

(12) 特許協力条約に基づいて公開された国際出願

(19) 世界知的所有権機関
国際事務局

(43) 国際公開日
2021年8月12日(12.08.2021)



(10) 国際公開番号

WO 2021/157124 A1

(51) 国際特許分類:
G06N 20/00 (2019.01)

(21) 国際出願番号: PCT/JP2020/036328

(22) 国際出願日: 2020年9月25日(25.09.2020)

(25) 国際出願の言語: 日本語

(26) 国際公開の言語: 日本語

(30) 優先権データ:
特願 2020-016010 2020年2月3日(03.02.2020) JP

(72) 発明者; および


(71) 出願人: 窪田 望 (**KUBOTA, Nozomu**) [JP/JP];
〒1080075 東京都港区港南1丁目9番36号
N T T D A T A 品川ビル13階 株式会社クリエーターズネクスト内 Tokyo (JP).

(74) 代理人: 稲葉 良幸, 外(**INABA, Yoshiyuki** et al.);
〒1066123 東京都港区六本木6-10-1
六本木ヒルズ森タワー23階 T M I
総合法律事務所 Tokyo (JP).

(81) 指定国(表示のない限り、全ての種類の国内保護が可能): AE, AG, AL, AM, AO, AT, AU, AZ, BA, BB, BG, BH, BN, BR, BW, BY, BZ, CA, CH, CL, CN, CO, CR, CU, CZ, DE, DJ, DK, DM, DO, DZ, EC, EE, EG, ES, FI, GB, GD, GE, GH, GM, GT, HN, HR, HU, ID, IL, IN, IR, IS, IT, JO, JP, KE, KG, KH, KN, KP, KR, KW, KZ, LA, LC, LK, LR, LS, LU, LY, MA, MD, ME, MG, MK, MN, MW, MX, MY, MZ, NA, NG, NI, NO, NZ, OM, PA, PE, PG, PH, PL, PT, QA, RO, RS, RU, RW, SA, SC, SD, SE, SG, SK, SL,

(54) **Title:** ANALYSIS DEVICE, ANALYSIS METHOD, AND ANALYSIS PROGRAM

(54) 発明の名称: 解析装置、解析方法及び解析プログラム



11 Learning unit
12 Calculation unit
12a Learning model
13 Acquiring unit
14 Prediction unit
14a Prediction model
15 Storage unit
15a Learning data
16 Generation unit

(57) **Abstract:** Provided are an analysis device, an analysis method, and an analysis program for predicting the performance of a learning model when a learning process is performed with a plurality of algorithms. An analysis device 10 uses a prediction model, which is generated by supervised learning using as learning data first shape information representing a global shape of a first loss function set with respect to a predetermined problem and the performance of a learning model, to predict the performance of the learning model with respect to each of a plurality of algorithms when machine learning of the learning model is carried out on the basis of second shape information representing a global shape of a second loss function set with respect to a new problem so as to decrease the value of the second loss function.

ST, SV, SY, TH, TJ, TM, TN, TR, TT, TZ, UA, UG,
US, UZ, VC, VN, WS, ZA, ZM, ZW.

- (84) 指定国(表示のない限り、全ての種類の広域保護が可能): ARIPO (BW, GH, GM, KE, LR, LS, MW, MZ, NA, RW, SD, SL, ST, SZ, TZ, UG, ZM, ZW), ユーラシア (AM, AZ, BY, KG, KZ, RU, TJ, TM), ヨーロッパ (AL, AT, BE, BG, CH, CY, CZ, DE, DK, EE, ES, FI, FR, GB, GR, HR, HU, IE, IS, IT, LT, LU, LV, MC, MK, MT, NL, NO, PL, PT, RO, RS, SE, SI, SK, SM, TR), OAPI (BF, BJ, CF, CG, CI, CM, GA, GN, GQ, GW, KM, ML, MR, NE, SN, TD, TG).

添付公開書類:

- 一 国際調査報告 (条約第21条(3))

(57) 要約: 複数のアルゴリズムで学習処理を行った場合における学習モデルの性能を予測する解析装置、解析方法及び解析プログラムを提供する。解析装置10は、所定の問題について設定された第1損失関数の大域的形状を表す第1形状情報及び学習モデルの性能を学習データとする教師あり学習によって生成された予測モデルを用いて、新たな問題について設定された第2損失関数の大域的形状を表す第2形状情報に基づいて、第2損失関数の値を小さくするように学習モデルの機械学習を実行した場合の学習モデルの性能を、複数のアルゴリズムそれぞれについて予測する。

明 細 書

発明の名称： 解析装置、解析方法及び解析プログラム

技術分野

[0001] 本発明は、解析装置、解析方法及び解析プログラムに関する。

背景技術

[0002] 近年、いわゆる人工知能を様々な問題に応用する試みがなされている。例えば、下記特許文献1には、様々な現実的な事象における問題の解決に用いることを目的としたモデル選択装置が記載されている。

先行技術文献

特許文献

[0003] 特許文献1：特開2019-220063号公報

発明の概要

発明が解決しようとする課題

[0004] しかしながら、学習モデルの学習処理を行うためのアルゴリズムは複数知られており、問題に応じて学習処理のアルゴリズムを適切に選択しなければ、学習モデルの性能を十分に引き出せない場合がある。一般的には、学習モデルを設定する者の経験則に基づき、所定の問題に所定のアルゴリズムを用いることが行われており、選択されたアルゴリズムが適切であるかどうかの性能評価をする手段がなかった。

[0005] そこで、本発明は、複数のアルゴリズムで学習処理を行った場合における学習モデルの性能を予測する解析装置、解析方法及び解析プログラムを提供する。

課題を解決するための手段

[0006] 本発明の一態様に係る解析装置は、複数のアルゴリズムを用いて、所定の問題について設定された第1損失関数の値を小さくするように所定の学習モデルの機械学習をそれぞれ行う学習部と、機械学習に基づき、第1損失関数の大域的形状を表す第1形状情報と、学習モデルの性能とを、アルゴリズム

ごとに算出する算出部と、複数のアルゴリズムのうち少なくともいずれかを用いて、新たな問題について設定された第2損失関数の値を小さくするような機械学習が学習部により実行され、算出部により算出された第2損失関数の大域的形状を表す第2形状情報を取得する取得部と、第1形状情報及び学習モデルの性能を学習データとする教師あり学習によって生成された予測モデルを用いて、第2形状情報に基づいて、第2損失関数の値を小さくするように学習モデルの機械学習を実行した場合の学習モデルの性能を、複数のアルゴリズムそれぞれについて予測する予測部と、を備える。

[0007] この態様によれば、複数のアルゴリズムのうち少なくとも1つのアルゴリズムを用いて学習モデルの機械学習を実行することで、他のアルゴリズムを用いて学習モデルの機械学習を実行した場合に得られる学習モデルの性能を予測することができる。

発明の効果

[0008] 本発明によれば、複数のアルゴリズムで学習処理を行った場合における学習モデルの性能を予測する解析装置、解析方法及び解析プログラムを提供することができる。

図面の簡単な説明

[0009] [図1]本発明の第1実施形態に係る解析装置の機能ブロックを示す図である。
[図2]同実施形態に係る解析装置の物理的構成を示す図である。
[図3]同実施形態に係る解析装置によって学習処理を行った学習モデルの性能を示す図である。
[図4]同実施形態に係る解析装置により算出される形状情報を示す図である。
[図5]同実施形態に係る解析装置により算出される学習データを示す図である。
。
[図6]同実施形態に係る解析装置により実行される予測処理のフローチャートである。
[図7]同実施形態に係る解析装置により実行される予測モデル生成処理のフローチャートである。

[図8]同実施形態に係る解析装置によって学習処理を行った学習モデルの性能を示す図である。

[図9]同実施形態に係る解析装置により表示されるハイパーパラメータ調整画面を示す図である。

[図10]同実施形態に係る解析装置により実行される予測処理のフローチャートである。

[図11]第2実施形態に係る解析装置の機能ブロックを示す図である。

[図12]同実施形態において、学習モデルの機械学習に用いられる、所定の銘柄における株価の値動きデータを示す図である。

[図13]同実施形態に係る解析装置による機械学習において用いられた、強化学習アルゴリズム及び最適化アルゴリズムを示す図である。

[図14]同実施形態に係る推定モデル生成部が生成する推定モデルの一例を示す図である。

[図15]同実施形態に係る解析装置により実行される推定処理の一例を示すフローチャートである。

[図16]同実施形態に係る解析装置により実行される推定モデル生成処理の一例を示すフローチャートである。

発明を実施するための形態

[0010] 添付図面を参照して、本発明の実施形態について説明する。なお、各図において、同一の符号を付したものは、同一又は同様の構成を有する。

[0011] [第1実施形態]

図1は、本発明の第1実施形態に係る解析装置10の機能ブロックの一例を示す図である。解析装置10は、学習部11、算出部12、取得部13、予測部14、記憶部15及び生成部16を備える。解析装置10は、汎用のコンピュータで構成されてもよい。

[0012] 学習部11は、複数のアルゴリズムを用いて、所定の問題について設定された第1損失関数の値を小さくするように所定の学習モデルの機械学習をそれぞれ行う。ここで、所定の問題は、例えば画像データ、系列データ及びテ

キストデータの少なくともいずれかについて、分類、生成及び最適化の少なくともいずれかを行う問題を含む。ここで、画像データは、静止画のデータと、動画のデータとを含む。系列データは、音声データや株価のデータを含む。また、所定の学習モデルは、画像認識モデル、系列データ解析モデル、ロボットの制御モデル、強化学習モデル、音声認識モデル、音声生成モデル、画像生成モデル、自然言語処理モデル等を含み、例えば、CNN (Convolutional Neural Network)、RNN (Recurrent Neural Network)、LSTM (Long Short-Term Memory)、双方向LSTM、DQN (Deep Q-Network)、VAE (Variational AutoEncoder)、GANs (Generative Adversarial Networks)、WaveNet、BERT (Bidirectional Encoder Representations from Transformers)、Word2Vec、ランダムフォレスト、サポートベクターマシン、ロジスティック回帰、勾配ブースティング決定木及び主成分分析等のいずれかであり、その他学習に適用可能なモデルを含む。また、学習モデルは、既存の学習済みモデルを枝刈り (Pruning)、量子化 (Quantization)、蒸留 (Distillation) 又は転移 (Transfer) して得られるモデルを含む。なお、これらは一例に過ぎず、学習部11は、これら以外の問題について、学習モデルの機械学習を行ってもよい。

