能である。位相幾何学的検索は、位相幾何学的情報の類似度に基づくオブジェクト検索を表す。位相幾何学的情報は、頂点、辺、および面の間の関係を提供する。関係に加えて、さらに位相幾何学的情報は、辺の向きおよび面の向きも含む。

【００２７】

その上さらに、本方法は、近似フォーマット（例えば、点群、メッシュ）に変換する必要なく、Ｂ－ｒｅｐモデルを処理するディープラーニングモデルに基づく。本方法は、あらゆる与えられたＢ－ｒｅｐモデルからシグネチャを計算するのに、ニューラルネットワークを用いる。今述べたシグネチャは、近いトポロジーの２つのＢ－ｒｅｐモデルが、近いシグネチャを有するような、入力されたＢ－ｒｅｐモデルのトポロジーにセンシティブである。

【００２８】

さらに、本方法は次を提供する。

－　時間効率：本方法は高速な問い合わせを可能にする、

－　メモリー空間効率：本方法は、Ｂ－ｒｅｐモデルのシグネチャを計算することに依存することによりＣＡＤ検索を可能にし、シグネチャが、メモリー空間要件に関して軽い、

－　データ駆動手法：本方法は、学習するラベルのないＢ－ｒｅｐデータセットをレバレッジすることを可能にする、および

－　自動トポロジー認識検索（automatic topologically-aware retrieval）のためのＢ－ｒｅｐグラフにおけるディープラーニングメソッド。フォーマットによって直接的に作動することの利点は、幾何学的情報のあらゆる損失（近似のために）を、または位相幾何学的情報の廃棄を避けることである。

【００２９】

学習メソッドは機械学習のためのである。

【００３０】

機械学習の分野からそれ自体知られているように、ニューラルネットワークによる入力の処理は、入力に演算を適用することを含み、演算が、重み値を含むデータによって定義される。ゆえに、ニューラルネットワークに学習させることは、上記学習のために構成されたデータセットに基づいて重みの値を決定することを含み、データセットが、もしかす

ると学習データセットまたはトレーニングデータセットと呼ばれる。そのため、データセットは、データ片を含み、各々が、それぞれのトレーニングサンプルを形成する。トレーニングサンプルは、ニューラルネットワークが学習された後に用いられることになる状況の多様性を表す。本明細書におけるトレーニングデータセットはどれでも、１０００、１００００、１０００００、または１０００００００より多い数のトレーニングサンプルを含むことがある。本開示の状況では、「データセットに基づいてニューラルネットワークに学習させること」によって、データセットが、重みの値（「パラメータ」とも呼ばれる）が設定されるニューラルネットワークに基づく、ニューラルネットワークの学習データセット／トレーニングデータセットであることを意味する。

【００３１】

学習メソッドの状況では、学習データセットは、ただちに述べられるＢ－ｒｅｐグラフに関する提供されたデータセットである。データセットについて提供することの議論の前に、含まれたデータ構造が、ただちに述べられる。

【００３２】

「Ｂ－ｒｅｐ」は、「ＢＲｅｐ」とも呼ばれ、「Boundary Representation」を表す。Ｂ－ｒｅｐは、ＣＡＤアプリケーションでは、最も一般的なタイプのモデリングである。Ｂ－ｒｅｐは、数学的に正確な、３Ｄオブジェクトの表現である。今述べた表現は、内部点と外部点との間の境界を定義する、連結された表面要素の集まりとして立体を定義する。Ｂ－ｒｅｐには、位相幾何学的構成要素と、それらの構成要素の幾何学的定義についての２種類の情報がある。位相幾何学的構成要素は、３Ｄオブジェクトの表面を定義する頂点、辺、および面、ならびにそれらの間の連結を含む。連結性に加えて、さらに、位相幾何学的情報は、辺および面の向きも含み、一方、幾何学的情報は、通常、頂点、辺、および面（それぞれ、点、曲線、および曲面）を記述する数理的な方程式からなる。

【００３３】

Ｂ－ｒｅｐ（すなわち、境界表現）は、機械部品の３Ｄ表現である。具体的には、Ｂ－ｒｅｐは、機械部品を表す３Ｄモデリングされたオブジェクトを記述する永続的なデータ表現である。Ｂ－ｒｅｐは、機械部品を表す３Ｄモデリングされたオブジェクトの設計段階で実行された計算および／または一連の操作の結果であり得る。モデリングされたオブジェクトを表現する際にコンピュータの画面に表示される機械部品の形状は、（例えば、Ｂ－ｒｅｐのテッセレーション）である。例では、Ｂ－ｒｅｐはモデルオブジェクトの一部を表している。

【００３４】

Ｂ－Ｒｅｐは、位相幾何学的エンティティおよび幾何学的エンティティを含む。位相幾何学的エンティティは、面、辺、および頂点である。幾何学的なエンティティは、表面、平面、曲線、ライン、点などの３Ｄ物体である。定義によると、面は、支持面という名の表面の境界部分である。辺は、曲線の境界部分であり、支持曲線と呼ばれる。頂点は、３Ｄ空間における点である。これらは次のように互いに関係される。曲線の境界部分は、曲線上にある２点（頂点）で定義される。表面の境界部分は、表面上にある辺の集合である境界によって定義される。面の辺の境界は、頂点を共有することによって連結される。面は、辺を共有することによって連結される。２つの面は、辺を共有するならば隣り合う。同様に、２つの辺は、頂点を共有するならば隣り合う。ＣＡＤシステムでは、Ｂ－Ｒｅｐは、「によって境界される」関係、位相幾何学的エンティティとサポートジオメトリ（supporting geometry）との関係、およびサポートジオメトリの数学的記述を適切なデータ構造で収集する。Ｂ－Ｒｅｐの内部の辺は、ちょうど２つの面が共有する辺である。定義によると、境界の辺は共有されず、１つの面にのみ接する。定義によると、境界面は、少なくとも１つの境界辺によって囲まれている。Ｂ－Ｒｅｐは、そのすべての辺が内部の辺である場合、閉じているという。Ｂ－Ｒｅｐは、少なくとも１つの境界の辺を含んでいれば、開いているという。閉じているＢ－ｒｅｐは、空間を（仮想的に）囲む材料の内側部分を定義するため、厚みのある３Ｄボリュームをモデリングするために用いられる。開いているＢ－ｒｅｐは、厚さが無視されるほど十分小さい３Ｄオブジェクトを表す、３

Ｄスキンをモデリングするのに用いられる。

【００３５】

ＣＡＤモデリングにおいて用いられる他の表現タイプを超えたＢ－ｒｅｐの重要な利点は、任意の形状を正確に表す能力である。たとえば、点群、距離場およびメッシュなど、用いられている他のすべての表現は、離散化によって表現する形状の近似を行う。一方、Ｂ－Ｒｅｐは、正確なデザインを表す表面方程式を含み、それゆえ、今述べたことが、ＣＮＣ用のツールパスの生成であるか、与えられた３Ｄプリンター技術に対して正しいサンプル密度への離散化するかどうかなど、さらなる製造のための真の「マスターモデル」を構成する。言い換えると、Ｂ－ｒｅｐを用いることによって、３Ｄモデルは、製造される物体の正確な表現であり得る。さらに、Ｂ－Ｒｅｐは、３Ｄモデルの挙動をシミュレーションするのにも有利である。応力、熱、電磁波などの解析においては、物理現象を捉えるためのシミュレーションメッシュの局所的な細分化をサポートし、キネマティクスにおいては、曲面間の真の接触モデリングをサポートすることが可能である。最後に、Ｂ－Ｒｅｐは、小さいメモリーおよび／またはファイルフットプリント（file footprint）を可能にする。第１に、表現が、パラメータのみに基づく曲面を含むからである。たとえばメッシュなどの他の表現では、同等な表面は最大で数千の三角形で含む。第２に、Ｂ－ｒｅｐは、履歴に基づく情報を含まないからである。

