

(19)日本国特許庁(JP)

(12)特許公報(B2)

(11)特許番号
特許第7119631号
(P7119631)

(45)発行日 令和4年8月17日(2022.8.17)

(24)登録日 令和4年8月8日(2022.8.8)

(51)国際特許分類	F I
G 0 6 Q 10/00 (2012.01)	G 0 6 Q 10/00 3 0 0
H 0 4 Q 9/02 (2006.01)	H 0 4 Q 9/02 B
H 0 4 Q 9/00 (2006.01)	H 0 4 Q 9/00 3 1 1 J
G 0 8 B 31/00 (2006.01)	G 0 8 B 31/00 A

請求項の数 5 (全13頁)

(21)出願番号	特願2018-116796(P2018-116796)	(73)特許権者	000004226 日本電信電話株式会社 東京都千代田区大手町一丁目5番1号
(22)出願日	平成30年6月20日(2018.6.20)	(74)代理人	110002147 特許業務法人酒井国際特許事務所
(65)公開番号	特開2019-219915(P2019-219915 A)	(72)発明者	高橋 大志 東京都千代田区大手町一丁目5番1号 日本電信電話株式会社内
(43)公開日	令和1年12月26日(2019.12.26)	(72)発明者	岩田 具治 東京都千代田区大手町一丁目5番1号 日本電信電話株式会社内
審査請求日	令和2年10月7日(2020.10.7)	(72)発明者	山中 友貴 東京都千代田区大手町一丁目5番1号 日本電信電話株式会社内
		(72)発明者	山田 真徳

最終頁に続く

(54)【発明の名称】 検知装置、検知方法および検知プログラム

(57)【特許請求の範囲】

【請求項1】

センサが出力するデータを取得する取得部と、
エンコーダとデコーダとを含んで前記データの確率分布を表すVAE (Variational AutoEncoder) において、該エンコーダに適用される事前分布を、該エンコーダを周辺化した周辺化事後分布に置換し、かつ、標準ガウス分布と前記周辺化事後分布との密度比を用いて、前記周辺化事後分布に対する該エンコーダのカルバックライブラー情報量を近似し、近似されたカルバックライブラー情報量を用いて該VAEを学習する学習部と、
学習されたVAEを用いて前記データの確率分布を推定し、新たに取得された前記データの推定される発生確率が所定の閾値より低い場合に異常として検知する検知部と、
を備えることを特徴とする検知装置。

10

【請求項2】

前記エンコーダおよび前記デコーダは、ガウス分布に従うことを特徴とする請求項1に記載の検知装置。

【請求項3】

前記検知部は、異常を検知した場合に、警報を出力することを特徴とする請求項1または2に記載の検知装置。

【請求項4】

検知装置で実行される検知方法であって、
センサが出力するデータを取得する取得工程と、

20

エンコーダとデコーダとを含んで前記データの確率分布を表すVAE (Variational AutoEncoder) において、該エンコーダに適用される事前分布を、該エンコーダを周辺化した周辺化事後分布に置換し、かつ、標準ガウス分布と前記周辺化事後分布との密度比を用いて、前記周辺化事後分布に対する該エンコーダのカルバックライブラー情報量を近似し、近似されたカルバックライブラー情報量を用いて該VAEを学習する学習工程と、学習されたVAEを用いて前記データの確率分布を推定し、新たに取得された前記データの推定される発生確率が所定の閾値より低い場合に異常として検知する検知工程と、を含んだことを特徴とする検知方法。

【請求項5】

センサが出力するデータを取得する取得ステップと、

10

エンコーダとデコーダとを含んで前記データの確率分布を表すVAE (Variational AutoEncoder) において、該エンコーダに適用される事前分布を、該エンコーダを周辺化した周辺化事後分布に置換し、かつ、標準ガウス分布と前記周辺化事後分布との密度比を用いて、前記周辺化事後分布に対する該エンコーダのカルバックライブラー情報量を近似し、近似されたカルバックライブラー情報量を用いて該VAEを学習する学習ステップと、学習されたVAEを用いて前記データの確率分布を推定し、新たに取得された前記データの推定される発生確率が所定の閾値より低い場合に異常として検知する検知ステップと、をコンピュータに実行させるための検知プログラム。