[0013] また、複数のアルゴリズムは、学習モデル12aの機械学習を行うアルゴリズムであり、学習モデル12aがニューラルネットワークを含む場合、誤差逆伝播法によりニューラルネットワークのパラメータを更新し、最適化するアルゴリズムであってよい。複数のアルゴリズムは、確率的勾配降下法 (stochastic gradient descent: SGD)、モーメントSGD、AdaGrad、RMSProp、AdaDelta及びADAM等を含む。また、複数のアルゴリズムは、学習モデル12aのパラメータを、量子ゲート方式又は量子アニーリング方式の量子コンピュータによって更新するアルゴリズムを含む。例えば、複数の弱学習器を組み合わせた1つの強学習器によって学習モデル12aを構成する場合、Hartmut Neven, Vasil S. Denchev, Geordie Rose, William G. Macready, "QBoost: Large Scale Classifier Training

with Adiabatic Quantum Optimization”, Proceedings of the Asian Conference on Machine Learning, PMLR 25:333-348, 2012.に記載のアルゴリズムを用いてよい。また、Jacob Biamonte, Peter Wittek, Nicola Pancotti, Patrick Rebentrost, Nathan Wiebe and Seth Lloyd, ”Quantum Machine Learning”, Nature volume 549, pages 195-202, 2017.に記載のアルゴリズムを用いてもよい。また、複数のアルゴリズムは、X G B o o s t、L i g h t G B M、バギング（並列的に学習するアルゴリズム）、ブースティング（前の弱学習器の学習結果を次の学習データに反映するアルゴリズム）及びスタッキング（二段階で学習を積み上げるアルゴリズム）を含む。また、複数のアルゴリズムは、下記参考文献1に記載の「アダプティブ・バルク・サーチ」のアルゴリズムを含む。

（参考文献1）「GPUの計算能力を最大限活用する組合せ最適化問題の新解法～1兆探索/秒を超えるアダプティブ・バルク・サーチ」、[online]、[令和2年8月25日検索]、<<https://www.hiroshima-u.ac.jp/news/59579>>

なお、これらは一例に過ぎず、複数のアルゴリズムは、これら以外のアルゴリズムを含んでよい。また、量子コンピュータは、超伝導線路により量子ビットを構成するものであったり、イオントラップにより量子ビットを構成するものであったり、量子ドットにより量子ビットを構成するものであったり、光回路によって量子ビットを構成するものであったりしてよく、ハードウェア構成は任意である。さらに、複数のアルゴリズムは、学習モデル12aのパラメータを、量子コンピュータ及び古典コンピュータのハイブリッド型コンピュータによって更新するアルゴリズムを含んでもよい。

[0014] 算出部12は、機械学習に基づき、第1損失関数の大域的形状を表す第1形状情報と、学習モデル12aの性能とを、アルゴリズムごとに算出する。所定の問題について設定された第1損失関数は、学習モデル12aの出力とラベルデータとに関する2乗誤差関数であったり、クロスエントロピー関数であったりしてよい。学習モデル12aが含む複数のパラメータを θ と表すとき、第1損失関数は、複数のパラメータ θ に関する関数 $L(\theta)$ と表せる

。本明細書では、関数 $L(\theta)$ の値を、第1損失関数の大域的形状を表す第1形状情報と呼ぶ。例えば、算出部12は、学習モデル12aの機械学習に基づき、パラメータ θ に対する関数 $L(\theta)$ の値を記録していき、第1損失関数の大域的形状を表す第1形状情報 $L(\theta)$ を算出する。

[0015] また、学習モデル12aの性能は、例えば、F値で表したり、F値／（学習処理の計算時間）で表したり、第1損失関数の値で表したりしてよい。なお、F値は、適合率（precision）をPと表し、再現率（recall）をRと表すとき、 $2PR / (P + R)$ により算出される値である。また、学習モデル12aの性能は、例えば、ME（平均誤差）、MAE（平均絶対誤差）、RMSE（平均平方二乗誤差）、MPE（平均誤差率）、MAPE（平均絶対誤差率）、RMSPPE（平均平方二乗誤差率）、ROC（Receiver Operating Characteristic）曲線及びAUC（Area Under the Curve）、Gini Norm、Kolmogorov-Smirnov又はPrecision/Recall等を用いて表してもよい。算出部12は、学習モデル12aの機械学習に基づき、F値等で表される学習モデル12aの性能を算出する。

[0016] 学習部11は、学習モデル12aのパラメータについて複数の初期値を設定し、複数のアルゴリズムを用いて、第1損失関数の値を小さくするように所定の学習モデル12aの機械学習を個別に実行又は並列に実行してもよい。並列実行の場合、算出部12は、機械学習に基づき、第1形状情報と、学習モデル12aの性能とを、アルゴリズムごとに並列して算出する。

[0017] 学習モデル12aのパラメータについて複数の初期値を設定する理由は、複数の初期値を用いて学習モデル12aの機械学習を実行することで、損失関数の極小値に対応するパラメータが選ばれてしまうおそれを少なくすることができるからである。これにより、大域的に最適な損失関数の最小値に対応するパラメータを選ぶことができる確率を上げることができる。また、学習モデル12aの機械学習を複数の初期値についてそれぞれ並列実行する場合、大域的な最適解をより高速に求めることができる。

[0018] 取得部13は、複数のアルゴリズムのうち少なくともいずれかを用いて、

新たな問題について設定された第2損失関数の値を小さくするような機械学習が学習部11により実行され、算出部12により算出された第2損失関数の大域的形状を表す第2形状情報を取得する。ここで、新たな問題は、画像データ、系列データ及びテキストデータの少なくともいずれかについて、分類、生成及び最適化の少なくともいずれかを行う問題を含む。また、第2損失関数は、学習モデル12aの出力とラベルデータとに関する2乗誤差関数であったり、クロスエントロピー関数であったりしてよく、第2形状情報は、複数のパラメータ θ に関する第2損失関数の関数形 $L(\theta)$ であってよい。

[0019] 予測部14は、第1形状情報及び学習モデル12aの性能を学習データとする教師あり学習によって生成された予測モデル14aを用いる。また、予測部14は、この予測モデル14aを用いて、第2形状情報に基づいて、第2損失関数の値を小さくするように学習モデル12aの機械学習を実行した場合の学習モデル12aの性能を、複数のアルゴリズムそれぞれについて予測する。例えば、予測部14は、予測モデル14aに、所定のアルゴリズムの第2形状情報を入力することで、その他のアルゴリズムを含む複数のアルゴリズムそれぞれについて、機械学習を実行した場合の学習モデル12aの性能を出力する。

[0020] 新たな問題について、いずれのアルゴリズムを用いれば学習モデル12aの性能を適切に引き出すことができるかを試行錯誤によって決定する場合、アルゴリズムの選定に時間を要する場合がある。本実施形態に係る解析装置10によれば、複数のアルゴリズムのうち少なくとも1つのアルゴリズムを用いて学習モデル12aの機械学習を実行することで、他のアルゴリズムを用いて学習モデル12aの機械学習を実行した場合に得られる学習モデル12aの性能を予測することができる。そのため、新たな問題が与えられた場合に、いずれのアルゴリズムを用いるべきか迅速に決定することができ、学習モデル12aの性能を適切に引き出すことができるようになる。

[0021] 学習部11は、1又は複数のハイパーパラメータを含む複数のアルゴリズム

ムを用いて、第1損失関数の値を小さくし、1又は複数のハイパーパラメータを複数の最適化アルゴリズムを用いて最適化して、所定の学習モデル12aの機械学習をそれぞれ行ってもよい。この場合、算出部12は、機械学習に基づき、第1損失関数の大域的形状を表す第1形状情報と、学習モデル12aの性能とを、複数の最適化アルゴリズムごとに算出する。ここで、ハイパーパラメータは、例えばアルゴリズムがSGDの場合、学習係数を含む。他のアルゴリズムに関しても、同様に、学習係数やモーメント係数といったハイパーパラメータが設定される。また、複数の最適化アルゴリズムは、例えば、ランダムサーチ、ベジアン最適化、CMA-ES、座標降下法、ネルダーミッド法、粒子群最適化及び遺伝的アルゴリズム等を含む。学習部11は、複数のアルゴリズムに関して1又は複数のハイパーパラメータを最適化する最適化アルゴリズムを用いた場合について、学習モデル12aの機械学習を実行した場合の学習モデル12aの性能を予測する。これにより、複数のアルゴリズムのうちいずれを選択すべきか予測するだけでなく、どのようなハイパーパラメータの最適化法を用いるべきであるか予測することができ、ハイパーパラメータチューニングに要する時間を短縮することができる。

[0022] 記憶部15は、第1形状情報及び学習モデル12aの性能を含む学習データ15aを記憶する。学習データ15aは、あるアルゴリズムによって学習モデル12aの機械学習を実行した場合における損失関数の大域的形状を表す第1形状情報と、その機械学習の結果得られた学習モデル12aの性能とを含む。

[0023] 生成部16は、学習データ15aを用いた教師あり学習によって、予測モデル14aを生成する。予測モデル14aは、例えばニューラルネットワークで構成されてよく、新たな問題について設定された第2損失関数の大域的形状を表す第2形状情報を入力として、複数のアルゴリズムを用いて、新たな問題について設定された第2損失関数の値を小さくするように学習モデル12aの機械学習を実行した場合の学習モデル12aの性能を予測するモデ

ルである。

[0024] 図2は、本実施形態に係る解析装置10の物理的構成の一例を示す図である。解析装置10は、演算部に相当するCPU (Central Processing Unit) 10aと、記憶部に相当するRAM (Random Access Memory) 10bと、記憶部に相当するROM (Read only Memory) 10cと、通信部10dと、入力部10eと、表示部10fと、を有する。これらの各構成は、バスを介して相互にデータ送受信可能に接続される。なお、本例では解析装置10が一台のコンピュータで構成される場合について説明するが、解析装置10は、複数のコンピュータ又は複数の演算部が組み合わされて実現されてもよい。また、図2で示す構成は一例であり、解析装置10はこれら以外の構成を有してもよいし、これらの構成のうち一部を有さなくてもよい。

[0025] CPU 10aは、RAM 10b又はROM 10cに記憶されたプログラムの実行に関する制御やデータの演算、加工を行う制御部である。CPU 10aは、複数のアルゴリズムを用いて、新たな問題について設定された第2損失関数の値を小さくするように学習モデルの機械学習を実行した場合の学習モデルの性能を、複数のアルゴリズムそれぞれについて予測するプログラム（解析プログラム）を実行する演算部である。CPU 10aは、入力部10eや通信部10dから種々のデータを受け取り、データの演算結果を表示部10fに表示したり、RAM 10bに格納したりする。

[0026] RAM 10bは、記憶部のうちデータの書き換えが可能なものであり、例えば半導体記憶素子で構成されてよい。RAM 10bは、CPU 10aが実行するプログラム、所定の問題について設定された損失関数の大域的形状及び学習モデルの性能を含む学習データといったデータを記憶してよい。なお、これらは例示であって、RAM 10bには、これら以外のデータが記憶されていてもよいし、これらの一部が記憶されていなくてもよい。

[0027] ROM 10cは、記憶部のうちデータの読み出しが可能なものであり、例えば半導体記憶素子で構成されてよい。ROM 10cは、例えば解析プログラムや、書き換えが行われないデータを記憶してよい。