【００３６】

本明細書では、頂点、面、および辺のほかに、各Ｂ－ｒｅｐは共辺も含む。共辺は、向き付けられた辺、すなわち、追加の向きの情報を有するＢ－ｒｅｐの辺である。それによって、共辺は、Ｂ－Ｒｅｐの面の周りの順序付けと、面の隣接とを定義する、すなわち、Ｂ－ｒｅｐのトポロジーを定義する。共辺は、Ｂ－ｒｅｐエンティティを完全にリンクさせる。各共辺は、１つの親面（すなわち、境界を定義する面）と、１つの親辺（すなわち、定義により、共辺が、向き付けられた向辺であり、ゆえに親辺を有する）と、同一の親辺を有する共辺である１つの片方の共辺と、共辺が属するループにおける次の共辺に対応する１つの次の共辺と、共辺が属するループにおける前の共辺に対応する１つの前の共辺とを有する。各共辺は、親面の周りの次の共辺および前の共辺、隣り合う面の対をなす共辺、親面、ならびに親辺との隣接関係を維持する。図１は、立方体の２つの面（Ｆ：Face（面）、Ｅ：Edge（辺）、Ｃ：co-edge（共辺）、Ｎ：Next interaction（ネクストインタラクション）、Ｍ：Mate Interaction（メートインタラクション）、ＰＦ：Parent Face（親面）、ＰＥ：Parent Edge（親辺））に関して他のエンティティとの共辺のインタラクション（interaction）の例を例示する。

【００３７】

本明細書における各Ｂ－ｒｅｐグラフは、それぞれのＢ－ｒｅｐのグラフ表現であり、グラフノードおよびグラフエッジを含む。各グラフノードは、それぞれのＢ－ｒｅｐのそれぞれの辺、それぞれの面、またはそれぞれの共辺を表す。今述べたことは、Ｂ－ｒｅｐの各辺に対してそれぞれのグラフノードがあり、Ｂ－ｒｅｐの各面に対してそれぞれのグラフノードがあり、Ｂ－ｒｅｐの各共辺に対してそれぞれのグラフノードがあることを意味する。各グラフノードはさらに、グラフノードに関連付けられた（すなわちグラフノードに所属している）幾何学的特徴および／または位相幾何学的特徴を含む。特徴は、ノードに関連付けられたデータであり、グラフノードによって表されるＢ－ｒｅｐ要素を特徴付ける幾何学的データおよび／または位相幾何学的データを記述するデータであり、例えばベクトル（特徴ベクトルとも呼ばれる）である。以下に、表１は、各Ｂ－ｒｅｐ－ｅｎｔｉｔｙ（辺、共辺、または面）に対して、本方法の例に従って、対応するグラフノードに所属している特徴ベクトルに含まれる幾何学的および／または位相幾何学的要素の名前のリストを、各幾何学的および／または位相幾何学的要素に対する要素の説明とともに示す。括弧の間の数字は、対応するベクトルの次元（dimension）を示す。

【００３８】

【表１】

エンティティ	名前	説明
辺（１５）	ジオメトリのタイプ（５）	辺のタイプ（線、円、楕円、Ｂ－スプライン、交わり曲線）を示すワンホットベクトル
	閉ループ（１）	辺が面に面自体の境界をつけるならば真に設定されるブーリアン
	線長（１）	線の長さ（線でなければ０）
	円半径（１）	円のエッジの半径（円でなければ０）
	楕円軸（２）	楕円の長軸および短軸（楕円でなければ０）
	平面と平面との凸面（３）	２つの平面の間のエッジの場合、エッジが凹か凸かを示す
	Ｂ－スプライン度および制御点（２）	エッジがＢ－スプラインであるならば、Ｂ－スプライン度、およびＢ－スプラインを制御する制御点の数
共辺（１）	方向フラグ（１）	共辺が親辺と同一の向きを有するかどうかを示す
面（８）	ジオメトリの種類（５）	面のタイプ（平面、球面、円柱面、トレ、Ｂ－スプライン）を示すワンホットベクトル
	Ｂ－スプラインおよび制御点（３）	面がＢ－スプラインであるならば、（パラメータの次元ｕおよびｖの両方の）Ｂ－スプライン度、および制御点の数

表１：幾何学的および／または位相幾何学的特徴ベクトルの例

【００３９】

表１により例示される上の例における特徴は、ＣＡＤモデルの回転および平行移動に対して不変である。図２は、幾何学的特徴と位相幾何学的特徴とのもつれのほぐしを例示し、幾何学的にはとても類似するが、位相幾何学的には大きく異なった２つのＢ－ｒｅｐモデルを示す。

【００４０】

さらにグラフは、グラフエッジも含む。各それぞれのグラフエッジは、２つのそれぞれのグラフノード、それぞれの第１のノードおよびそれぞれの第２のノードを連結する。第１のグラフノードは、それぞれの共辺を表す。第２のグラフノードは、次のうちの１つを表す。

－　それぞれの共辺に関連付けられた面（すなわち、共辺の親面、つまり、境界を定義する面）、

－　辺（すなわち、共辺の親辺）、

－　隣り合う共辺（すなわち、次の共辺または前の共辺、つまり、共辺が属するループにおける次の共辺または前の共辺）、または

－　対をなす共辺（すなわち、同一の親辺を有する共辺）。

【００４１】

トレーニングデータセットを取得することは、トレーニングデータセットを作成すること、つまり、Ｂ－ｒｅｐグラフを作成することまたは生成することを含む。Ｂ－ｒｅｐグラフを作成すること／生成することは、次を含むことがある。

－　ＳＴＥＰファイルであり得る、Ｂ－ｒｅｐファイル（例えば、既に設計されたＣＡＤモデルの）としてエンコードされたＢ－ｒｅｐを取得すること（例えば、（例えば、遠くの）メモリーまたはサーバーまたはＢ－ｒｅｐデータベースから検索することまたはダウ

ンロードすること）、
－　グラフノードがＢ－ｒｅｐの位相幾何学的構成要素であり、辺がそれらの間のインタラクションを表す、初期Ｂ－ｒｅｐグラフにＢ－ｒｅｐファイルを（いずれかの既知の方法により）変換すること、
－　Ｂ－ｒｅｐファイルから幾何学的パラメータを抽出し、位相幾何学的特徴および／または幾何学的特徴を計算すること、および
－　計算された特徴を初期Ｂ－ｒｅｐグラフに統合することによって、トレーニングデータセットのＢ－ｒｅｐグラフを形成すること。

【００４２】

あるいは、トレーニングデータセットを取得することは、Ｂ－ｒｅｐグラフを（例えば、遠くの）メモリーまたはサーバーまたはデータベースから取得することまたはダウンロードすることを含むことがある。

【００４３】

トレーニングデータセットについて取得することにさらに付け加えて、次に、本方法は、トレーニングデータセットに基づくディープＣＡＤニューラルネットワークの学習を含む。学習は、方法が、トレーニングデータセットのＢ－ｒｅｐグラフをニューラルネットワークへの入力としてフィードし、ニューラルネットワークが十分に満足のいく出力を出力しない限り（例えば適切な収束基準に関して、例えば損失最適化に関して）、ニューラルネットワークの重みを修正することを意味する。入力されたＢ－ｒｅｐグラフに対する、ニューラルネットワークの出力は、Ｂ－ｒｅｐグラフにより表されるＢ－ｒｅｐのトポロジカルシグネチャである。トポロジカルシグネチャは、ニューラルネットワークが、入力されたＢ－ｒｅｐに関して出力する埋め込みベクトルであり、基礎をなすＢ－ｒｅｐのトポロジーをキャプチャする。