【発明の詳細な説明】

【技術分野】

20

【0001】

本発明は、検知装置、検知方法および検知プログラムに関する。

【背景技術】

【0002】

近年、車やエアコン等の様々な物をインターネットに接続するいわゆるIoTの普及に伴い、物に取り付けられたセンサのセンサデータを用いて物の異常や故障を事前に検知する技術が注目されている。例えば、機械学習を用いてセンサデータが示す異常値を検出して、物に異常や故障が発生する前触れを検知する。すなわち、機械学習によりデータの確率分布を推定する生成モデルを作成し、発生する確率が高いデータを正常、発生する確率が低いデータを異常と定義して異常を検知する。

30

【0003】

データの確率分布を推定する技術として、潜在変数とニューラルネットワークとを用いた機械学習による生成モデルであるVAE (Variational AutoEncoder) が知られている(非特許文献1~3参照)。VAEは、大規模かつ複雑なデータの確率分布を推定するため、異常検知、画像認識、動画認識、音声認識等の様々な分野に応用されている。一般に、VAEでは、潜在変数の事前分布は標準ガウス分布と仮定されている。

【先行技術文献】

【非特許文献】

【0004】

【文献】Diederik P.Kingma、Max Welling、“Auto-Encoding Variational Bayes”、[online]、2014年5月、[2018年5月25日検索]、インターネット<URL:https://arxiv.org/abs/1312.6114>
Matthew D.Hoffman、Matthew J.Johnson、“ELBO surgery: yet another way to carve up the variational evidence lower bound”、[online]、2016年、Workshop in Advances in Approximate Bayesian Inference、NIPS 2016、[2018年5月25日検索]、インターネット<URL:http://approximateinference.org/2016/accepted/HoffmanJohnson2016.pdf>
Jakub M.Tomczak、Max Welling、“VAE with a VampPrior”、[online]、2017年、arXiv preprint arXiv:1705.07120、[2018年5月25日検索]、インターネット<URL:https://arxiv.org/abs/1705.07120>

40

50

【発明の概要】

【発明が解決しようとする課題】

【0005】

しかしながら、従来のVAEでは、潜在変数の事前分布を標準ガウス分布と仮定した場合には、データの確率分布の推定の精度が低かった。

【0006】

本発明は、上記に鑑みてなされたものであって、VAEによるデータの確率分布を高精度に推定することを目的とする。

【課題を解決するための手段】

【0007】

上述した課題を解決し、目的を達成するために、本発明に係る検知装置は、センサが出力するデータを取得する取得部と、エンコーダとデコーダとを含んで前記データの確率分布を表す生成モデルにおいて、該エンコーダの事前分布を、該エンコーダを周辺化した周辺化事後分布に置換し、かつ、標準ガウス分布と前記周辺化事後分布との密度比を用いてカルバックライブラー情報量を近似し、前記データを用いて該生成モデルを学習する学習部と、学習された生成モデルを用いて前記データの確率分布を推定し、新たに取得された前記データの推定される発生確率が所定の閾値より低い場合に異常として検知する検知部と、を備えることを特徴とする。

10

【発明の効果】

【0008】

本発明によれば、VAEによるデータの確率分布を高精度に推定可能となる。

20

【図面の簡単な説明】

【0009】

【図1】図1は、検知装置の概要を説明するための説明図である。

【図2】図2は、検知装置の概略構成を例示する模式図である。

【図3】図3は、学習部の処理を説明するための説明図である。

【図4】図4は、検知部の処理を説明するための説明図である。

【図5】図5は、検知部の処理を説明するための説明図である。

【図6】図6は、検知処理手順を示すフローチャートである。

【図7】図7は、検知プログラムを実行するコンピュータを例示する図である。

30

【発明を実施するための形態】

【0010】

以下、図面を参照して、本発明の一実施形態を詳細に説明する。なお、この実施形態により本発明が限定されるものではない。また、図面の記載において、同一部分には同一の符号を付して示している。

【0011】

〔検知装置の概要〕

本実施形態の検知装置は、VAEをベースにした生成モデルを作成してIoTのセンサデータの異常を検知する。ここで、図1は、検知装置の概要を説明するための説明図である。図1に示すように、VAEは、エンコーダおよびデコーダと呼ばれる2つの条件付き確率分布で構成される。