- [0028] 通信部10dは、解析装置10を他の機器に接続するインターフェースである。通信部10dは、インターネット等の通信ネットワークに接続されてよい。
- [0029] 入力部10eは、ユーザからデータの入力を受け付けるものであり、例えば、キーボード及びタッチパネルを含んでよい。
- [0030] 表示部10fは、CPU10aによる演算結果を視覚的に表示するものであり、例えば、LCD (Liquid Crystal Display) により構成されてよい。表示部10fが演算結果を表示することは、XAI (eXplainable AI: 説明可能なAI) に貢献し得る。表示部10fは、例えば、損失関数の大域的形状を表示してよい。
- [0031] 解析プログラムは、RAM10bやROM10c等のコンピュータによって読み取り可能な記憶媒体に記憶されて提供されてもよいし、通信部10dにより接続される通信ネットワークを介して提供されてもよい。解析装置10では、CPU10aが解析プログラムを実行することにより、図1を用いて説明した様々な動作が実現される。なお、これらの物理的な構成は例示であって、必ずしも独立した構成でなくてもよい。例えば、解析装置10は、CPU10aとRAM10bやROM10cが一体化したLSI (Large-Scale Integration) を備えていてもよい。また、解析装置10は、GPU (Graphical Processing Unit) やASIC (Application Specific Integrated Circuit) を備えていてもよい。
- [0032] 図3は、本実施形態に係る解析装置10によって学習処理を行った学習モデルの性能の一例を示す図である。同図では、SGD、モーメントSGD (Momentum SGD)、AdaGrad、RMSProp、AdaDelta、ADAM、量子ゲート方式及び量子アニーリング方式というアルゴリズムを用い、それぞれ、ランダムサーチ (Random Search)、ベジアン最適化 (Bayesian Optimization)、CMA-ES、座標降下法 (Coordinate Search) 及びネルダーミード法 (Nelder-Mead) によって1又は複数のハイパーパラメータを最適化した場合における学習モデルの性能を示している。例えば、

$a_1 \sim a_5$ は、アルゴリズムとしてSGDを用いて、ランダムサーチ、ベジアン最適化、CMA-ES、座標降下法又はネルダーミッド法によって1又は複数のハイパーパラメータを最適化した場合における学習モデルの性能を表す数値である。なお、 $b_1 \sim b_5$ 、 $c_1 \sim c_5$ 、 $d_1 \sim d_5$ 、 $e_1 \sim e_5$ 、 $f_1 \sim f_5$ 、 $g_1 \sim g_5$ 及び $h_1 \sim h_5$ は、同様に学習モデルの性能を表す数値である。

[0033] 図4は、本実施形態に係る解析装置10により算出される形状情報の一例を示す図である。同図では、簡単のため、学習モデルのパラメータとして θ_1 及び θ_2 を示し、損失関数の値 $L(\theta)$ を示している。同図に示すように、損失関数の大域的形状は、複数の極小点を含み、最小点の探索が困難な場合がある。本実施形態に係る解析装置10は、このような損失関数の大域的形状を、学習モデル及び学習アルゴリズムの特徴量と捉え、損失関数の大域的形状から、複数のアルゴリズムを用いて学習モデルの学習処理を行った場合に関する学習モデルの性能を予測する。

[0034] 図5は、本実施形態に係る解析装置10により算出される学習データの一例を示す図である。同図では、SGD、モーメントSGD (Momentum SGD)、AdaGrad、RMSProp、AdaDelta、ADAM、量子ゲート方式及び量子アニーリング方式というアルゴリズムについて、第1形状情報及び学習モデルの性能を示している。例えば、 $L_a(\theta)$ は、アルゴリズムとしてSGDを用いた場合における第1形状情報を表し、 S_a は、アルゴリズムとしてSGDを用いた場合における学習モデルの性能を表す数値である。同様に、 $L_b(\theta)$ 、 $L_c(\theta)$ 、 $L_d(\theta)$ 、 $L_e(\theta)$ 、 $L_f(\theta)$ 、 $L_g(\theta)$ 及び $L_h(\theta)$ は、アルゴリズムとしてAdaGrad、RMSProp、AdaDelta、ADAM、量子ゲート方式又は量子アニーリング方式を用いた場合における第1形状情報を表す。また、 S_b 、 S_c 、 S_d 、 S_e 、 S_f 、 S_g 及び S_h は、アルゴリズムとしてAdaGrad、RMSProp、AdaDelta、ADAM、量子ゲート方式又は量子アニーリング方式を用いた場合における学習モデルの性能を表す数値で

ある。なお、学習モデルの性能は、図3に示すように、ハイパーパラメータの最適化アルゴリズムごとに算出し、それらを学習データとしてもよい。

[0035] 図6は、本実施形態に係る解析装置10により実行される予測処理の一例を示すフローチャートである。はじめに、解析装置10は、所定の問題及び所定の学習モデルの指定を他の情報処理装置から受け付ける（S10）。所定の問題及び所定の学習モデルの指定は、ユーザ入力されてよい。

[0036] 次に、解析装置10は、学習モデルのパラメータについて複数の初期値を設定し（S11）、1又は複数のハイパーパラメータを含む複数のアルゴリズムを用いて、第1損失関数の値を小さくし、1又は複数のハイパーパラメータを複数の最適化アルゴリズムを用いて最適化して、所定の学習モデルの機械学習をそれぞれ並列実行する（S12）。

[0037] また、解析装置10は、機械学習に基づき、第1損失関数の大域的形状を表す第1形状情報と、学習モデルの性能とを、アルゴリズムごとに並列して算出する（S13）。そして、解析装置10は、第1形状情報及び学習モデルの性能を学習データとして記憶部15に記憶する（S14）。

[0038] その後、解析装置10は、新たな問題の指定を他の情報処理装置から受け付ける（S15）。新たな問題の指定は、ユーザ入力されてよい。

[0039] 解析装置10は、複数のアルゴリズムのうち少なくともいずれかを用いて、新たな問題について設定された第2損失関数の値を小さくするような機械学習が学習部11により実行され、算出部12により算出された第2損失関数の大域的形状を表す第2形状情報を取得する（S16）。そして、解析装置10は、予測モデルを用いて、第2形状情報に基づいて、第2損失関数の値を小さくするように学習モデルの機械学習を実行した場合の学習モデルの性能を、複数のアルゴリズムそれぞれについて予測する（S17）。

[0040] 図7は、本実施形態に係る解析装置10により実行される予測モデル生成処理の一例を示すフローチャートである。はじめに、解析装置10は、第1形状情報及び学習モデルの性能を含む学習データを取得する（S20）。なお、学習データは、インターネット等の通信ネットワークを介して、外部記

憶装置から取得してもよい。

[0041] その後、解析装置 10 は、学習データを用いた教師あり学習によって、第 2 形状情報に基づいて、第 2 損失関数の値を小さくするように学習モデルの機械学習を実行した場合の学習モデルの性能を、複数のアルゴリズムそれぞれについて予測する予測モデルを生成する (S 21)。そして、解析装置 10 は、生成された予測モデルを記憶する。

[0042] 図 8 は、本実施形態に係る解析装置 10 によって学習処理を行った学習モデルの性能を示す図である。同図では、階層型クラスタリング、非階層型クラスタリング、トピックモデル、自己組織化マップ、アソシエーション分析、協調フィルタリング、正準相関分析、量子ゲート方式及び量子アニーリング方式という教師なし学習を用いて学習データを分類し、分類に応じた前処理アルゴリズムを適用して、それぞれ、ランダムサーチ (Random Search)、ベイジアン最適化 (Bayesian Optimization)、CMA-ES、座標降下法 (Coordinate Search) 及びネルダーミード法 (Nelder-Mead) によって 1 又は複数のハイパーパラメータを最適化した場合における学習モデルの性能を示している。G1～G5 は、教師なし学習として階層型クラスタリングを用いて、ランダムサーチ、ベイジアン最適化、CMA-ES、座標降下法又はネルダーミード法によって、階層型クラスタリングに含まれる 1 又は複数のハイパーパラメータを最適化した場合における学習モデルの性能を表す数値である。なお、G6～G45 は、同様に学習モデルの性能を表す数値である。

[0043] 学習部 11 は、1 又は複数のハイパーパラメータを含む複数の前処理アルゴリズムを用いて、機械学習に用いる学習データの前処理を行い、複数のアルゴリズムを用いて、第 1 損失関数の値を小さくし、1 又は複数のハイパーパラメータを複数の最適化アルゴリズムを用いて最適化して、所定の学習モデルについて、前処理された学習データを用いた機械学習をそれぞれ行う。そして、算出部 12 は、前処理された学習データを用いた機械学習に基づき、第 1 損失関数の大域的形状を表す第 1 形状情報と、学習モデルの性能とを

、複数の前処理アルゴリズムごとに算出する。

[0044] 複数の前処理アルゴリズムは、欠損値処理、外れ値の対応、連続値の離散化、データ操作、次元削減、ワンホットベクトル化、データ拡張、特徴量エンジニアリング及びビン分割を含んでよい。複数の前処理アルゴリズムは、学習データを教師なし学習を用いて分類し、分類に応じた前処理を行うアルゴリズムを含む。すなわち、複数の前処理アルゴリズムは、階層型クラスタリング、非階層型クラスタリング、トピックモデル、自己組織化マップ、アソシエーション分析、協調フィルタリング、正準相関分析、量子ゲート方式及び量子アニーリング方式といった教師なし学習を用いて学習データを分類し、分類に応じて欠損値処理、説明変数の絞り込み、ワンホットベクトル化及びビン分割の少なくともいずれかを行うアルゴリズムを含む。

[0045] 図9は、本実施形態に係る解析装置10により表示されるハイパーパラメータ調整画面を示す図である。同図では、学習アルゴリズムのハイパーパラメータを調整するためのスライドバーと、前処理アルゴリズムのハイパーパラメータを調整するためのスライドバーと、縦軸に学習アルゴリズムの種類を数値で表し、横軸に前処理アルゴリズムの種類を数値で表して、(L-損失関数)の値のヒートマップを表示している。ここで、Lは、損失関数の最大値である。なお、(L-損失関数)の値は、学習モデルの性能を表す値の一例であり、解析装置10は、損失関数の値のヒートマップに替えて、学習モデルの性能を示すF値やF値/(学習処理の計算時間)のヒートマップを表示してもよい。

[0046] 解析装置10は、複数のアルゴリズムに含まれる1又は複数のハイパーパラメータと、複数の前処理アルゴリズムに含まれる1又は複数のハイパーパラメータとを調整可能に表示し、学習モデルの性能を、複数のアルゴリズム及び複数の前処理アルゴリズムそれぞれについて表示する。解析装置10のユーザは、学習アルゴリズムのハイパーパラメータ及び前処理アルゴリズムのハイパーパラメータを調整しつつ、ヒートマップにより示される最も損失関数の値が小さくなる点(最尤点)を確認し、その点に対応する学習アルゴ

リズム及び前処理アルゴリズムを選択することで、複数の学習アルゴリズム及び複数の前処理アルゴリズムの中から最適なアルゴリズムを効率良く選択することができる。

[0047] 図10は、本実施形態に係る解析装置10により実行される予測処理のフローチャートである。はじめに、解析装置10は、学習アルゴリズムのハイパーパラメータの指定及び前処理アルゴリズムのハイパーパラメータの指定を受け付ける（S30）。

[0048] その後、解析装置10は、学習データを教師なし学習を用いて分類する（S31）。そして、解析装置10は、1又は複数のハイパーパラメータを含む複数の前処理アルゴリズムを用いて、機械学習に用いる学習データの前処理を行い、複数のアルゴリズムを用いて、第1損失関数の値を小さくし、1又は複数のハイパーパラメータを複数の最適化アルゴリズムを用いて最適化して、所定の学習モデルについて、前処理された学習データを用いた機械学習をそれぞれ実行する（S32）。

[0049] 解析装置10は、前処理された学習データを用いた機械学習に基づき、第1損失関数の大域的形状を表す第1形状情報と、学習モデルの性能とを、複数の前処理アルゴリズムごとに算出する（S33）。そして、解析装置10は、第1形状情報及び学習モデルの性能を学習データとして記憶する（S34）。