【００４４】

ディープＣＡＤニューラルネットワークはディープニューラルネットワークであり、ＤＮＮとも呼ばれる。ＤＮＮは、観測データから学習させることをコンピュータに可能にするバイオロジカリーインスパイヤード・プログラミング・パラダイム（biologically-inspired programming paradigm）であるニューラルネットワークにて学習させるための技法の強力なセットである。物体認識において、ＤＮＮの成功は、他の手法（ｍｉｎ－ｃｕｔ、ＳＶＭ、ブースティング、ランダムフォレストなど）において用いられる手により設計される低いレベルの特徴（Ｚｅｒｎｉｋｅモーメント、ＨＯＧ、Ｂａｇ－ｏｆ－Ｗｏｒｄｓ、ＳＩＦＴなど）とは対照的に、リッチな中間レベルのメディア表現を学習する能力による。より具体的には、ＤＮＮは、生データに基づくエンドツーエンドの学習に焦点を合わせる。言い換えると、生の特徴から始まりラベルに終わるエンドツーエンドの最適化を達成することにより、特徴工学から可能な限り極大の範囲へ離れる。ＤＮＮのことは、参考文献D. E. Rumelhart、G. E. Hinton、R. J. Williams、「Learning internal representations by error propagation, Parallel distributed processing: exploreorations in microstructure of cognition」、第１巻：foundations、MIT Press、ケンブリッジ、ＭＡ、１９８６年に述べられ、参照により本明細書に組み入れられる。

【００４５】

ディープＣＡＤニューラルネットワークは、例えば、参照により本明細書に組み入れられる参考文献T. N. Kipf およびM. Welling、「Semi-Supervised Classification with Graph Convolutional Networks」、２０１６年に述べられるような、古典的なグラフ畳み込みネットワークのアーキテクチャを有することがある。アーキテクチャは、ディープＣＡＤニューラルネットワークの入力データがグラフであるので、特に適応する。上記のモデルの標準的な目的は、グラフの各ノードに対する埋め込みベクトルを計算することである。今述べたモデルは、通常、メッセージパッシングに基づき、グラフのノードを記述する埋め込みベクトルを計算するために、各ノードは、近傍から前の特徴ベクトルを収集し、ディープラーニングネットワークに渡す。ディープＣＡＤニューラルネッ

トワークアーキテクチャは、具体的には、参照により本明細書に組み入れられる参考文献J. G. Lambourne、K. D. Willis、P. K. Jayaraman、A. Sanghi、P. Meltzer、およびH. Shayani、「BRepNet：A topological message passing system for solid models」ＣＶＰＲ ２０２１に提案されたものであり、古典的なグラフ畳み込みネットワーク（先に引用した文献T. N. KipfおよびM. Welling、「Semi-Supervised Classification with Graph Convolutional Networks」、２０１６年に述べられるような）と同じ原理に基づくディープラーニングモデルであるが、共辺のトポロジカルインタラクション（topological interaction）に基づくメッセージパッシングを有する。

【００４６】

ディープＣＡＤニューラルネットワークは、メッセージパッシングが起こるニューラルネットワークの層である、畳み込みユニットを含むことがある。畳み込みユニットは、カーネルコンカチネーションを行うように構成される。カーネルコンカチネーション（kernel concatenation）は、ニューラルネットワークのカーネルに従って、隣接しているＢ－ｒｅｐ要素の特徴ベクトルにより各共辺の特徴ベクトルをコンカチネートする。機械学習の分野においてそれ自体知られているように、カーネルは、ニューラルネットワークが入力の特徴をコンカチネートすることに従う特定のウォークであり、特徴は、本明細書では、位相幾何学的特徴および／または幾何学的特徴である。カーネルは、今述べたウォークに従って、各共辺の特徴を近傍の特徴とコンカチネートする。カーネルウォークは、５つの次の初歩のウォーク操作、次の共辺、前の共辺、片方の共辺、親面、および親辺の組み合わせであり得る。図３は、今述べた操作（ＰＥ：親辺、ＰＦ：親面、Ｎ：次、Ｐ：前、Ｍ：片方、Ｃ：共辺、Ｅ：辺、Ｆ：面）を例示する。最後の２つのウォーク操作は、共辺でないエンティティの上で終わるので、終わらせる。カーネルは、｛Ｉ，Ｎ，Ｐ，Ｍ，ＰＥ，ＰＦ｝であり得る、すなわち、各共辺は、現在の特徴ベクトルを、次の共辺、前の共辺、片方の共辺、親辺、および親面の現在の特徴ベクトルとコンカチネートし、（各共辺Ｃに対する）次のコンカチネートされた特徴ベクトルに帰着する。

【００４７】

【数６】

$$\phi_c^{(i)} = \left[X_c^{(i)} \middle| X_N^{(i)} \middle| X_P^{(i)} \middle| X_M^{(i)} \middle| X_{PE}^{(i)} \middle| X_{PF}^{(i)} \right]$$

【００４８】

ただし、$X_k^{(i)}$は、ステップｉにおけるエンティティｋの特徴ベクトルである。

【００４９】

畳み込みユニットは、さらに、カーネルコンカチネーションに起因する共辺の各々のコンカチネートされた特徴ベクトルを、稠密なニューラルネットワークへの入力として渡すように構成されることがある。稠密なニューラルネットワークは、ＭＬＰ（Multi-Layer Perception）であるディープニューラルネットワークである。稠密なネットワークは、（各共辺ｃに関して）次を出力することがある。

【００５０】

【数７】

$$\psi_c^{(i)} = \mathrm{MLP}\left(\phi_c^{(i)}\right) = \left[\psi_{CC}^{(i)} \middle| \psi_{CF}^{(i)} \middle| \psi_{CE}^{(i)} \right]$$

【００５１】

ただし、$\Psi_{CC}^{(i)}$、$\Psi_{CF}^{(i)}$、$\Psi_{CE}^{(i)}$は、$\Psi_c^{(i)}$の次元が３＊ｈであるような同一の次元ｈを有する。

【００５２】

畳み込みユニットは、さらに、共辺についての入力されているコンカチネートされた特徴ベクトルに関しての稠密なニューラルネットワークによって出力された各ベクトルに対

する、新しい辺特徴ベクトル（edge feature vector）、新しい面特徴ベクトル（face feature vector）、および新しい共辺特徴ベクトル（co-edge feature vector）を計算するように構成されることがある。例えば、稠密なニューラルネットワークは、カーネルコンカチネーションに起因する共辺ｃについての入力されているコンカチネートされた特徴ベクトルΦ$_{c}^{(i)}$に関して出力することがある。

【００５３】

【数８】

$$\psi_c^{(i)} = \mathrm{MLP}\left(\phi_c^{(i)}\right) = \left[\ \psi_{CC}^{(i)} \middle| \psi_{CF}^{(i)} \middle| \psi_{CE}^{(i)}\ \right],$$

【００５４】

ただし、Ψ$_{CC}^{(i)}$、Ψ$_{CF}^{(i)}$、Ψ$_{CE}^{(i)}$は、Ψ$_{c}^{(i)}$の次元が３＊ｈであるような同一の次元ｈを有する。次に、各共辺ｃ、各面Ｆ、および各辺Ｅに対する新しい特徴ベクトルは、次であり得る。