40

【0012】

エンコーダ $q(z|x)$ は、高次元のデータ x を符号化して、低次元の潜在変数 z による表現に変換する。ここで、 θ_q はエンコーダのパラメータである。また、デコーダ $p(x|z)$ は、エンコーダで符号化されたデータを復号化して、元のデータ x を再現する。ここで、 θ_p はデコーダのパラメータである。元のデータ x が連続値の場合、一般に、エンコーダおよびデコーダにはガウス分布が適用される。図1に示す例では、エンコーダの分布は $N(z; \mu_q(x), \sigma_q^2(x))$ であり、デコーダの分布は $N(x; \mu_p(z), \sigma_p^2(z))$ である。

【0013】

50

具体的には、VAEは、次式(1)に示すように、真のデータの確率分布 $p_D(\mathbf{x})$ を $p_\theta(\mathbf{x})$ として再現する。ここで、 $p_\lambda(\mathbf{z})$ は事前分布と呼ばれ、一般に、平均 $\mu = 0$ 、分散 $\Sigma = 1$ の標準ガウス分布と仮定される。

【0014】

【数1】

$$p_\theta(\mathbf{x}) = \int p_\theta(\mathbf{x} | \mathbf{z}) p_\lambda(\mathbf{z}) d\mathbf{z} \quad \dots(1)$$

【0015】

10

VAEは、真のデータ分布と生成モデルによるデータ分布との差を最小にするように学習を行う。すなわち、VAEの生成モデルは、デコーダの再現率を表す尤度に対応する対数尤度の平均値を最大にするように、エンコーダのパラメータおよびデコーダのパラメータを決定することにより、作成される。これらのパラメータは、対数尤度の下界を表す変分下界が最大となる場合において決定される。言い換えれば、VAEの学習においては、変分下界にマイナス1を乗じた損失関数の平均値を最小化するように、エンコーダおよびデコーダのパラメータが決定される。

【0016】

具体的には、VAEの学習では、次式(2)に示すように、対数尤度を周辺化した周辺化対数尤度 $\mathbb{E}_{p_D(\mathbf{x})} \ln p_\theta(\mathbf{x})$ の平均値を最大化するように、パラメータが決定される。

20

【0017】

【数2】

$$\max_{\theta} \int p_D(\mathbf{x}) \ln p_\theta(\mathbf{x}) d\mathbf{x} \quad \dots(2)$$

【0018】

周辺化対数尤度は、次式(3)に示すように、変分下界により下から抑えられる。

【0019】

【数3】

30

$$\begin{aligned} \ln p_\theta(\mathbf{x}) &= \ln \mathbb{E}_{q_\phi(\mathbf{z}|\mathbf{x})} \left[\frac{p_\theta(\mathbf{x} | \mathbf{z}) p_\lambda(\mathbf{z})}{q_\phi(\mathbf{z} | \mathbf{x})} \right] \\ &\geq \mathbb{E}_{q_\phi(\mathbf{z}|\mathbf{x})} \left[\ln \frac{p_\theta(\mathbf{x} | \mathbf{z}) p_\lambda(\mathbf{z})}{q_\phi(\mathbf{z} | \mathbf{x})} \right] \\ &= \mathcal{L}(\theta, \phi; \mathbf{x}) \end{aligned} \quad \dots(3)$$

【0020】

すなわち、周辺化対数尤度の変分下界は、次式(4)で表される。

40

【0021】

【数4】

$$\begin{aligned} \mathcal{L}(\theta, \phi; \mathbf{x}) &= \mathbb{E}_{q_\phi(\mathbf{z}|\mathbf{x})} [\ln p_\theta(\mathbf{x} | \mathbf{z})] \\ &\quad - D_{KL}(q_\phi(\mathbf{z} | \mathbf{x}) \| p_\lambda(\mathbf{z})) \end{aligned} \quad \dots(4)$$

ここで、 \mathcal{L} は変分下界

【0022】

上記式(4)の第一項(にマイナスを付したものは、再構成誤差と呼ばれる。また、第二項は、事前分布 $p_\lambda(\mathbf{z})$ に対するエンコーダ $q_\phi(\mathbf{z} | \mathbf{x})$ のカルバックライブラ

50

一情報量と呼ばれる。上記式(4)に示したように、変分下界とは、カルバックライブラー情報量で正則化された再構成誤差と解釈することができる。つまり、カルバックライブラー情報量は、エンコーダ $q(z|x)$ が事前分布 $p(z)$ に近づくように正則化する項ということができる。VAEは、第一項を大きく、第二項のカルバックライブラー情報量を小さくして、周辺化対数尤度の平均値を最大化するように、学習を行う。