[0050] その後、解析装置10は、新たな問題の指定を受け付ける（S35）。そして、解析装置10は、複数の前処理アルゴリズムのうち少なくともいずれかを用いて、新たな問題について設定された第2損失関数の値を小さくするような機械学習が学習部により実行され、算出部により算出された第2損失関数の大域的形状を表す第2形状情報を取得する（S36）。

[0051] 最後に、解析装置10は、予測モデルを用いて、第2形状情報に基づいて、第2損失関数の値を小さくするように学習モデルの機械学習を実行した場合の学習モデルの性能を、複数の前処理アルゴリズムそれぞれについて予測する（S37）。

[0052] 以上説明した実施形態は、本発明の理解を容易にするためのものであり、本発明を限定して解釈するためのものではない。実施形態が備える各要素並びにその配置、材料、条件、形状及びサイズ等は、例示したものに限定されるわけではなく適宜変更することができる。また、異なる実施形態で示した構成同士を部分的に置換し又は組み合わせることが可能である。

[0053] [第2実施形態]

第2実施形態では、主に第1実施形態と異なる点について説明し、第1実施形態と実質的に同一の内容を適宜省略して説明する。なお、第2実施形態では、第1実施形態で説明した各種の構成が適用され得る。

[0054] 図11は、第2実施形態に係る解析装置20の機能ブロックを示す図である。第2実施形態に係る解析装置20は、学習部21、算出部22、取得部23、推定部24、記憶部25及び推定モデル生成部26を備える。第2実施形態に係る解析装置20は、第1実施形態に係る解析装置10が備える予測部14に代えて推定部24を備え、第1実施形態に係る生成部16に代えて推定モデル生成部26を備えている。なお、第2実施形態に係る解析装置20が備える学習部21、算出部22、取得部23及び記憶部25の機能は、少なくとも第1実施形態に係る解析装置10が備える対応する機能部の機能を有してもよい。

[0055] 第2実施形態に係るアルゴリズムは、例えば強化学習アルゴリズムであるものとする。学習部21は、複数の強化学習アルゴリズムのそれぞれに含まれる1又は複数のハイパーパラメータを複数の最適化アルゴリズムを用いて最適化し、最適化された1又は複数のハイパーパラメータを含む複数の強化学習アルゴリズムを用いて所定の学習モデルの機械学習をそれぞれ行う。

[0056] 具体的には、学習部21は、複数の強化学習アルゴリズムを用いて、所定の問題について設定されたトレーニングデータに基づき所定の学習モデルの機械学習を行う。本実施形態では、学習部21は、例えば、株価の値動きデータをトレーニングデータとして用いて、エージェントが得られる報酬を最大化するように学習モデルの機械学習を行う。なお、機械学習には、値動き

データの他に、例えば、各種のニュース及びソーシャルデータ（例えば、銘柄の評判に関する情報等）等が用いられてよい。本実施形態では、強化学習におけるエージェントの行動は、例えば、株の売買取引（具体的には、株の購入、売却、ホールド等）であり、報酬は株の売買取引による利益であり、報酬の最大化は利回りの最大化に相当する。このとき、学習部 2 1 は、所定時間単位で、例えば 1 μ 秒単位で学習モデルの機械学習を行ってよい。

[0057] 算出部 2 2 は、所定の問題について設定されたテストデータを用いて、学習モデルの性能を算出する。本実施形態では、テストデータは、例えば、株価の値動きデータを含んでよい。性能は、例えば、トレーニングデータを用いて学習モデルを評価したときに得られた利回り等であってもよい。

[0058] 記憶部 2 5 は、機械学習に用いられたデータ（トレーニングデータ及びテストデータ等、例えば値動きデータ）、強化学習アルゴリズム及び最適化アルゴリズム等を記憶する。また、記憶部 2 5 は、トレーニングデータと、強化学習アルゴリズム及び最適化アルゴリズムの組み合わせとを含む学習データ 2 5 a を記憶する。

[0059] 推定モデル生成部 2 6 は、学習データを用いた教師あり学習によって、新たな問題に応じた強化学習アルゴリズム及び最適化アルゴリズムの組み合わせを推定する推定モデルを生成する。具体的には、推定モデル生成部 2 6 は、トレーニングデータと、学習モデルの性能に基づき選択されるアルゴリズム及び最適化アルゴリズムの組み合わせとを学習データとする教師あり学習を行うことにより、新たな問題に応じたアルゴリズム及び最適化アルゴリズムの組み合わせを推定するための推定モデルを生成する。学習データとして用いられるアルゴリズム及び最適化アルゴリズムの組み合わせ（以下、「強化戦略」とも称する。）は、学習モデルの性能に基づいて選択されてよい。例えば、設定された問題について最適な強化戦略が、学習データとして推定モデル生成部 2 6 により選択されてよい。

[0060] 推定部 2 4 は、推定モデル 2 4 a を用いて、新たな問題について設定された設定データに基づいて、新たな問題に応じた強化学習アルゴリズム及び最

適化アルゴリズムの組み合わせを推定する。ここで、新たな問題について設定された設定データは、例えば、機械学習に用いられていない新たな株価値動きデータであってよい。

[0061] また、第2実施形態に係る解析装置20は、第1実施形態に係る解析装置10が備える図2に示した物理的構成と実質的に同一の物理的構成を備えるものとする。ここでは、第2実施形態に係る解析装置20が備える物理的構成と、第1実施形態に係る解析装置10が備える物理的構成との間の異なる点について簡単に説明する。

[0062] 第2実施形態に係るCPU10aは、複数のアルゴリズムのそれぞれに含まれる1又は複数のハイパーパラメータを複数の最適化アルゴリズムを用いて最適化して、複数のアルゴリズムを用いて所定の学習モデルの機械学習をそれぞれ行い、学習モデルの性能をアルゴリズム及び前記最適化アルゴリズムごとに算出するプログラム（解析プログラム）を実行する演算部である。

[0063] また、第2実施形態に係るRAM10bは、CPU10aが実行するプログラム、トレーニングデータ、テストデータ、強化学習アルゴリズム及び最適化アルゴリズムの組み合わせといったデータを記憶してよい。なお、これらは例示であって、RAM10bには、これら以外のデータが記憶されていてもよいし、これらの一部が記憶されていなくてもよい。また、第2実施形態に係る表示部10fは、例えば、推定モデルによる推定結果等を表示してよい。

[0064] 図12は、本実施形態において、学習モデルの機械学習に用いられる、所定の銘柄における株価値動きデータを示す図である。値動きデータは、例えば、1日単位で変動する株価値のデータであり、2019年の1月から12月までのデータであるものとする。本実施形態では、例えばホールドアウト法等が用いられ、値動きデータがトレーニングデータ及びテストデータに分割される。例えば、2019年の1月頭から6月末までの値動きデータをトレーニングデータとし、2019年の7月頭から12月末までの値動きデー

タをテストデータとしてよい。

[0065] 図13は、本実施形態に係る解析装置20による機械学習において用いられた、強化学習アルゴリズム及び最適化アルゴリズムを示す図である。同図に示すように、本実施形態では、Turtle Trading agent、Moving Average agent、Signal Rolling agent、Policy Gradient agent、Q-learning agent、Evolution Strategy agent、Double Q-learning agent、Recurrent Q-learning agent、Double Recurrent Q-learning agent、Duel Q-learning agent、Double Duel Q-learning agent、Duel Recurrent Q-learning agent、Double Duel Recurrent Q-learning agent、Actor-critic agent、Actor-critic Duel agent、Actor-critic Recurrent agent、Actor-critic Duel Recurrent agent、Curiosity Q-learning agent、Recurrent Curiosity Q-learning agent、Duel Curiosity Q-learning agent、Neuro-evolution agent、Neuro-evolution with Novelty search agent、ABCD strategy agent、Deep Evolution Strategyといった強化学習アルゴリズムを用いる。また、本実施形態では、それぞれの強化学習アルゴリズムについて、ランダムサーチ (Random Search)、ベイジアン最適化 (Bayesian Optimization)、CMA-ES、座標降下法 (Coordinate Search) 及びネルダーミッド法 (Nelder-Mead) の最適化アルゴリズムによって1又は複数のハイパーパラメータを最適化した。

[0066] 図13に示すG1～G120は、強化学習アルゴリズム及び最適化アルゴリズムの組み合わせを特定する番号である。本実施形態では、G1～G120の強化戦略により構築した学習モデルのそれぞれについて、算出部22により性能が算出される。性能の算出は、テストデータによる評価（例えば、得られた利回り）であってよい。これにより、最適な強化戦略、すなわち最も評価の高い学習モデルを構築できる強化戦略を選択できるようになる。

[0067] 本実施形態における例では、解析装置20は、互いに銘柄の異なる複数の値動きデータのそれぞれについて最適な強化戦略を特定して、複数の識別番号のそれぞれに値動きデータ及び最適な強化戦略に関する情報を対応付けて記憶してよい。複数の識別番号のそれぞれに対応付けられるデータは、例え

ば、値動きデータ、銘柄（例えば、株式会社A）、値動きデータの期間（例えば、1月1日～4月30日）、トレーニングデータの期間（例えば、1月1日～2月28日）、最適な強化戦略（例えばG1）、テストデータの期間（例えば、3月1日～4月30日）及び利回り（例えば、12%）等であってよい。ここで、利回りは、最適な強化戦略をテストデータで評価した場合に得られる利回りであり、IRR（内部収益率）であってよい。ここで、複数の識別番号のそれぞれに対応付けられた情報に基づき抽出されるトレーニングデータ及び最適な強化戦略は、後述する推定モデルを生成するための学習データとなる。

[0068] 図14は、推定モデル生成部26が生成する推定モデルの一例を示す図である。図14に示すように、推定モデルは、入力層31、隠れ層32及び出力層33を含むニューラルネットワークにより構成される。推定モデル生成部26は、トレーニングデータと最適な強化戦略とを学習データとして教師あり学習を行い、推定モデルを生成する。具体的には、推定モデル生成部26は、トレーニングデータを入力層31に入力し、出力層33から最適な強化戦略が出力されるように、重みづけパラメータの学習を行う。このとき、推定モデル生成部26は、トレーニングデータに加えて、値動きデータに関する各種のデータ（例えば、銘柄等）を付帯情報として入力層31に入力してもよい。

[0069] 生成された推定モデルの入力層31に新たな問題について設定された値動きデータ（及び付帯情報）が入力されると、出力層33から新たな問題に応じた強化戦略が出力される。例えば、図13に示したG11の強化戦略が新たな問題に対して最適な強化戦略として出力され得る。ここで、解析装置20は、ソフトマックス関数を用いて、図12に示した120個の組み合わせを性能（例えば、利回り）に応じた順番（例えば利回り順）に、解析装置20が備える表示部に表示してもよい。これにより、例えば銘柄等に応じた適切な強化戦略を選択して、利回りのよい学習モデルを構築することが可能となる。