【００５５】

【数９】

$$\begin{cases} X_c^{(i+1)} = \ \psi_{CC}^{(i)} \\ X_E^{(i+1)} = \mathrm{MaxPool}(\ \psi_{CE1}^{(i)},\ \psi_{CE2}^{(i)}) \\ X_F^{(i+1)} = \ \mathrm{MaxPool}(\ \psi_{CF1}^{(i)}, \ldots,\ \psi_{CFk}^{(i)}) \end{cases}$$

【００５６】

ただし、

- Ｘ$_{c}^{(i+1)}$は、共辺ｃに対する稠密なニューラルネットワークの出力Ψ$_{c}^{(i)}$のために計算された新しい共辺特徴であり、
- Ｘ$_{E}^{(i+1)}$は、辺Ｅに対する計算された新しい辺特徴であり、ただし、Ψ$_{CE1}^{(i)}$およびΨ$_{CE2}^{(i)}$は、２つの関連している共辺の特徴ベクトルに対応し、
- Ｘ$_{F}^{(i+1)}$は、面Ｆに対する計算された新しい面特徴であり、ただし、Ψ$_{CF1}^{(i)}$，．．．，Ψ$_{CFk}^{(i)}$は、ｋ個の関連している共辺の特徴に対応する。

【００５７】

新しい特徴ベクトルの計算は、今述べた計算が、面および辺のエンティティの新しい特徴を取得するために、以前に計算された（すなわち、共辺レベルで）特徴ベクトルをプールするので、「エンティティプーリング（Entity pooling）」と呼ばれることがある。今述べた計算が、エンティティによりプーリングのために用いられる中間ベクトルを分離するという事実は、学習されるニューラルネットワークが、エンティティの各タイプに対する固有の特徴を学習するのに役立つ。

【００５８】

畳み込みユニットの終りに、それによって、出力は、各エンティティに所属している新しい特徴ベクトルを有する、依然としてグラフであり得る。ディープＣＡＤニューラルネットワークは、畳み込みユニットを、予め決められた回数、例えば少なくとも３回、例えば３回繰り返し適用するように構成されることがある。言い換えると、本方法は、複数の畳み込みユニットを次々とスタックすることがある。ちょうどコンピュータビジョンにおいて畳み込み層をスタックすることがモデルの受容野を増やすように、畳み込みユニットをスタックすることは、各共辺が、その近傍のより広い部分を見るのに役立ち、ゆえに、より大域的な特徴および／またはより複雑な特徴をキャプチャするのに役立つことが可能である。

【００５９】

ディープＣＡＤニューラルネットワークは、畳み込みユニットアプリケーション（複数可）に起因する面特徴ベクトルのアグリゲーションを行うことによって、大域的な特徴ベクトルを計算するようにさらに構成されることがある。今述べた計算は「グローバルプー

リング（global pooling）」と呼ばれる。大域的な特徴ベクトルの今述べた計算は、各ノードエンティティが埋め込みベクトルを有するグラフから単一の埋め込みを生成できるので、入力ＣＡＤモデルに対する単一のシグネチャを返すディープＣＡＤニューラルネットワークの目的にかなうことを可能にする。各面がＢ－ｒｅｐグラフにおいて共辺のセットに連結されるので、グローバルプーリングは、面特徴をアグリゲーションするだけであり、十分である。上記のように、それによって、辺または共辺よりも、局所的な近傍のより多くの情報を集めることができる。

【００６０】

アグリゲーションは、マックスプーリング手法／戦略に基づくことがある、すなわち、アグリゲーションは、面を介してマックスプーリング戦略／手法を用いることがある。マックスプーリングは、下記のように実装されることがある。Z_gを、グローバル入力されたＢ－ｒｅｐ－ｇｒａｐｈの埋め込み、$Z_F^{(k)}$を、ディープＣＡＤニューラルネットワークの最後の畳み込み層により出力される面（ｋ）の埋め込みとおく。次に、マックスプーリングは、次のようにZ_gを計算することからなることがある。

【００６１】

【数１０】

$$Z_F^{(k)} \in \mathbb{R}^h$$

【００６２】

に対して、

【００６３】

【数１１】

$$Z_g = \mathrm{MaxPool}\left(Z_F^{(1)}, Z_F^{(2)}, \ldots, Z_F^{(K)}\right) \in \mathbb{R}^h$$

【００６４】

ただし、ｈは面の埋め込み次元である。

【００６５】

あるいは、アグリゲーションは、アテンションメカニズムメソッドに基づくことがある。上記のメソッドは、参照により本明細書に組み入れられる参考文献Ｍ．Ｉｌｓｅ、Ｊ．Ｍ．Ｔｏｍｃｚａｋ、およびＭ．Ｗｅｌｌｉｎｇ、「Attention-based Deep Multiple Instance Learning」、２０１８年に述べられ、今述べた代替のアグリゲーション戦略は、モデルに追加の学習モジュールを導入する。プーリングは、今述べた場合では、面の埋め込み（$Z_F^{(1)}, \ldots, Z_F^{(K)}$）の加重平均である。

【００６６】

【数１２】

$$Z_g = \sum_{k=1}^{K} a_k \, Z_F^{(k)}$$

【００６７】

重み（$a_1, \ldots, a_K$）は、ニューラルネットワークによって計算される。

【００６８】

【数１３】

$$a_k = \frac{e^{w^T \tanh\left(V \, Z_F^{(k)^T}\right)}}{\sum_{i=1}^{K} e^{w^T \tanh\left(V \, Z_F^{(i)^T}\right)}}$$

【００６９】

ただし、ｗ∈ユークリッド空間Ｒ^{ｈｘ１}、Ｖ∈ユークリッド空間Ｒ^{ｈｘｈ}は、学習されたパラメータである。

【００７０】

両方の戦略は、入力が、まったく異なった数のノードまたは辺を有することが可能である課題に対処することを可能にする。図４は、２つの戦略を例示する（Ｆ：面、Ｃ：共辺、Ｅ：辺）。図５は、グローバルプーリングが行われる前に、３つの畳み込みユニットが連続して適用される、ディープＣＡＤニューラルネットワークのグローバルアーキテクチャの例を示す。各畳み込みユニットは、カーネルコンカチネーション、多層パーセプトロン（Multi-Layer Perceptron；ＭＬＰ）の適用、およびエンティティプーリングを行う。

【００７１】

ディープＣＡＤニューラルネットワークの学習は、大域的な特徴ベクトルのトポロジカルシグネチャを計算するためにディープＣＡＤニューラルネットワークを訓練する対照学習（contrastive learning）を行うことを含むことがある。事実確認的学習（constative learning）は、Ｂ－ｒｅｐグラフがラベル付けされない、またはグラフが由来するＢ－ｒｅｐモデルがラベル付けされない場合を取り扱うことを可能にする。対照学習の概念は、参照により本明細書に組み入れられる参考文献T. Chen、S. Kornblith、M. Norouzi、およびG. E. Hinton、「A Simple Framework for Contrastive Learning of Visual Representations」２０２０から知られており、本方法にて実装されるために適合される。