【0023】

ところで、上記したように、事前分布は標準ガウス分布と仮定されるが、その場合には、VAEの学習が妨げられ、データの確率分布の推定精度が低いことが知られている。これに対し、VAEに最適な事前分布は、解析的に求めることができるものである。

【0024】

そこで、本実施形態の検知装置では、事前分布を、次式(5)に示すように、エンコーダ $q(z|x)$ を周辺化した周辺化事後分布 $q(z)$ に置換する(非特許文献2参照)。

【0025】

【数5】

$$\int p_D(\mathbf{x}) q_\phi(\mathbf{z}|\mathbf{x}) d\mathbf{x} \equiv q_\phi(\mathbf{z}) \quad \dots(5)$$

【0026】

一方、事前分布 $p(z)$ を周辺化事後分布 $q(z)$ に置換した場合には、周辺化事後分布 $q(z)$ に対するエンコーダ $q(z|x)$ のカルバックライブラー情報量を解析的に求めることができない。そこで、本実施形態の検知装置では、カルバックライブラー情報量を精度よく近似できるように、標準のガウス分布と周辺化事後分布との密度比を用いて、カルバックライブラー情報量を近似する。これにより、データの確率分布を高精度に推定可能なVAEの生成モデルが作成される。

【0027】

[検知装置の構成]

図2は、検知装置の概略構成を例示する模式図である。図2に例示するように、検知装置10は、パソコン等の汎用コンピュータで実現され、入力部11、出力部12、通信制御部13、記憶部14、および制御部15を備える。

【0028】

入力部11は、キーボードやマウス等の入力デバイスを用いて実現され、操作者による入力操作に対応して、制御部15に対して処理開始などの各種指示情報を入力する。出力部12は、液晶ディスプレイなどの表示装置、プリンター等の印刷装置等によって実現される。

【0029】

通信制御部13は、NIC(Network Interface Card)等で実現され、ネットワーク3を介したサーバ等の外部の装置と制御部15との通信を制御する。

【0030】

記憶部14は、RAM(Random Access Memory)、フラッシュメモリ(Flash Memory)等の半導体メモリ素子、または、ハードディスク、光ディスク等の記憶装置によって実現され、後述する検知処理により学習されたデータの生成モデルのパラメータ等が記憶される。なお、記憶部14は、通信制御部13を介して制御部15と通信する構成でもよい。

【0031】

制御部15は、CPU(Central Processing Unit)等を用いて実現され、メモリに記憶された処理プログラムを実行する。これにより、制御部15は、図4に例示するように、取得部15a、学習部15bおよび検知部15cとして機能する。なお、これらの機能部は、異なるハードウェアに実装されてもよい。

10

20

30

40

50

【 0 0 3 2 】

取得部 1 5 a は、センサが出力するデータを取得する。例えば、取得部 1 5 a は、I o T 機器に取り付けられたセンサが出力するセンサデータを、通信制御部 1 3 を介して取得する。センサデータとしては、例えば、車に取り付けられた温度、速度、回転数、走行距離等のセンサのデータや、工場内で稼働する多種多様な機器のそれぞれに取り付けられた温度、振動数、音等のセンサのデータが例示される。

【 0 0 3 3 】

学習部 1 5 b は、エンコーダとデコーダとを含んでデータの確率分布を表す生成モデルにおいて、該エンコーダの事前分布を、該エンコーダを周辺化した周辺化事後分布に置換し、かつ、標準ガウス分布と周辺化事後分布との密度比を用いてカルバックライブラー情報量を近似し、データを用いて生成モデルを学習する。

10

【 0 0 3 4 】

具体的には、学習部 1 5 b は、データが発生する確率分布を表す生成モデルを、ガウス分布に従うエンコーダとデコーダとを含む V A E をベースに作成する。その際、学習部 1 5 b は、該エンコーダの事前分布を、上記式 (5) に示した該エンコーダを周辺化した周辺化事後分布 $q (z)$ に置換する。さらに、学習部 1 5 b は、平均 $\mu = 0$ 、分散 $\sigma^2 = 1$ の標準ガウス分布 $p (z)$ と周辺化事後分布 $q (z)$ との密度比を推定することで、周辺化事後分布 $q (z)$ に対するエンコーダ $q (z | x)$ のカルバックライブラー情報量を近似する。

【 0 0 3 5 】

ここで、密度比推定とは、2つの確率分布のそれぞれを推定することなく、2つの確率分布の密度比を推定する手法である。それぞれの確率分布を解析的に求められない場合であっても、それぞれの確率分布からのサンプリングが可能な場合には、2つの確率分布の密度比を求めることができるので、密度比推定の適用が可能である。