- [0070] 図15は、本実施形態に係る解析装置20により実行される推定処理の一例を示すフローチャートである。はじめに、解析装置20は、所定の問題及び所定の学習モデルの指定を他の情報処理装置から受け付ける（S40）。所定の問題及び所定の学習モデルの指定は、ユーザ入力されてよい。
- [0071] 次に、解析装置20は、学習モデルのパラメータについて複数の初期値を設定する（S41）。次に、解析装置20は、複数の強化学習アルゴリズムのそれぞれに含まれる1又は複数のハイパーパラメータを複数の最適化アルゴリズムを用いて最適化し、所定の問題について設定されたトレーニングデータに基づき、最適化された1又は複数のハイパーパラメータを含む複数の強化学習アルゴリズムを用いて学習モデルの機械学習をそれぞれ個別実行又は並列実行する（S42）。
- [0072] また、解析装置20は、機械学習に基づき、学習モデルの性能を、強化学習アルゴリズム及び最適化アルゴリズムごとに個別に又は並列に算出する（S43）。そして、解析装置20は、所定の問題について設定されたトレーニングデータと、強化学習アルゴリズム及び最適化アルゴリズムの組み合わせとを、学習データとして記憶部25に記憶する（S44）。
- [0073] その後、解析装置20は、新たな問題の指定を他の情報処理装置から受け付ける（S45）。新たな問題の指定は、ユーザ入力されてよい。次に、解析装置20は、新たな問題について設定された設定データを取得する（S46）。
- [0074] そして、解析装置20は、後述する推定モデル生成処理により生成された推定モデルを用いて、新たな問題について設定された設定データに基づいて、新たな問題に応じた強化学習アルゴリズム及び最適化アルゴリズムの組み合わせを推定する（S47）。
- [0075] 図16は、本実施形態に係る解析装置20により実行される推定モデル生成処理の一例を示すフローチャートである。はじめに、解析装置20は、所定の問題について設定されたトレーニングデータと、強化学習アルゴリズム及び最適化アルゴリズムの組み合わせとを含む学習データを取得する（S5

0)。なお、学習データは、インターネット等の通信ネットワークを介して、外部記憶装置から取得してもよい。

[0076] その後、解析装置20は、学習データを用いた教師あり学習によって、新たな問題に応じた強化学習アルゴリズム及び最適化アルゴリズムの組み合わせを推定する推定モデルを生成する(S51)。そして、解析装置20は、生成された推定モデルを記憶する(S52)。

[0077] 従来では、学習モデルを構築する様々なアルゴリズムと、そのアルゴリズムに含まれるハイパーパラメータを最適化する様々な最適化アルゴリズムが提案されている。しかしながら、アルゴリズム及び最適化アルゴリズムの組み合わせは多数あり、適切な組み合わせを選ぶことが困難であった。本実施形態によれば、機械学習により構築された学習モデルの性能が、アルゴリズム及び最適化アルゴリズムごとに評価される。このため、より適切なアルゴリズム及び最適化アルゴリズムの組み合わせを簡便に選択することが可能となる。

[0078] なお、本実施形態では、アルゴリズムが強化学習アルゴリズムであるものとして説明したが、アルゴリズムは、これに限定されるものではなく、教師あり学習及び教師なし学習等の各種の機械学習に用いられるアルゴリズムであってよい。すなわち、本開示の技術によれば、各種のアルゴリズム及び最適化アルゴリズムごとの学習モデルの性能を算出することが可能となる。

[0079] また、第2実施形態では、第1実施形態において説明した各種の構成が適用され得る。例えば、第1実施形態において説明した前処理が施されてよい。これにより、前処理、強化学習及びハイパーパラメータの最適化等の各種の処理が自動的に実行され、本開示のアルゴリズムによる株の売買取引の実行が可能となる。

[0080] [応用例]

以下の第1～第3応用例では、上記実施形態の応用例について説明する。以下の応用例では、主に第2実施形態に係る解析装置20が用いられることを想定して説明する。

[0081] [第1応用例]

第2実施形態では、強化学習におけるエージェントが株の売買の取引を行う例を用いて説明した。強化学習はこれに限定されるものではなく、本開示の技術は、各種の強化学習に適用され得る。例えば、強化学習のエージェントは、自動運転により走行する自動運転車であってもよい。この場合には、例えば、 $(MAD + FDE) / 2$ のスコアを指標として、そのスコアが小さくなるほど、エージェントがより多くの報酬を獲得できるように設定されてよい。この場合、アルゴリズムは、例えば、Social LSTM、Social GAN、MX-LSTM、Social Force、SR-LSTM、RED、Ind-TF及びAMENet等を含んでよい。なお、これらのアルゴリズムは、下記文献に記載されている。

(Social LSTM) A. Alahi, K. Goel, V. Ramanathan, A. Robicquet, L. Fei-Fei, S. Savarese, Social lstm: Human trajectory prediction in crowded spaces, in: In Proceedings of CVPR, 2016, pp. 961-971.

(Social GAN) A. Gupta, J. Johnson, L. Fei-Fei, S. Savarese, A. Alahi, Social gan: Socially acceptable trajectories with generative adversarial networks, in: In Proceedings of CVPR, 2018, pp. 2255-2264.

(MX-LSTM) I. Hasan, F. Setti, T. Tsesmelis, A. Del Bue, F. Galasso, M. Cristani, Mxlstm: mixing tracklets and vislets to jointly forecast trajectories and head poses, in: In Proceedings of CVPR, 2018, pp. 6067-6076.

(Social Force) D. Helbing, P. Molnar, Social force model for pedestrian dynamics, Physical review E 51 (5) (1995) 4282.

(SR-LSTM) P. Zhang, W. Ouyang, P. Zhang, J. Xue, N. Zheng, Sr-lstm: State refinement for lstm towards pedestrian trajectory prediction, in: In Proceedings of CVPR, 2019, pp. 12085-12094.

(RED) S. Becker, R. Hug, W. Hubner, M. Arens, An evaluation of

trajectory prediction approaches and notes on the trajnet benchmark, arXiv preprint arXiv:1805.07663 (2018).

(Ind-TF) F. Giuliari, I. Hasan, M. Cristani, F. Galasso, Transformer networks for trajectory forecasting, arXiv preprint arXiv:2003.08111 (2020).

(AMENet) AMENet: Attentive Maps Encoder Network for Trajectory Prediction Hao Chenga, Wentong Liaob, Michael Ying Yangc, Bodo Rosenhahn^b, Monika Sester.

[0082] また、最適化アルゴリズムは、例えば、ランダムサーチ、ベイジアン最適化、CMA-ES、座標降下法及びネルダーミッド法等を含む。なお、強化学習の指標は、 $(MAD + FDE) / 2$ に限らず、MADあるいはFDE等であってもよい。これらのアルゴリズム及び最適化アルゴリズムの組み合わせについて、例えば算出部22により、学習モデルの性能が算出されてよい。エージェントは、アルゴリズム及び最適化アルゴリズムの組み合わせの中で、どの組み合わせが最適であるかをLSTM等によって生成された学習モデルの性能に基づき判断できる。

[0083] [第2応用例]

従来、ミリ波又はサブテラヘルツ波の無線通信ネットワークに関する技術が開発されている。ミリ波又はサブテラヘルツ波の無線通信ネットワークの性能を最大限に引き出す上で、従来にない低遅延及び高信頼性を実現することが課題となっている。機械学習を利用して無線ネットワークが周囲の感覚を獲得することが、この課題を解決する有効な手段の一つとなり得る。

[0084] 下記の参考文献2では、ディープラーニング及びコンピュータビジョンを利用することで、上記課題を解決することが試みられている。具体的には、参考文献2には、観測されたRGB画像のシーケンス及びビームフォーミングベクトルから、将来起こりうるリンク閉塞(link-brockage)を予測する方法を学習するディープニューラルネットワークアーキテクチャが開示されている。

[0085] しかし、参考文献2によって示されているハイパーパラメータの最適化アルゴリズムはADAMであり、バッチサイズは1000である。この前提条件において、リンク閉塞の予測精度は86%程度である。この参考文献2において開示されている技術に対しても、本明細書に開示のように、ハイパーパラメータを自動的に最適化したり、適切な学習モデルを構築できるアルゴリズム及び最適化アルゴリズムの組み合わせを選択したりすることにより、予測精度の改善が可能になると考えられる。

(参考文献2) G. Charan, M. Alrabeiah, and A. Alkhateeb, Vision-Aided Dynamic Blockage Prediction for 6G Wireless Communication Networks, arXiv preprint arXiv:2006.09902 (2020).

[0086] [第3応用例]

また、下記参考文献3では、自律移動ロボットからカーブミラー越しに見える人を推測する技術が記載されている。参考文献3では、FCN-8s at onceに基づくネットワークが採用されている。このネットワークは、2つのネットワークからなり、そのうちの1つのネットワークは、セマンティックセグメンテーションを行う分類ネットワークであり、もう一方のネットワークは、深度画像予測を行う回帰ネットワークである。分類ネットワーク及び回帰ネットワークは、ともに事前学習済みのVGG16モデルのfc7層までを用いて重みを初期化している。特に、pool5層までは、特微量抽出器として扱われる。ただし、回帰ネットワークの入力は、3チャンネル色画像Irealと、センサから取得した深度画像Drealとを変換した3チャンネル深度画像Dcolorの2つを連結させた6チャンネル画像とするため、conv1__1層のみ重みを複製して6チャンネルに対応させている。

(参考文献3) 内海佑斗、北川晋吾、矢野倉伊織、岡田慧、稲葉雅幸：CNNによる深度予測に基づく鏡を活用した死角の物体知覚、人工知能学会全国大会論文集、第33回全国大会(2019)。

[0087] しかし、参考文献3に記載では、ハイパーパラメータの最適化及び学習モ

デルの選定が自動化されていないため、推測の精度が十分でないと考えられる。また、ロボットが随時人など対象（他には、自転車又は自動車等）を検知するためには、より早く処理が実行されることも求められる。本開示の技術によれば、ハイパーパラメータの最適化の調整及び適切な学習モデルの選定が自動化されるため、推測の精度及びスピードを向上できる。

[0088] [第4 応用例]

第4 応用例では、解析装置が適切なアルゴリズムの組み合わせを推論する処理（以下、「推論処理」ともいう。）と、アルゴリズムの組み合わせを全探索する処理（以下、「全探索処理」ともいう。）とを並列に実行する例を説明する。

[0089] 第4 応用例では、上述した前処理アルゴリズムを用いた学習データの前処理、最適化アルゴリズムを用いたハイパーパラメータの最適化及び強化学習アルゴリズムを用いた機械学習が行われることで学習モデルが生成されてよい。また、第4 応用例では、前処理アルゴリズム、最適化アルゴリズム及び強化学習アルゴリズムの組み合わせを単にアルゴリズムの組み合わせとも称する。また、解析装置は、アルゴリズムの組み合わせのそれぞれについての性能を、第2 実施形態において説明したように、例えばトレーニングデータを用いて算出してよい。さらに、解析装置は、第2 実施形態において説明した各種の方法をアルゴリズムの組み合わせに適用して、新たな問題に応じたアルゴリズムの組み合わせを推定するための推定モデルを生成してよい。このとき、トレーニングデータ、アルゴリズムの組み合わせ及び性能を学習データとして推定モデルが生成されてよい。

[0090] 第4 応用例では、解析装置は、例えばネットワークに接続された外部の装置からデータを取得して、第1 時間単位で学習データ（例えば、株価の値動きデータ等）を追加または更新し、第1 定時間単位で所定の学習モデルでアクション（例えば、株の取引等）を行ってよい。このとき、解析装置は、第2 時間単位で推論処理を実行し、さらに、第3 時間単位で全探索処理を実行できる。ここで、第1 時間は第2 時間より短く、第2 時間は第3 時間よりも