【００７２】

元の論文（T. Chen、S. Kornblith、M. Norouzi、およびG. E. Hinton、「A Simple Framework for Contrastive Learning of Visual Representations」２０２０）では、フレームワークは、図６に例示されるように、対照学習パラダイムを用いて、教師なしのやり方にて画像の埋め込みを学習することを提案する。目標は、たとえば、近い埋め込みベクトルを有する２つの類似の入力（正のペア）と、遠い埋め込みベクトルを有する異なる出力（負のペア）など、訓練データの表現に富む潜在表現を学習することである。しかしながら、訓練データがラベル付けされないならば、正のペアおよび負のペアは、最初にアクセスできない。対照学習パラダイムは、データ拡張技法を介して、今述べたペアを合成的に作成することで、今述べた制限を回避する。具体的には、各入力データは、同一の入力についての２つの変換が正のペアを構成し、そうでなければ負のペアを構成するために、図６（ステップ１））に例示されるようなランダムな変換を受ける。例えば、画像データセットへの適用のために、たとえばランダムなカラーシフトおよびランダムなトリミングなどの古典的な画像変換が選択されることがある。

【００７３】

本方法の対照学習は、次を含むポジティブトランスフォーメーションに基づくことがある。

－　恒等変換、
－　確率ｐによる辺のランダムなジオメトリの割り当て（例えば、線が楕円になる）、
－　確率ｐによる面のランダムなジオメトリの割り当て（例えば、平面が円筒面になる）、
－　確率ｐによる面の特徴ベクトルの零との置き換え、および
－　確率ｐによる辺の削除、削除は、入力されたＢ－ｒｅｐグラフから面を切り離すならば適用されない

言い換えると、今述べた変換は、事実確認的学習フレームワークのペアを生成するために用いられる変換であり得る。今述べたことは、本方法により考慮された特定の入力（Ｂ－ｒｅｐグラフ、おそらくラベルのない）に関して、ポジティブトランスフォーメーションが特定の入力データ型に適応されるので、対照学習フレームワークを実装することを可能にする。すべての変換は、グラフのトポロジーを保持し、学習されたネットワークを、トポロジー的な類似度をキャプチャすることに導く。

【００７４】

対照学習は、コサイン類似度に基づく正規化温度スケール交差エントロピー損失（normalized temperature-scaled cross entropy loss）を最小にすることを含みことがあり、損失は、次のタイプであり、

【００７５】

【数１４】

$$L(i,j) = -\log \frac{e^{sim(Z_i,Z_j)}}{\sum_{k=1}^{2N} 1_{[k\neq i]}\, e^{sim(Z_i,Z_k)}},$$

【００７６】

ただし、（ｉ，ｊ）は正のペアを表し、（Z_i，Z_j）はディープＣＡＤニューラルネットワークによる正のペアの埋め込みを表し、および、ただし、ｓｉｍは、

【００７７】

【数１５】

$$x, y \in \mathbb{R}^h$$

【００７８】

に対して、式

【００７９】

【数１６】

$$sim(x,y) = \frac{x.y}{\|x\|\|y\|} = \frac{\sum_{i=1}^{h} x_i y_i}{\sqrt{\sum_{i=1}^{h} x_i^2}\sqrt{\sum_{i=1}^{h} y_i^2}}$$

【００８０】

により定義されるコサイン類似度である。損失は、ミニバッチトレーニング（mini-batch training）によるミニバッチに用いられ、ただし、Ｎがミニバッチのサイズである。ゆえに、（ペアを含む）拡張されたバッチは、２Ｎ個の要素を有する。拡張されたバッチは、（図６のステップ２）におけるような）埋め込みを計算するディープＣＡＤニューラルネットワークに渡される。（図６のステップ３）に例示されるような）ニューラルネットワークの目的は、埋め込みとその正のペアとの間の類似度を最大化し、その他の２（Ｎ－１）個の埋め込みの間の類似度を最小化することである。類似度関数はコサイン類似度である。上述の式において、

【００８１】

【数１７】

$$(i,j)$$

【００８２】

は、サイズ２Ｎの拡張されたバッチにおける正のペアを表す。

さらに、本方法に従って学習可能なニューラルネットワークが、つまり、本方法によって学習されたニューラルネットワークの重みを有するコンピュータに実装されるニューラルネットワークデータ構造が提供される。例えば、提供されるニューラルネットワークは、本方法の学習ステップによって固定された重みにより、本方法によって直に学習されていることがある。

【００８３】

さらに、ニューラルネットワークの使用の方法が提供される。使用の方法は、Ｂ－ｒｅｐを表すＢ－ｒｅｐグラフを取得することを含む。使用の方法は、さらに、ニューラルネットワークをＢ－ｒｅｐグラフに適用することによって、Ｂ－ｒｅｐのトポロジカルシグネチャを取得することを含む。

【００８４】
使用の方法は、ＣＡＤモデルの間の類似度サーチに関して、およびＣＡＤオブジェクト検索に関してであり得る。実際、学習されたニューラルネットワークは、入力されたＢ－ｒｅｐ（ＣＡＤ）オブジェクトからトポロジカルシグネチャを生成する。今述べたシグネチャは、位相幾何学的情報を埋め込む。上記のように、位相幾何学的に類似するＣＡＤモデル（Ｂ－ｒｅｐｓ）は、高いシグネチャ類似度を有する、または有する傾向がある。
【００８５】
使用の方法は、２つのＣＡＤモデルの間の位相幾何学的類似度サーチに関してであり得る。今述べた場合では、使用の方法は、次を含むことがある。
－　第１のＢ－ｒｅｐの第１のＢ－ｒｅｐグラフと第２のＢ－ｒｅｐの第２のＢ－ｒｅｐグラフとを提供すること、
－　ニューラルネットワークを第１のＢ－ｒｅｐグラフにおよび第２のＢ－ｒｅｐグラフに適用することによって、第１のＢ－ｒｅｐの第１のトポロジカルシグネチャおよび第２のＢ－ｒｅｐの第２のトポロジカルシグネチャを取得すること、ならびに
－　２つのシグネチャの間の類似度を評価すること。
【００８６】
使用の方法は、位相幾何学的類似度サーチを通じたデータベースのＣＡＤオブジェクト検索に関してであり得る。今述べた場合では、使用の方法は、次を含むことがある。
－　次を提供すること、
　○　与えられたＢ－ｒｅｐの与えられたＢ－ｒｅｐグラフ、
　○　データベースの各Ｂ－ｒｅｐおよび／またはＣＡＤモデルが、そのトポロジカルシグネチャ（すなわち、既に計算されたもの、例えば、ニューラルネットワークを用いて以前に計算されたもの）に関連付けられている、Ｂ－ｒｅｐに関連付けられたＢ－ｒｅｐおよび／またはＣＡＤモデルのデータベース、
－　与えられたＢ－ｒｅｐグラフにニューラルネットワークを適用することによって、与えられたＢ－ｒｅｐのシグネチャを取得すること、
－　与えられたＢ－ｒｅｐのシグネチャによりデータベースに問い合わせること、および
－　データベースの各Ｂ－ｒｅｐおよび／またはＣＡＤモデルに関して、与えられたＢ－ｒｅｐのシグネチャとデータベースのＢ－ｒｅｐおよび／またはＣＡＤモデルのシグネチャとの間の類似度を評価すること。
【００８７】
使用の方法のすべての上述の例では、Ｂ－ｒｅｐのグラフを提供することは、学習メソッドにおけるトレーニングデータセットの提供のために本明細書にて述べられるようなＢ－ｒｅｐグラフを生成することを含むことがある。データベースを提供することは、モデルのＢ－ｒｅｐグラフにディープＣＡＤニューラルネットワークを適用することによって、データベースのモデルの少なくともいくつか（例えば、すべて）のトポロジカルシグネチャを取得することを含むことがある（データベースの提供は、生成することを含むことがある）。シグネチャと別のシグネチャとの間の類似度を評価することは、２つのシグネチャの間のコサイン類似度を計算することを含むことがある。２つのシグネチャベクトル
【００８８】
【数１８】
X