20

【 0 0 3 6 】

具体的には、周辺化事後分布 $q (z)$ に対するエンコーダ $q (z | x)$ のカルバックライブラー情報量は、次式 (6) に示すように2つの項に分解できる。

【 0 0 3 7 】

【数 6】

$$\begin{aligned}
 D_{KL}(q_{\phi}(\mathbf{z} | \mathbf{x}) \| q_{\phi}(\mathbf{z})) & \\
 &= \int q_{\phi}(\mathbf{z} | \mathbf{x}) \ln \frac{q_{\phi}(\mathbf{z} | \mathbf{x})}{q_{\phi}(\mathbf{z})} d\mathbf{z} \\
 &= \int q_{\phi}(\mathbf{z} | \mathbf{x}) \ln \frac{q_{\phi}(\mathbf{z} | \mathbf{x}) p(\mathbf{z})}{q_{\phi}(\mathbf{z}) p(\mathbf{z})} d\mathbf{z} \\
 &= \int q_{\phi}(\mathbf{z} | \mathbf{x}) \ln \frac{q_{\phi}(\mathbf{z} | \mathbf{x})}{p(\mathbf{z})} d\mathbf{z} + \int q_{\phi}(\mathbf{z} | \mathbf{x}) \ln \frac{p(\mathbf{z})}{q_{\phi}(\mathbf{z})} d\mathbf{z} \\
 &= D_{KL}(q_{\phi}(\mathbf{z} | \mathbf{x}) \| p(\mathbf{z})) - \mathbb{E}_{q_{\phi}(\mathbf{z} | \mathbf{x})} \left[\ln \frac{q_{\phi}(\mathbf{z})}{p(\mathbf{z})} \right] \quad \dots (6)
 \end{aligned}$$

30

【 0 0 3 8 】

上記式 (6) において、第一項は、標準ガウス分布 $p (z)$ に対するエンコーダ $q (z | x)$ のカルバックライブラー情報量であり、解析的に計算可能である。また、第二項は、標準ガウス分布 $p (z)$ と周辺化事後分布 $q (z)$ との密度比を用いて表される。この場合に、標準ガウス分布 $p (z)$ から周辺化事後分布 $q (z)$ から容易にサンプリングが可能であるため、密度比推定の適用が可能である。

40

【 0 0 3 9 】

なお、高次元のデータについては、密度比の推定精度が低いことが知られているが、V A E の潜在変数 z は低次元であるため、密度比の推定を高精度に行うことが可能である。

【 0 0 4 0 】

50

具体的には、次式(7)に示すように、 z の関数 $T(z)$ を用いた目的関数を最大化する $T(z)$ を $T^*(z)$ とする。この場合に、次式(8)に示すように、 $T^*(z)$ は、標準ガウス分布 $p(z)$ と周辺化事後分布 $q(z)$ との密度比に等しくなる。

【0041】

【数7】

$$T^*(z) = \max_T \left\{ \mathbb{E}_{q_\phi(z)} \ln(\sigma(T(z))) + \mathbb{E}_{p(z)} \ln(1 - \sigma(T(z))) \right\} \quad \dots(7)$$

【0042】

【数8】

$$T^*(z) = \ln \frac{q_\phi(z)}{p(z)} \quad \dots(8)$$

10

【0043】

そこで、学習部15bは、次式(9)に示すように、上記式(6)に示したカルバックライブラー情報量の密度比を $T^*(z)$ に置換する近似を行う。

【0044】

【数9】

$$\begin{aligned} D_{KL}(q_\phi(z|x) || q_\phi(z)) \\ = D_{KL}(q_\phi(z|x) || p(z)) - \mathbb{E}_{q_\phi(z|x)} [T^*(z)] \end{aligned} \quad \dots(9)$$

20

【0045】

これにより、学習部15bは、周辺化事後分布 $q(z)$ に対するエンコーダ $q(z|x)$ のカルバックライブラー情報量を精度よく近似することが可能となる。したがって、学習部15bは、データの確率分布を高精度に推定可能なVAEの生成モデルを作成できる。

【0046】

図3は、学習部15bの処理を説明するための説明図である。図3には、各種の手法により学習された生成モデルの対数尤度が例示されている。図3において、標準ガウス分布は、従来のVAEを表す。また、VampPriorは、潜在変数を混合分布としたVAEを表す(非特許文献3参照)。また、対数尤度は、生成モデルの精度評価の尺度であり、値が大きいほど精度が高いことを表す。図3に示す例では、手書き数字のサンプルデータであるMNISTのデータセットを用いて、対数尤度が算出されている。