短くてよい。第1時間、第2時間及び第3時間は、特に限定されないが、第4応用例では、それぞれ、1 μ 秒、1分及び1時間等である例について説明する。

[0091] 全探索処理は、アルゴリズムの組み合わせのそれぞれを用いて、取得した学習データに基づく機械学習により学習モデルを生成し、それぞれのアルゴリズムの組み合わせの性能を評価して、アルゴリズムの組み合わせのそれぞれと性能とを対応付けた実績データを更新する処理である。ここでは、第2時間の間に取得されるデータを用いて、全てのアルゴリズムの組み合わせの性能を評価するために第3時間がかかるものとする。従って、600万のデータを用いて、実績データが1時間に1回更新される。更新された実績データを参照することにより、最も適切なアルゴリズムの組み合わせを特定することが可能となり、実績データの少なくとも一部は、推定モデルを生成するための学習データとなる。

[0092] 推論処理は、推定モデルに例えば株価の値動きデータ等を入力して、入力したデータに応じたアルゴリズムの組み合わせを取得し、株の取引を行う学習モデルを取得したアルゴリズムに基づき生成される学習モデルに切り替える処理である。例えば、解析装置は、600万のデータを推定モデルに入力してアルゴリズムの組み合わせを取得し、取得したアルゴリズムの組み合わせにより生成した学習モデルに切り替える。また、解析装置は、学習モデルを用いて、第1時間単位でアクションを行うことができる。

[0093] 解析装置は、第1時間毎という短時間毎に株の取引を行うため、取引の執行に強く、具体的には、突発的な株価の上昇傾向あるいは下降傾向、大恐慌及びバブル等に強い。このとき、全てのアルゴリズムの組み合わせが探索されない場合には、適切な学習モデルに基づく取引が行われたとしても、機会損失あるいは単純損失のリスクが常に孕んでいる。

[0094] また、アルゴリズムの組み合わせが1つである場合には、解析装置による株の取引が他者に予測され、解析装置に逆張りをさせるための攻撃が仕掛けられる可能性がある。例えば、解析装置が10億円を株式Aに投資すること

が予測され、1000億円を空売りする等の攻撃が仕掛けられることが考えられる。このような攻撃に対する防御としては、次の数 μ 秒後の取引では解析装置にも空売りさせる、あるいは一度に大きな損失を被る可能性がある選択をしないように解析装置を制御すること等が考えられる。

[0095] また、解析装置は、取引方法の指示に強く、具体的には、新たに取得した学習データ（例えば、1時間前に取得した株価の値動きデータ等）を用いて、第2時間毎に、より適切なアルゴリズムの組み合わせに切り替えることができる。すなわち、解析装置の内部において、株の取引を行うためのアルゴリズムの組み合わせを随時変化させながら、株の取引を行うことができる。これによって、機会損失及び単純損失のリスクが低減される。また、用いられるアルゴリズムの組み合わせが分散されるため、上述した逆張りの攻撃等により損失が生じる可能性を低減できる。

[0096] また、解析装置は、第3時間毎にアルゴリズムの組み合わせの実績データを更新でき、取引の測定に強く、具体的には、非常に高い精度を持って株価の値動きに対する最適解を見つけることができる。処理の性質上、データの処理に時間がかかるものの、非常に優れた推定モデルの学習データを生成することが可能となる。

[0097] 応用例4に係る解析装置は、学習モデルを用いた取引、推論処理及び全探索処理を繰り返しながら、より適切な処理を行うことができるようになる。

[0098] なお、第4応用例では、解析装置が株の取引を行う例について説明したが、上述した推論処理及び全探索処理を並列して実行する処理等は、自動車における自動運転等の各種の目的に利用され得る。

[0099] [第5応用例]

上記実施形態では、主に、解析装置が、前処理アルゴリズムを用いた学習データの最適化、最適化アルゴリズムを用いたハイパーパラメータの最適化及びアルゴリズムを用いた機械学習を行う例を説明した。第5応用例では、解析装置が、前処理アルゴリズムによる前処理が行われる前に学習データにさらに前処理を行う、いわば前処理の前処理を行う例を説明する。

[0100] 前処理の前処理を行うアルゴリズムは、例えば、C A S H問題に初めて言及した参考文献4、P y t h o nで書かれたA u t o M L (Automated Machine Learning)に関する参考文献5、メタ学習 (meta-learning)を導入した参考文献6、及び遺伝的アルゴリズムで柔軟なパイプラインを生成することが記載された参考文献7に記載のアルゴリズム等であってよい。

[0101] (参考文献4) C. Thornton, F. Hutter, H. H. Hoos, and K. L. Brown, Auto-WEKA: Combined Selection and Hyperparameter Optimization of Classification Algorithms, arXiv preprint arXiv:1208.3719, 2013.

(参考文献5) B. Komer, J. Bergstra and C. Eliasmith, Hyperopt-Sklearn: Automatic Hyperparameter Configuration for Scikit-Learn, In Proc. of THE 13th PYTHON IN SCIENCE CONF.:pages 34-40, 2014.

(参考文献6) M. Feurer, A. Klein, K. Eggenberger, J. Springenberg, M. Blum and F. Hutter, Efficient and Robust Automated Machine Learning, NIPS, 2015.

(参考文献7) R. S. Olson, N. Bartley, R. J. Urbanowicz and J. H. Moore, Evaluation of a Tree-based Pipeline Optimization Tool for Automating Data Science, arXiv preprint arXiv:1603.06212, 2016.

[0102] また、解析装置は、これらの参考文献に記載された前処理の前処理を行うアルゴリズム (具体的には、これらの参考文献において、学習データに基づく前処理アルゴリズム、最適化アルゴリズム及びアルゴリズムが実行される前までのアルゴリズム) により生成されたデータに基づいて、前処理アルゴリズム、最適化アルゴリズム及びアルゴリズムの組み合わせを用いて学習モデルを生成してよい。さらに、解析装置は、これらのアルゴリズムの組み合わせ毎に性能を算出してよい。

[0103] 前処理の前処理が施された学習データに、前処理を行い、ハイパーパラメータの最適化を行い、アルゴリズムを用いた学習モデルの生成を行うことにより、より汎用性の高いA IであるA G I (Artificial General Intelligence: 汎用A I) を生成できることが期待される。すなわち、例えば脳波デー

タあるいは画像データ等のあらゆる学習データを利用したAIを実現することが期待できる。

符号の説明

[0104] 10, 20…解析装置、10a…CPU、10b…RAM、10c…ROM、10d…通信部、10e…入力部、10f…表示部、11, 21…学習部、12, 22…算出部、12a, 22a…学習モデル、13, 23…取得部、14…予測部、14a…予測モデル、24…推定部、24a…推定モデル、15, 25…記憶部、15a, 25a…学習データ、16…生成部、26…推定モデル生成部

請求の範囲

[請求項1] 複数のアルゴリズムを用いて、所定の問題について設定された第1損失関数の値を小さくするように所定の学習モデルの機械学習をそれぞれ行う学習部と、

前記機械学習に基づき、前記第1損失関数の大域的形状を表す第1形状情報と、前記学習モデルの性能とを、アルゴリズムごとに算出する算出部と、

前記複数のアルゴリズムのうち少なくともいずれかを用いて、新たな問題について設定された第2損失関数の値を小さくするような機械学習が前記学習部により実行され、前記算出部により算出された前記第2損失関数の大域的形状を表す第2形状情報を取得する取得部と、

前記第1形状情報及び前記学習モデルの性能を学習データとする教師あり学習によって生成された予測モデルを用いて、前記第2形状情報に基づいて、前記第2損失関数の値を小さくするように前記学習モデルの機械学習を実行した場合の前記学習モデルの性能を、前記複数のアルゴリズムそれぞれについて予測する予測部と、

を備える解析装置。

[請求項2] 前記学習部は、1又は複数のハイパーパラメータを含む前記複数のアルゴリズムを用いて、前記第1損失関数の値を小さくし、前記1又は複数のハイパーパラメータを複数の最適化アルゴリズムを用いて最適化して、前記所定の学習モデルの機械学習をそれぞれ行い、

前記算出部は、前記機械学習に基づき、前記第1損失関数の大域的形状を表す第1形状情報と、前記学習モデルの性能とを、最適化アルゴリズムごとに算出する、

請求項1に記載の解析装置。

[請求項3] 前記学習データを用いた教師あり学習によって、前記予測モデルを生成する生成部をさらに備える、

請求項1又は2に記載の解析装置。

- [請求項4] 前記学習部は、前記学習モデルのパラメータについて複数の初期値を設定し、前記複数のアルゴリズムを用いて、前記第1損失関数の値を小さくするように前記所定の学習モデルの機械学習を並列実行し、
前記算出部は、前記機械学習に基づき、前記第1形状情報と、前記学習モデルの性能とを、アルゴリズムごとに並列して算出する、
請求項1から3のいずれか一項に記載の解析装置。
- [請求項5] 前記学習モデルは、ニューラルネットワークを用いたモデルを含む、
請求項1から4のいずれか一項に記載の解析装置。
- [請求項6] 前記複数のアルゴリズムは、前記ニューラルネットワークのパラメータを誤差逆伝播法によって更新するアルゴリズムを含む、
請求項5に記載の解析装置。
- [請求項7] 前記所定の問題及び前記新たな問題は、画像データ、系列データ及びテキストデータの少なくともいずれかについて、分類、生成及び最適化の少なくともいずれかを行う問題を含む、
請求項1から6のいずれか一項に記載の解析装置。
- [請求項8] 前記複数のアルゴリズムは、前記学習モデルのパラメータを、量子ゲート方式又は量子アニーリング方式の量子コンピュータによって更新するアルゴリズムを含む、
請求項1から7のいずれか一項に記載の解析装置。
- [請求項9] 前記学習部は、1又は複数のハイパーパラメータを含む複数の前処理アルゴリズムを用いて、前記機械学習に用いる学習データの前処理を行い、前記複数のアルゴリズムを用いて、前記第1損失関数の値を小さくし、前記1又は複数のハイパーパラメータを複数の最適化アルゴリズムを用いて最適化して、前記所定の学習モデルについて、前処理された前記学習データを用いた機械学習をそれぞれ行い、
前記算出部は、前処理された前記学習データを用いた機械学習に基づき、前記第1損失関数の大域的形状を表す第1形状情報と、前記学

習モデルの性能とを、前記複数の前処理アルゴリズムごとに算出する、

請求項 1 から 8 のいずれか一項に記載の解析装置。

[請求項10] 前記複数の前処理アルゴリズムは、前記学習データを教師なし学習を用いて分類し、分類に応じた前処理を行うアルゴリズムを含む、請求項 9 に記載の解析装置。

[請求項11] 前記複数のアルゴリズムに含まれる 1 又は複数のハイパーパラメータと、前記複数の前処理アルゴリズムに含まれる 1 又は複数のハイパーパラメータとを調整可能に表示し、前記学習モデルの性能を、前記複数のアルゴリズム及び前記複数の前処理アルゴリズムそれぞれについて表示する、