【００８９】
および
【００９０】
【数１９】
Y

【００９１】
の間のコサイン類似度は、次のコサイン類似度関数により計算される。
【００９２】
【数２０】

$$\mathrm{sim}(x,y) = \frac{x.y}{\|x\|\|y\|} = \frac{\sum_{i=1}^{h} x_i y_i}{\sqrt{\sum_{i=1}^{h} x_i^2}\sqrt{\sum_{i=1}^{h} y_i^2}}.$$

【００９３】
２つのシグネチャの間の類似度を計算することは非常に速いので、結果は、非常に短い時間量にてユーザーに与えられることが可能である。
【００９４】
図７は、１５０ｋ個の産業機械（ネジ、ナット、ノブ、または同類のもの）のデータベースのトレーニングをされた、産業機械データセットのおよび学術データセットのテストをされたディープＣＡＤニューラルネットワークから取得された結果の例を示し、（参照により本明細書に組み入れられる参考文献P. K. Jayaraman、A. Sanghi、J. G. Lambourne、K. D. Willis、T. Davies、H. Shayani、およびN. Morris、「UV-Net：Learning from Boundary Representations」CVPR2021に述べられる）アルファベット大文字のソリッドレターが、それぞれ、上３行および下３行に表示される。各オブジェクトの上の数字は、入力シグネチャとの類似度である。図７は、オブジェクト自体がデータベースに属すると、最も類似したオブジェクトがオブジェクト自体であることを例示する。先に引用した文献P. K. Jayaraman、A. Sanghi、J. G. Lambourne、K. D. Willis、T. Davies、H. Shayani、およびN. Morris、「UV-Net：Learning from Boundary Representations」CVPR2021に述べられる幾何学的検索と比較して、類似モデルが同一の文字カテゴリに属する場合、位相幾何学的検索は、むしろグラフ情報（構造および要素の特徴）に関して類似したオブジェクトを抽出する。
【００９５】
学習メソッドと使用の方法とは、最初に学習メソッドを行い（今述べたステップは「オフラインステージ」と呼ばれることがある）、次に使用の方法を行う（今述べたステップは「オンラインステージ」と呼ばれることがある）ことを含む同一のＣＡＤオブジェクトの検索処理において実装されることがある。図８および図９は、上記処理の例のフローチャートを示す。処理は、今述べた図面に例示され、次のオフラインステージおよびオンラインステージを含む。
－　オフラインステージ：ステージは、製造Ｂ－ｒｅｐオブジェクトを用いてモデルをトレーニングすることに向けられる。ステージは、ユーザーからトランスペアレントであり得る。
【００９６】
○　トレーニングＢ－ｒｅｐグラフ生成は、生のＢ－ｒｅｐトレーニングファイルから、グラフのノードがすべての位相幾何学的構成要素であり、辺がそれらの間のインタラクションを表すグラフへの変換パイプラインを実装することを表す。データ解析は、幾何学的の抽出と、異なったコンポーネントに対する特徴計算とを含む、
○　ニューラルネットワークモデルは、トレーニングＢ－ｒｅｐグラフに基づいて学習される。Ｂ－ｒｅｐ　ＤＮＮベースのモデルからなる、
－　オンラインステージ：Ｂ－ｒｅｐファイルおよびデータベースが与えられ、データは、対応するＢ－ｒｅｐグラフを生成するために最初に前処理される。次に、訓練されたモデルは、入力オブジェクトおよびデータベースオブジェクトのシグネチャを計算するのに適用される。最後に、最も類似したオブジェクトは、シグネチャの類似度（距離）に関して、入力Ｂ－ｒｅｐに対しＢ－ｒｅｐデータベースから検索される。
【００９７】

図１０～１３は、オンラインステージの例を例示する。各図面は、問い合わせＢ－ｒｅｐと、データベースにおいて検索された最も位相幾何学的に類似するＢ－ｒｅｐと、を示す。さらに各図面は、幾何学的検索と位相幾何学的検索との違いを例示するために、最も幾何学的に類似したＢ－ｒｅｐも示す。

【００９８】

方法は、コンピュータに実装される。今述べたことは、方法のステップ（または実質的にすべてのステップ）が、少なくとも１台のコンピュータ、または同じようなあらゆるシステムによって実行されることを意味する。ゆえに、方法のステップは、コンピュータによって、おそらく完全に自動的に、または、半自動的に行われる。例では、方法のステップのうちの少なくともいくつかのトリガーは、ユーザーコンピューターインタラクションを通じて行われることがある。要求されるユーザーコンピューターインタラクションのレベルは、予想される自動性のレベルしだいであり、ユーザーの願望を実装する必要性とのバランスに置かれることがある。例では、今述べたレベルは、ユーザー定義されるおよび／または事前定義されることがある。

【００９９】

方法のコンピュータ実装の典型的な例は、今述べた目的に対して適合したシステムにより方法を行うことである。システムは、メモリーおよびグラフィカルユーザーインターフェース（ＧＵＩ）に結合されたプロセッサーを含むことがあり、メモリーは、方法を行うための命令を含むコンピュータプログラムを記録している。さらに、メモリーは、データベースを格納することもある。メモリーは、上記のストレージに対して適合したあらゆるハードウェアであり、おそらく、いくつかの物理的に異なった部分（例えば、プログラム用の１つ、およびおそらくデータベース用の１つ）を含む。

【０１００】

図１４は、システムが、クライアントコンピュータシステム、例えば、ユーザーのワークステーションであるシステムの例を示す。

【０１０１】

例に関するクライアントコンピューターは、内部通信ＢＵＳ１０００に連結された中央処理装置（ＣＰＵ）１０１０、ＢＵＳにさらに連結されたランダムアクセスメモリー（ＲＡＭ）１０７０を含む。さらに、クライアントコンピューターは、ＢＵＳに連結されたビデオランダムアクセスメモリー１１００に関連付けられたグラフィック処理装置（graphical processing unit：ＧＰＵ）１１１０を有して提供される。さらに、ビデオＲＡＭ１１００は、当業者にはフレームバッファとしても知られている。マスストレージデバイスコントローラー１０２０は、たとえばハードドライブ１０３０などのマスメモリーデバイスへのアクセスを管理する。コンピュータプログラム命令およびデータを有形に具現化することに対して適したマスメモリーデバイスは、例として、たとえば、ＥＰＲＯＭ、ＥＥＰＲＯＭ、およびフラッシュメモリーデバイスなどの半導体メモリーデバイス、たとえば内蔵ハードディスクおよび取外し可能ディスクなどの磁気ディスク、光磁気ディスクを含む、不揮発性メモリーのすべてのかたちを含む。前述のもののいずれかは、特別に設計されたＡＳＩＣ（特定用途向け集積回路）により補完される、または組み込まれることがある。ネットワークアダプター１０５０は、ネットワーク１０６０へのアクセスを管理する。さらに、クライアントコンピューターは、たとえば、カーソル制御デバイス、キーボード、または同等のものなど、ハプティックデバイス１０９０を含むこともある。カーソル制御デバイスは、クライアントコンピューターに用いられて、ユーザーに、カーソルをディスプレイ１０８０におけるどんな望みのロケーションにでも選択的に置くことを許可する。加えて、カーソル制御デバイスは、ユーザーに、種々のコマンドを選択し制御信号を入力することを可能にする。カーソル制御デバイスは、システムに制御信号を入力するために、いくらかの信号生成デバイスを含む。通常、カーソル制御デバイスは、マウスであり、マウスのボタンが信号を生成するのに用いられることがある。あるいはまたはさらに加えて、クライアントコンピュータシステムは、センシティブパッド、および／またはセンシティブスクリーンを含むことがある。