30

【0047】

図3に示すように、従来のVAEおよびVampPriorと比較して、上記実施形態に示した本発明の手法により、対数尤度の値が大きくなり精度が向上していることがわかる。このように、本実施形態の学習部15bにより、高精度な生成モデルを作成できる。

【0048】

図2の説明に戻る。検知部15cは、学習された生成モデルを用いてデータの確率分布を推定し、新たに取得されたデータの推定される発生確率が所定の閾値より低い場合に異常として検知する。例えば、図4および図5は、検知部15cの処理を説明するための説明図である。図4に例示するように、検知装置10では、車等のモノに取り付けられた速度、回転数、走行距離等のセンサのデータを取得部15aが取得して、学習部15bがデータの確率分布を表す生成モデルを作成する。

40

【0049】

また、検知部15cが、作成された生成モデルを用いてデータ発生の確率分布を推定する。そして、検知部15cは、新たに取得部15aが取得したデータの推定される発生確率が、所定の閾値以上の場合には正常、所定の閾値より低い場合には異常と判定する。

50

【 0 0 5 0 】

例えば、図 5 (a) に示したように、2次元のデータ空間に点で示したデータが与えられた場合に、検知部 1 5 c は、学習部 1 5 b が作成した生成モデルを用いて、図 5 (b) に示すように、データ発生の確率分布を推定する。図 5 (b) において、データ空間上の色が濃いほど、その部分のデータの発生の確率が高いことを示している。したがって、図 5 (b) に x で示した発生の確率が低いデータは、異常データと見なすことができる。

【 0 0 5 1 】

また、検知部 1 5 c は異常を検知した場合に、警報を出力する。例えば、出力部 1 2 あるいは通信制御部 1 3 を介して管理装置等に、異常検知の旨のメッセージやアラームを出力する。

【 0 0 5 2 】

[検知処理]

次に、図 6 を参照して、本実施形態に係る検知装置 1 0 による検知処理について説明する。図 6 は、検知処理手順を示すフローチャートである。図 6 のフローチャートは、例えば、検知処理の開始を指示する操作入力があったタイミングで開始される。

【 0 0 5 3 】

まず、取得部 1 5 a が、車等のモノに取り付けられた速度、回転数、走行距離等のセンサのデータを取得する (ステップ S 1)。次に、学習部 1 5 b が、取得されたデータを用いて、ガウス分布に従うエンコードとデコードとを含んでデータの確率分布を表す生成モデルを学習する (ステップ S 2)。

【 0 0 5 4 】

その際、学習部 1 5 b は、エンコードの事前分布を、該エンコードを周辺化した周辺化事後分布に置換する。また、学習部 1 5 b は、標準ガウス分布と周辺化事後分布との密度比を用いてカルバックライブラー情報量を近似する。

【 0 0 5 5 】

次に、検知部 1 5 c が、作成された生成モデルを用いてデータ発生の確率分布を推定する (ステップ S 3)。また、検知部 1 5 c は、新たに取得部 1 5 a が取得したデータの推定される発生確率が所定の閾値より低い場合に、異常として検知する (ステップ S 4)。検知部 1 5 c は異常を検知した場合に、警報を出力する。これにより、一連の検知処理が終了する。

【 0 0 5 6 】

以上、説明したように、本実施形態の検知装置 1 0 において、取得部 1 5 a が、センサが出力するデータを取得する。また、学習部 1 5 b が、エンコードとデコードとを含んでデータの確率分布を表す生成モデルにおいて、該エンコードの事前分布を、該エンコードを周辺化した周辺化事後分布に置換し、かつ、標準ガウス分布と周辺化事後分布との密度比を用いてカルバックライブラー情報量を近似し、取得したデータを用いて生成モデルを学習する。検知部 1 5 c は、学習された生成モデルを用いてデータの確率分布を推定し、新たに取得されたデータの推定される発生確率が所定の閾値より低い場合に異常として検知する。

【 0 0 5 7 】

これにより、検知装置 1 0 は、低次元の潜在変数を用いた密度比推定を適用して、高精度なデータの生成モデルを作成することができる。このように、検知装置 1 0 は、IoT 機器のセンサデータのように大規模かつ複雑なデータの生成モデルを高精度に学習することができる。したがって、データの発生確率を高精度に推定し、データの異常を検知することが可能となる。