請求項 9 又は 10 に記載の解析装置。

[請求項12] 解析装置に備えられたプロセッサによって、複数のアルゴリズムを用いて、所定の問題について設定された第 1 損失関数の値を小さくするように所定の学習モデルの機械学習をそれぞれ行うことと、

前記機械学習に基づき、前記第 1 損失関数の大域的形状を表す第 1 形状情報と、前記学習モデルの性能とを、アルゴリズムごとに算出することと、

前記複数のアルゴリズムのうち少なくともいずれかを用いて、新たな問題について設定された第 2 損失関数の値を小さくするような機械学習が実行され、前記第 2 損失関数の大域的形状を表す第 2 形状情報を取得することと、

前記第 1 形状情報及び前記学習モデルの性能を学習データとする教師あり学習によって生成された予測モデルを用いて、前記第 2 形状情報に基づいて、前記第 2 損失関数の値を小さくするように前記学習モデルの機械学習を実行した場合の前記学習モデルの性能を、前記複数のアルゴリズムそれぞれについて予測することと、

を実行する解析方法。

[請求項13]

解析装置に備えられたプロセッサに、

複数のアルゴリズムを用いて、所定の問題について設定された第1損失関数の値を小さくするように所定の学習モデルの機械学習をそれぞれ行うことと、

前記機械学習に基づき、前記第1損失関数の大域的形状を表す第1形状情報と、前記学習モデルの性能とを、アルゴリズムごとに算出することと、

前記複数のアルゴリズムのうち少なくともいずれかを用いて、新たな問題について設定された第2損失関数の値を小さくするような機械学習が実行され、当該機械学習に基づき、前記第2損失関数の大域的形状を表す第2形状情報を取得することと、

前記第1形状情報及び前記学習モデルの性能を学習データとする教師あり学習によって生成された予測モデルを用いて、前記第2形状情報に基づいて、前記第2損失関数の値を小さくするように前記学習モデルの機械学習を実行した場合の前記学習モデルの性能を、前記複数のアルゴリズムそれぞれについて予測することと、

を実行させる解析プログラム。

[請求項14]

複数のアルゴリズムのそれぞれに含まれる1又は複数のハイパーパラメータを複数の最適化アルゴリズムを用いて最適化し、最適化された1又は複数のハイパーパラメータを含む複数のアルゴリズムを用いて所定の学習モデルの機械学習をそれぞれ行う学習部と、

前記機械学習に基づき、前記学習モデルの性能を、前記アルゴリズム及び前記最適化アルゴリズムごとに算出する算出部と、

を備える解析装置。

[請求項15]

前記アルゴリズムは、強化学習アルゴリズムであり、

前記学習部は、複数の前記強化学習アルゴリズムを用いて、前記所定の問題について設定されたトレーニングデータに基づき所定の学習

モデルの機械学習を行い、

前記算出部は、前記所定の問題について設定されたテストデータを用いて、前記学習モデルの性能を算出する、

請求項 1 4 に記載の解析装置。

[請求項16]

前記トレーニングデータと前記性能に基づき選択される強化学習アルゴリズム及び最適化アルゴリズムの組み合わせとを学習データとする教師あり学習を行うことにより、新たな問題に応じた強化学習アルゴリズム及び最適化アルゴリズムの組み合わせを推定するための推定モデルを生成する推定モデル生成部をさらに備える、

請求項 1 5 に記載の解析装置。

[請求項17]

解析装置に備えられたプロセッサによって、

複数のアルゴリズムのそれぞれに含まれる 1 又は複数のハイパーパラメータを複数の最適化アルゴリズムを用いて最適化し、最適化された 1 又は複数のハイパーパラメータを含む複数のアルゴリズムを用いて所定の学習モデルの機械学習をそれぞれ行うことと、

前記機械学習に基づき、前記学習モデルの性能を、前記アルゴリズム及び前記最適化アルゴリズムごとに算出することと、

を実行する解析方法。

[請求項18]


解析装置に備えられたプロセッサに、

複数のアルゴリズムのそれぞれに含まれる 1 又は複数のハイパーパラメータを複数の最適化アルゴリズムを用いて最適化し、最適化された 1 又は複数のハイパーパラメータを含む複数のアルゴリズムを用いて所定の学習モデルの機械学習をそれぞれ行うことと、


前記機械学習に基づき、前記学習モデルの性能を、前記アルゴリズム及び前記最適化アルゴリズムごとに算出することと、

を実行させる解析プログラム。

[図1]




[図2]



[図3]

	Random Search	Bayesian Optimization	CMA-ES	Coordinate Search	Nelder-Mead
SGD	a1	a2	a3	a4	a5
Momentum SGD	b1	b2	b3	b4	b5
AdaGrad	c1	c2	c3	c4	c5
RMSProp	d1	d2	d3	d4	d5
AdaDelta	e1	e2	e3	e4	e5
ADAM	f1	f2	f3	f4	f5
量子ゲート方式	g1	g2	g3	g4	g5
量子アニーリング方式	h1	h2	h3	h4	h5


[図4]




[図5]

	第1形状情報	学習モデルの性能
SGD	$La(\theta)$	Sa
Momentum SGD	$Lb(\theta)$	Sb
AdaGrad	$Lc(\theta)$	Sc
RMSProp	$Ld(\theta)$	Sd
AdaDelta	$Le(\theta)$	Se
ADAM	$Lf(\theta)$	Sf
量子ゲート方式	$Lg(\theta)$	Sg
量子アニーリング方式	$Lh(\theta)$	Sh

[図6]




[図7]




[図8]

	Random Search	Bayesian Optimization	CMA-ES	Coordinate Search	Nelder-Mead
階層型クラスタリング	G1	G2	G3	G4	G5
非階層型クラスタリング	G6	G7	G8	G9	G10
トピックモデル	G11	G12	G13	G14	G15
自己組織化マップ	G16	G17	G18	G19	G20
アソシエーション分析	G21	G22	G23	G24	G25
協調フィルタリング	G26	G27	G28	G29	G30
正準相関分析	G31	G32	G33	G34	G35
量子アニーリング	G36	G37	G38	G39	G40
量子ゲート	G41	G42	G43	G44	G45


[図9]




[図10]



[図11]




[図12]




[図13]

	Random Search	Bayesian optimization	CMA-ES	Coordinate-search method	Nelder-Mead
Turtle Trading agent	G1	G2	G3	G4	G5
Moving Average agent	G6	G7	G8	G9	G10
Signal Rolling agent	G11	G12	G13	G14	G15
Policy Gradient agent	G16	G17	G18	G19	G20
Q-learning agent	G21	G22	G23	G24	G25
Evolution Strategy agent	G26	G27	G28	G29	G30
Double Q-learning agent	G31	G32	G33	G34	G35
Recurrent Q-learning agent	G36	G37	G38	G39	G40
Double Recurrent Q-learning agent	G41	G42	G43	G44	G45
Duel Q-learning agent	G46	G47	G48	G49	G50
Double Duel Q-learning agent	G51	G52	G53	G54	G55
Duel Recurrent Q-learning agent	G56	G57	G58	G59	G60
Double Duel Recurrent Q-learning agent	G61	G62	G63	G64	G65
Actor-critic agent	G66	G67	G68	G69	G70
Actor-critic Duel agent	G71	G72	G73	G74	G75
Actor-critic Recurrent agent	G76	G77	G78	G79	G80
Actor-critic Duel Recurrent agent	G81	G82	G83	G84	G85
Curiosity Q-learning agent	G86	G87	G88	G89	G90
Recurrent Curiosity Q-learning agent	G91	G92	G93	G94	G95
Duel Curiosity Q-learning agent	G96	G97	G98	G99	G100
Neuro-evolution agent	G101	G102	G103	G104	G105
Neuro-evolution with Novelty search agent	G106	G107	G108	G109	G110
ABCD strategy agent	G111	G112	G113	G114	G115
Deep Evolution Strategy	G116	G117	G118	G119	G120

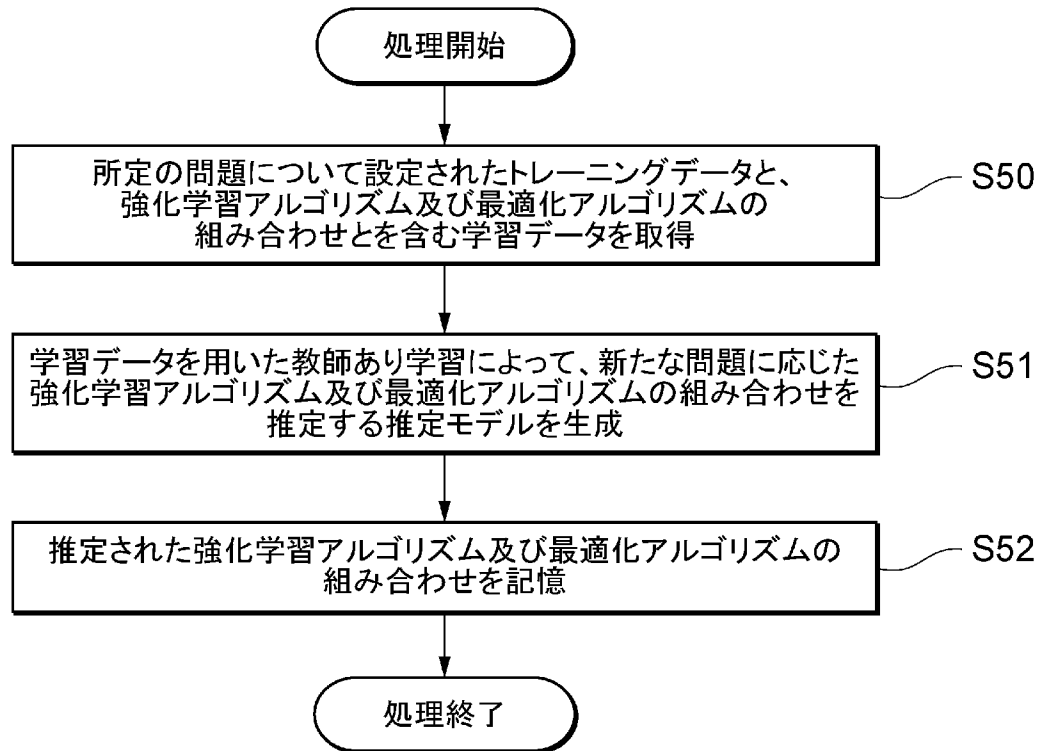
[図14]



[図15]



[図16]



INTERNATIONAL SEARCH REPORT

International application No.