【０１０２】
コンピュータプログラムは、コンピュータによって実行可能な命令を含み、命令が上記のシステムに方法を行わせるための手段を含むことがある。プログラムは、システムのメモリーを含む、あらゆるデータ記録媒体に記録可能であり得る。プログラムは、例えば、デジタル電子回路に、またはコンピュータのハードウェア、ファームウェア、ソフトウェアに、またはそれらの組み合わせに実装されることがある。プログラムは、装置として、例えば、プログラマブルプロセッサーによる実行のために機械読取り可能ストレージデバイスに有形に具現化された製品として実装されることがある。方法ステップは、方法の機能を行う命令のプログラムを、入力データに操作し出力を生成することによってプログラマブルプロセッサーが行うことにより行われることがある。ゆえに、プロセッサーは、データストレージシステム、少なくとも１つの入力デバイス、および少なくとも１つの出力デバイスからデータおよび命令を受信し、データおよび命令を送信するようにプログラム可能であり、結合されることがある。アプリケーションプログラムは、ハイレベル手続きプログラミング言語もしくはオブジェクト指向プログラミング言語にて、または望まれるならばアセンブリ言語もしくはマシン言語にて実装されることがある。いかなる場合も、言語は、コンパイル言語またはインタプリタ言語であり得る。プログラムは、フルインストールプログラムまたはアップデートプログラムであり得る。システムへのプログラムの適用は、いかなる場合も、方法を行うための命令に帰着する。あるいは、コンピュータプログラムは、クラウドコンピューティング環境のサーバーに格納され実行されることがあり、サーバーは、１つまたは複数のクライアントとネットワークを介して通信している。上記場合、処理ユニットがプログラムにより含まれる命令を実行することによって、クラウドコンピューティング環境において方法が行われる。

【図面】
【図１】

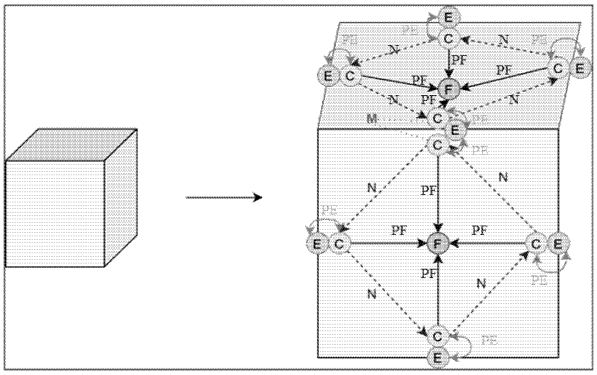

【図２】

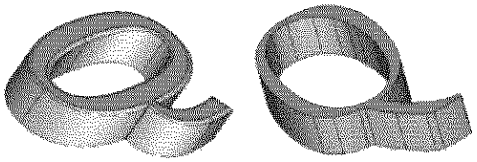

【図３】

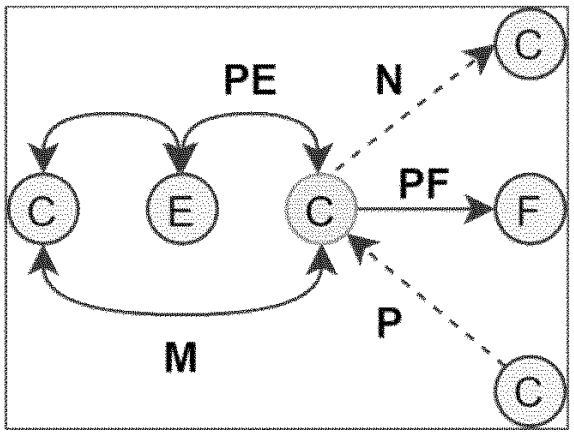
PE
N
PF
P
M
C
E
C
C
F
C

【図４】

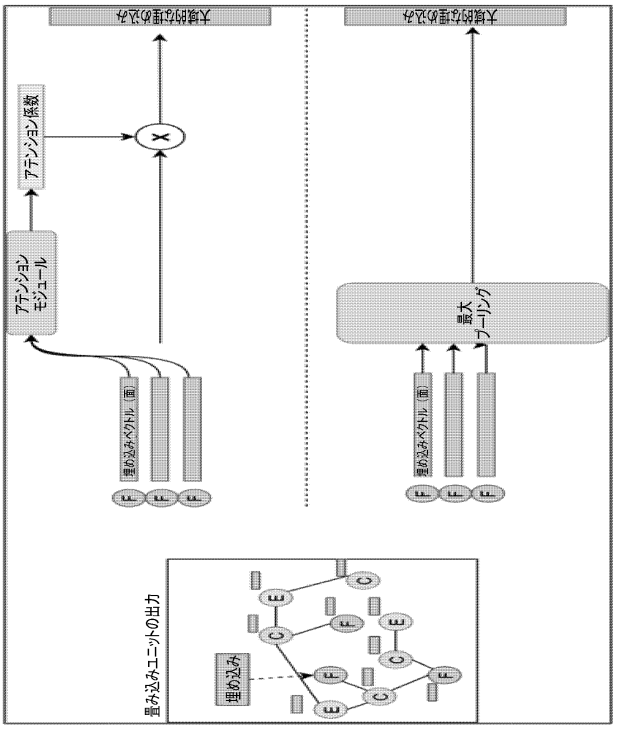
大域的な埋め込み
アテンション係数
アテンション モジュール
埋め込みベクトル（面）
大域的な埋め込み
最大 プーリング
埋め込みベクトル（面）
畳み込みユニットの出力
埋め込み

【図５】

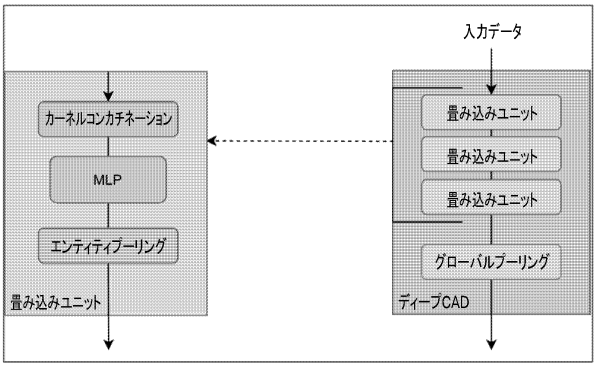
入力データ
カーネルコンカチネーション
MLP
エンティティプーリング
畳み込みユニット
畳み込みユニット
畳み込みユニット
畳み込みユニット
グローバルプーリング
ディープCAD

【図６】

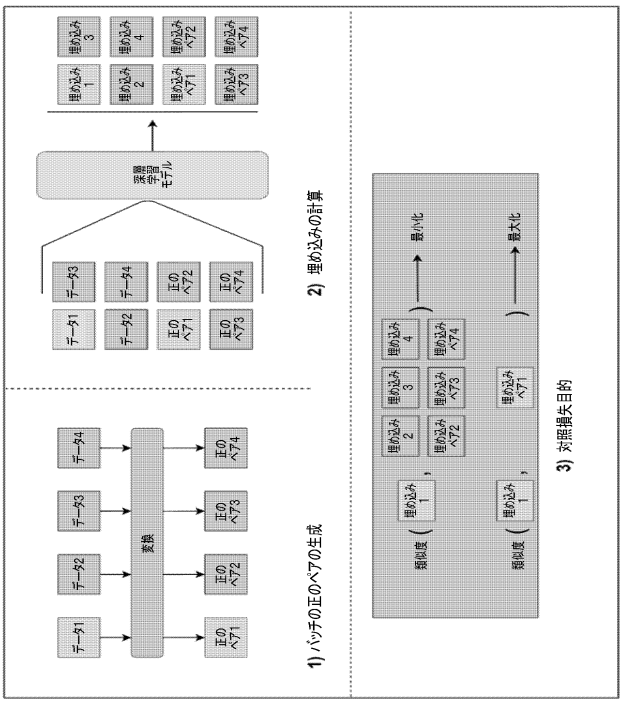
深層学習モデル
2) 埋め込みの計算
1) バッチの正のペアの生成
変換
3) 対照損失目的
類似度
最小化
最大化