【 0 0 5 8 】

例えば、検知装置 1 0 は、車に取り付けられた温度、速度、回転数、走行距離等の各種センサが出力する大規模かつ複雑なデータを取得して、走行中の車に発生した異常を高精度に検知することができる。あるいは、検知装置 1 0 は、工場内で稼働する多種多様な機器のそれぞれに取り付けられた温度、振動数、音等のセンサが出力する大規模かつ複雑な

10

20

30

40

50

データを取得して、いずれかの機器に異常が発生した場合に高精度に異常を検知することができる。

【 0 0 5 9 】

なお、本実施形態の検知装置 1 0 は、従来の V A E をベースとしたものに限定されない。すなわち、学習部 1 5 b の処理は、V A E の特殊なケースである A E (Auto Encoder) をベースとしてもよいし、エンコーダおよびデコーダがガウス分布以外の確率分布に従うものとしてもよい。

【 0 0 6 0 】

[プログラム]

上記実施形態に係る検知装置 1 0 が実行する処理をコンピュータが実行可能な言語で記述したプログラムを作成することもできる。一実施形態として、検知装置 1 0 は、パッケージソフトウェアやオンラインソフトウェアとして上記の検知処理を実行する検知プログラムを所望のコンピュータにインストールさせることによって実装できる。例えば、上記の検知プログラムを情報処理装置に実行させることにより、情報処理装置を検知装置 1 0 として機能させることができる。ここで言う情報処理装置には、デスクトップ型またはノート型のパーソナルコンピュータが含まれる。また、その他にも、情報処理装置にはスマートフォン、携帯電話機や P H S (Personal Handyphone System) 等の移動体通信端末、さらには、P D A (Personal Digital Assistants) 等のスレート端末等がその範疇に含まれる。

10

【 0 0 6 1 】

また、検知装置 1 0 は、ユーザが使用する端末装置をクライアントとし、当該クライアントに上記の検知処理に関するサービスを提供するサーバ装置として実装することもできる。例えば、検知装置 1 0 は、I o T 機器のセンサのデータを入力とし、異常を検知した場合に検知結果を出力する検知処理サービスを提供するサーバ装置として実装される。この場合、検知装置 1 0 は、W e b サーバとして実装することとしてもよいし、アウトソーシングによって上記の検知処理に関するサービスを提供するクラウドとして実装することとしてもかまわない。以下に、検知装置 1 0 と同様の機能を実現する検知プログラムを実行するコンピュータの一例を説明する。

20

【 0 0 6 2 】

図 7 は、検知プログラムを実行するコンピュータの一例を示す図である。コンピュータ 1 0 0 0 は、例えば、メモリ 1 0 1 0 と、C P U 1 0 2 0 と、ハードディスクドライブインタフェース 1 0 3 0 と、ディスクドライブインタフェース 1 0 4 0 と、シリアルポートインタフェース 1 0 5 0 と、ビデオアダプタ 1 0 6 0 と、ネットワークインタフェース 1 0 7 0 とを有する。これらの各部は、バス 1 0 8 0 によって接続される。

30

【 0 0 6 3 】

メモリ 1 0 1 0 は、R O M (Read Only Memory) 1 0 1 1 および R A M 1 0 1 2 を含む。R O M 1 0 1 1 は、例えば、B I O S (Basic Input Output System) 等のブートプログラムを記憶する。ハードディスクドライブインタフェース 1 0 3 0 は、ハードディスクドライブ 1 0 3 1 に接続される。ディスクドライブインタフェース 1 0 4 0 は、ディスクドライブ 1 0 4 1 に接続される。ディスクドライブ 1 0 4 1 には、例えば、磁気ディスクや光ディスク等の着脱可能な記憶媒体が挿入される。シリアルポートインタフェース 1 0 5 0 には、例えば、マウス 1 0 5 1 およびキーボード 1 0 5 2 が接続される。ビデオアダプタ 1 0 6 0 には、例えば、ディスプレイ 1 0 6 1 が接続される。

40

【 0 0 6 4 】

ここで、ハードディスクドライブ 1 0 3 1 は、例えば、O S 1 0 9 1、アプリケーションプログラム 1 0 9 2、プログラムモジュール 1 0 9 3 およびプログラムデータ 1 0 9 4 を記憶する。上記実施形態で説明した各情報は、例えばハードディスクドライブ 1 0 3 1 やメモリ 1 0 1 0 に記憶される。