【図７】

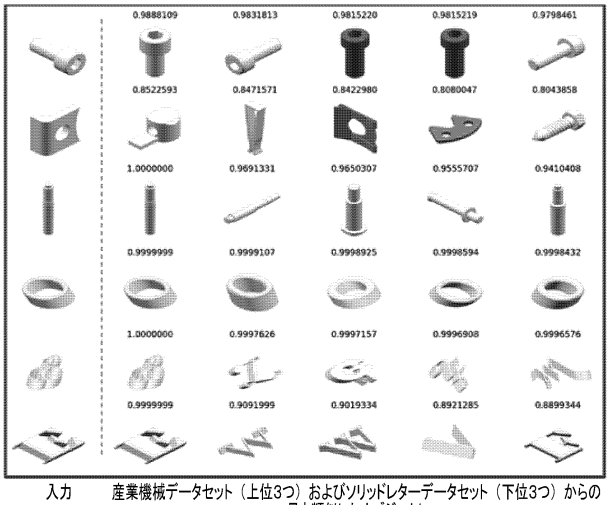

入力　　産業機械データセット（上位3つ）およびソリッドレターデータセット（下位3つ）からの最も類似したオブジェクト

【図８】

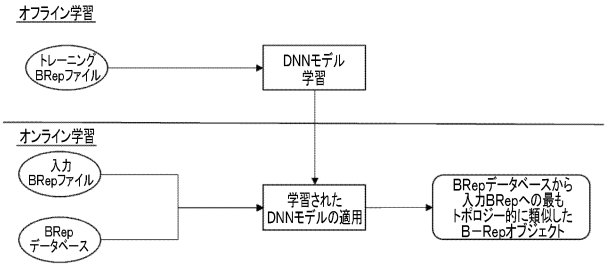

【図９】

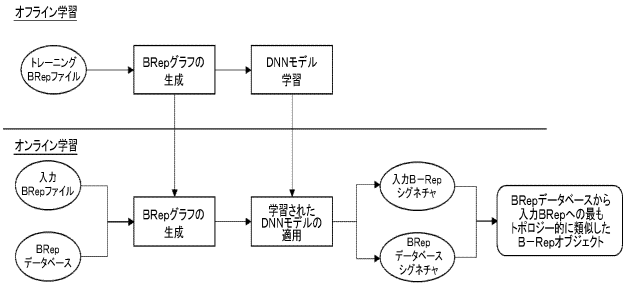

【図１０】

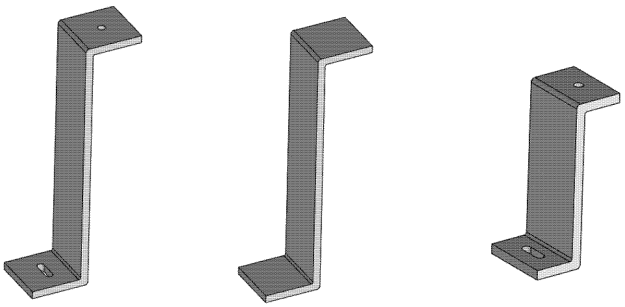

クエリ　　最も近い（幾何学的に）　　最も近い（トポロジー的に）

【図１１】

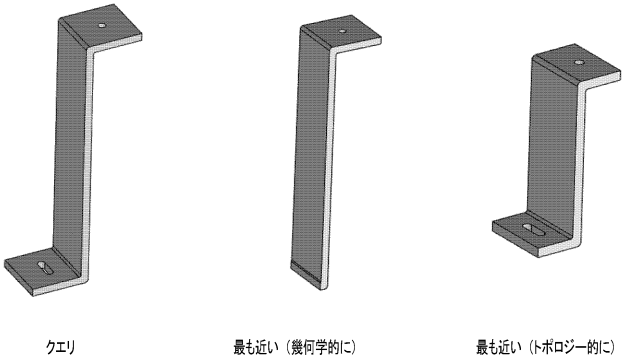

【図１２】

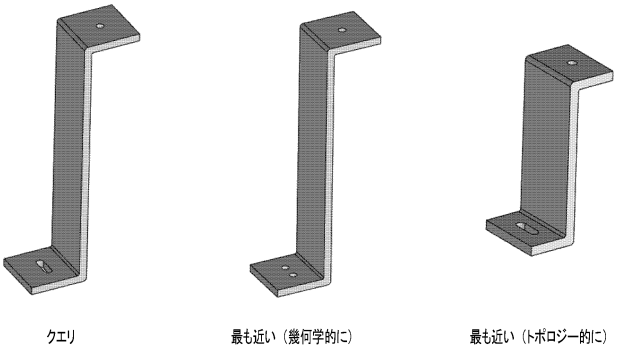

【図１３】

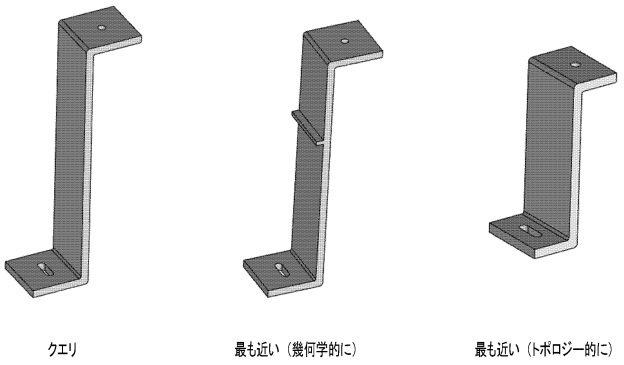

【図１４】

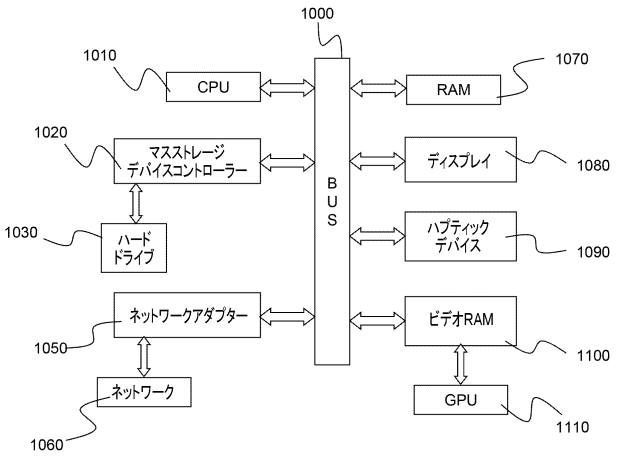

【外国語明細書】

2024028206000042.pdf

フロントページの続き

ソー １０ シーエス ４０５０１ ダッソー システムズ エスイー内
(72)発明者 レミー サバティエ
フランス ７８９４６ ベリジー－ビラクブレー セデックス リュ マルセル ダッソー １０ シーエス ４０５０１ ダッソー システムズ エスイー内

Ｆターム（参考） 5B146 DC03 DL08 EA17