【 0 0 6 5 】

また、検知プログラムは、例えば、コンピュータ 1 0 0 0 によって実行される指令が記

50

述されたプログラムモジュール 1093 として、ハードディスクドライブ 1031 に記憶される。具体的には、上記実施形態で説明した検知装置 10 が実行する各処理が記述されたプログラムモジュール 1093 が、ハードディスクドライブ 1031 に記憶される。

【0066】

また、検知プログラムによる情報処理に用いられるデータは、プログラムデータ 1094 として、例えば、ハードディスクドライブ 1031 に記憶される。そして、CPU 1020 が、ハードディスクドライブ 1031 に記憶されたプログラムモジュール 1093 やプログラムデータ 1094 を必要に応じて RAM 1012 に読み出して、上述した各手順を実行する。

【0067】

なお、検知プログラムに係るプログラムモジュール 1093 やプログラムデータ 1094 は、ハードディスクドライブ 1031 に記憶される場合に限られず、例えば、着脱可能な記憶媒体に記憶されて、ディスクドライブ 1041 等を介して CPU 1020 によって読み出されてもよい。あるいは、検知プログラムに係るプログラムモジュール 1093 やプログラムデータ 1094 は、LAN (Local Area Network) や WAN (Wide Area Network) 等のネットワークを介して接続された他のコンピュータに記憶され、ネットワークインタフェース 1070 を介して CPU 1020 によって読み出されてもよい。

【0068】

以上、本発明者によってなされた発明を適用した実施形態について説明したが、本実施形態による本発明の開示の一部をなす記述および図面により本発明は限定されることはない。すなわち、本実施形態に基づいて当業者等によりなされる他の実施形態、実施例および運用技術等は全て本発明の範疇に含まれる。

【符号の説明】

【0069】

- 10 検知装置
- 11 入力部
- 12 出力部
- 13 通信制御部
- 14 記憶部
- 15 制御部
- 15 a 取得部
- 15 b 学習部
- 15 c 検知部

10

20

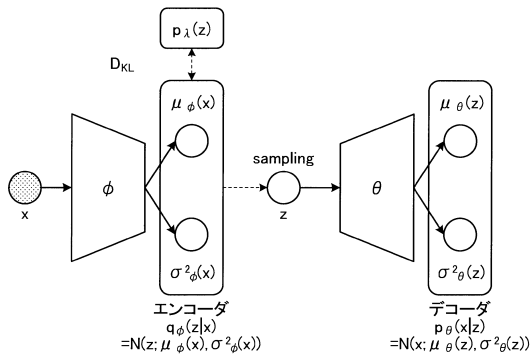
30

40

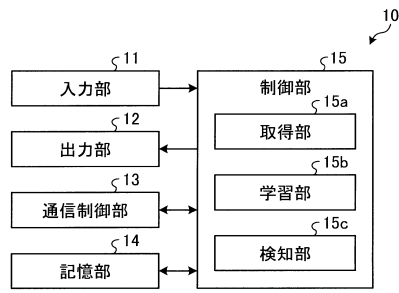
50

【図面】

【図 1】



【図 2】




10

【図 3】

	標準ガウス分布	VampPrior	本発明
対数尤度	-94.03 ± 0.09	-93.99 ± 0.92	-91.30 ± 0.22

【図 4】




20

30

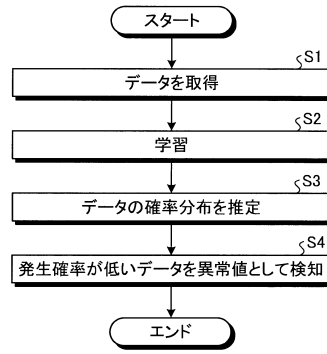
40

50

【図5】




【図6】



10

20

【図7】



30

40

50

フロントページの続き

東京都千代田区大手町一丁目5番1号 日本電信電話株式会社内

(72)発明者 八木 哲志

東京都千代田区大手町一丁目5番1号 日本電信電話株式会社内

審査官 原 忠

(56)参考文献 国際公開第2017/094267(WO, A1)

国際公開第2017/168870(WO, A1)

特開2017-027145(JP, A)

(58)調査した分野 (Int.Cl., DB名)

G06Q 10/00 - 99/00

H04Q 9/02

H04Q 9/00

G08B 31/00