PCT/JP2020/036328

A. CLASSIFICATION OF SUBJECT MATTER G06N 20/00 (2019.01) i FI: G06N20/00 130 According to International Patent Classification (IPC) or to both national classification and IPC		
B. FIELDS SEARCHED Minimum documentation searched (classification system followed by classification symbols) G06N3/00-99/00 Documentation searched other than minimum documentation to the extent that such documents are included in the fields searched Published examined utility model applications of Japan 1922-1996 Published unexamined utility model applications of Japan 1971-2020 Registered utility model specifications of Japan 1996-2020 Published registered utility model applications of Japan 1994-2020 Electronic data base consulted during the international search (name of data base and, where practicable, search terms used)		
C. DOCUMENTS CONSIDERED TO BE RELEVANT		
Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
Y A	JP 2018-66136 A (HOKKAIDO GAS CO., LTD.) 26 April 2018 (2018-04-26) paragraphs [0064]-[0069]	14-15, 17-18 16
Y	クジラ飛行机、外 2 名, Python による AI・機械学習・深層学習アプリのつくり方, 初版, ソシム株式会社, 20 February 2019, pp. 112-114 in particular, page 114 "hint of improvement", non-official translation (KUJIRAHIKOUZUKUE et al., "A method for making AI, machine learning, and deep learning by Python", 1st edition, SOCYM CO., LTD.)	14-15, 17-18
A	JP 5-298277 A (HITACHI, LTD.) 12 November 1993 (1993-11-12)	1-18
A	JP 5-61848 A (HITACHI, LTD.) 12 March 1993 (1993-03-12)	1-18
A	JP 2019-159769 A (FUJITSU LTD.) 19 September 2019 (2019-09-19)	1-18
A	JP 2005-135287 A (INCORPORATED ADMINISTRATIVE AGENCY NTL AGRICULTURAL AND BIO-ORIENTED RESEARCH ORGANIZATION) 26 May 2005 (2005-05-26)	1-18
☐ Further documents are listed in the continuation of Box C. ☒ See patent family annex.		
* Special categories of cited documents: "A" document defining the general state of the art which is not considered to be of particular relevance "E" earlier application or patent but published on or after the international filing date "L" document which may throw doubts on priority claim(s) or which is cited to establish the publication date of another citation or other special reason (as specified) "O" document referring to an oral disclosure, use, exhibition or other means "P" document published prior to the international filing date but later than the priority date claimed "T" later document published after the international filing date or priority date and not in conflict with the application but cited to understand the principle or theory underlying the invention "X" document of particular relevance; the claimed invention cannot be considered novel or cannot be considered to involve an inventive step when the document is taken alone "Y" document of particular relevance; the claimed invention cannot be considered to involve an inventive step when the document is combined with one or more other such documents, such combination being obvious to a person skilled in the art "&" document member of the same patent family		
Date of the actual completion of the international search 02 December 2020 (02.12.2020)		Date of mailing of the international search report 15 December 2020 (15.12.2020)
Name and mailing address of the ISA/ Japan Patent Office 3-4-3, Kasumigaseki, Chiyoda-ku, Tokyo 100-8915, Japan		Authorized officer Telephone No.

INTERNATIONAL SEARCH REPORT

International application No.

PCT/JP2020/036328

Box No. II Observations where certain claims were found unsearchable (Continuation of item 2 of first sheet)

This international search report has not been established in respect of certain claims under Article 17(2)(a) for the following reasons:

1. ☐ Claims Nos.:
because they relate to subject matter not required to be searched by this Authority, namely:

2. ☐ Claims Nos.:
because they relate to parts of the international application that do not comply with the prescribed requirements to such an extent that no meaningful international search can be carried out, specifically:

3. ☐ Claims Nos.:
because they are dependent claims and are not drafted in accordance with the second and third sentences of Rule 6.4(a).

Box No. III Observations where unity of invention is lacking (Continuation of item 3 of first sheet)

This International Searching Authority found multiple inventions in this international application, as follows:
See extra sheet

1. ☐ As all required additional search fees were timely paid by the applicant, this international search report covers all searchable claims.
2. ☒ As all searchable claims could be searched without effort justifying additional fees, this Authority did not invite payment of additional fees.
3. ☐ As only some of the required additional search fees were timely paid by the applicant, this international search report covers only those claims for which fees were paid, specifically claims Nos.:

4. ☐ No required additional search fees were timely paid by the applicant. Consequently, this international search report is restricted to the invention first mentioned in the claims; it is covered by claims Nos.:

Remark on Protest

- ☐ The additional search fees were accompanied by the applicant's protest and, where applicable, the payment of a protest fee.
- ☐ The additional search fees were accompanied by the applicant's protest but the applicable protest fee was not paid within the time limit specified in the invitation.
- ☐ No protest accompanied the payment of additional search fees.

INTERNATIONAL SEARCH REPORT

Information on patent family members

International application No.

PCT/JP2020/036328

Patent Documents referred in the Report	Publication Date	Patent Family	Publication Date
JP 2018-66136 A	26 Apr. 2018	(Family: none)	
JP 5-298277 A	12 Nov. 1993	(Family: none)	
JP 5-61848 A	12 Mar. 1993	(Family: none)	
JP 2019-159769 A	19 Sep. 2019	(Family: none)	
JP 2005-135287 A	26 May 2005	US 2005/0096758 A1	

INTERNATIONAL SEARCH REPORT

International application No.

PCT/JP2020/036328

<Continuation of Box No. III>

Claims 1-18 are classified into the following two inventions.

(Invention 1) Claims 1-13

Claims 1-13 have the special technical feature of "calculating, for each algorithm, first shape information indicating an overall shape of a first loss function and the performance of a learning model on the basis of machine learning, acquiring second shape information indicating an overall shape of a second loss function by performing machine learning that decreases the value of the second loss function set for a new problem by using at least one of a plurality of algorithms, and using a prediction model generated through supervised learning for which the first shape information and the performance of the learning model are used as learning data so as to predict, for each of the plurality of algorithms, the performance of the learning model when the machine learning of the learning model is performed so as to decrease the value of the second loss function". Thus, claims 1-13 are classified as invention 1.

(Invention 2) Claims 14-18

Claims 14-18 share, with claim 1 classified as invention 1, the common technical feature of having: a "learning unit, which performs machine learning of a prescribed learning model by using a plurality of algorithms; and a calculation unit, which calculates, for each of the algorithms, the performance of the learning model on the basis of the machine learning. However, this technical feature does not make a contribution over the prior art in light of the disclosure of document 1 (JP 2018-66136 A), and is thus not considered to be a special technical feature. Furthermore, claims 14-18 share no other identical or corresponding technical features with claim 1.

Furthermore, claims 14-18 are not dependent on claim 1. Furthermore, claims 14-18 are not substantially identical or equivalent to any of the claims classified as invention 1.

Therefore, claims 14-18 cannot be classified as invention 1.

Claims 14-18 have the special technical feature of "optimizing one or more hyper-parameters included in a plurality of algorithms respectively by using a plurality of optimizing algorithms, performing machine learning of a prescribed learning model by using the plurality of algorithms including the optimized one or more hyper-parameters, and calculating, for each of the algorithms and each of the optimizing algorithms, the performance of the learning model on the basis of the machine learning". Thus, claims 14-18 are classified as invention 2.

A. 発明の属する分野の分類（国際特許分類（IPC）） G06N 20/00(2019.01)i FI: G06N20/00 130		
B. 調査を行った分野		
調査を行った最小限資料（国際特許分類（IPC）） G06N3/00-99/00		
最小限資料以外の資料で調査を行った分野に含まれるもの 日本国実用新案公報 1922-1996年 日本国公開実用新案公報 1971-2020年 日本国実用新案登録公報 1996-2020年 日本国登録実用新案公報 1994-2020年		
国際調査で使用した電子データベース（データベースの名称、調査に使用した用語）		
C. 関連すると認められる文献		
引用文献の カテゴリー*	引用文献名 及び一部の箇所が関連するときは、その関連する箇所の表示	関連する 請求項の番号
Y A	JP 2018-66136 A（北海道瓦斯株式会社）26.04.2018（2018-04-26） [0064] - [0069]	14-15, 17-18 16
Y	クジラ飛行機、外2名、PythonによるAI・機械学習・深層学習アプリのつくり方、初版、ソシム株式会社、2019.02.20, pp.112-114 特にp.114「改良のヒント」	14-15, 17-18
A	JP 5-298277 A（株式会社日立製作所）12.11.1993（1993-11-12）	1-18
A	JP 5-61848 A（株式会社日立製作所）12.03.1993（1993-03-12）	1-18
A	JP 2019-159769 A（富士通株式会社）19.09.2019（2019-09-19）	1-18
A	JP 2005-135287 A（独立行政法人農業・生物系特定産業技術研究機構）26.05.2005（2005-05-26）	1-18
☐ C欄の続きにも文献が列挙されている。 ☒ パテントファミリーに関する別紙を参照。		
* 引用文献のカテゴリー “A” 特に関連のある文献ではなく、一般的技術水準を示すもの “E” 国際出願日前の出願または特許であるが、国際出願日以後に公表されたもの “L” 優先権主張に疑義を提起する文献又は他の文献の発行日若しくは他の特別な理由を確立するために引用する文献（理由を付す） “O” 口頭による開示、使用、展示等に言及する文献 “P” 国際出願日前で、かつ優先権の主張の基礎となる出願の日の後に公表された文献 “T” 国際出願日又は優先日後に公表された文献であって出願と抵触するものではなく、発明の原理又は理論の理解のために引用するもの “X” 特に関連のある文献であって、当該文献のみで発明の新規性又は進歩性がないと考えられるもの “Y” 特に関連のある文献であって、当該文献と他の1以上の文献との、当業者にとって自明である組合せによって進歩性がないと考えられるもの “&” 同一パテントファミリー文献		
国際調査を完了した日 02.12.2020		国際調査報告の発送日 15.12.2020
名称及びあて先 日本国特許庁(ISA/JP) 〒100-8915 日本国 東京都千代田区霞が関三丁目4番3号		権限のある職員（特許庁審査官） 杉浦 孝光 5B 5287 電話番号 03-3581-1101 内線 3545

第III欄 発明の単一性が欠如しているときの意見（第1ページの3の続き）

次に述べるようにこの国際出願に二以上の発明があるとこの国際調査機関は認めた。

請求項1－18に示す請求の範囲は、以下の2つの発明に区分される。

（発明1）請求項1－13

請求項1－13は、「機械学習に基づき、第1損失関数の大域的形状を表す第1形状情報と、学習モデルの性能とを、アルゴリズムごとに算出し、複数のアルゴリズムのうち少なくともいずれかを用いて、新たな問題について設定された第2損失関数の値を小さくするような機械学習が実行され、前記第2損失関数の大域的形状を表す第2形状情報を取得し、前記第1形状情報及び前記学習モデルの性能を学習データとする教師あり学習によって生成された予測モデルを用いて、前記第2形状情報に基づいて、前記第2損失関数の値を小さくするように前記学習モデルの機械学習を実行した場合の前記学習モデルの性能を、前記複数のアルゴリズムそれぞれについて予測する」という特別な技術的特徴を有しているため、発明1に区分する。

（発明2）請求項14－18

請求項14－18は、発明1に区分された請求項1と、「複数のアルゴリズムを用いて、所定の学習モデルの機械学習をそれぞれ行う学習部と、前記機械学習に基づき、前記学習モデルの性能をアルゴリズムごとに算出する算出部」を備えるという共通の技術的特徴を有している。しかしながら、当該技術的特徴は、文献1（JP 2018-66136 A）の開示内容に照らし、先行技術に対する貢献をもたらすものではないから、特別な技術的特徴であるとはいえない。また、請求項14－18と請求項1との間に、他に同一の又は対応する技術的特徴は存在しない。

さらに、請求項14－18は、請求項1の従属請求項ではない。また、請求項14－18は、発明1に区分されたいずれの請求項に対しても実質同一又はそれに準ずる関係にない。

したがって、請求項14－18は発明1に区分できない。

そして、請求項14－18は、「複数のアルゴリズムのそれぞれに含まれる1又は複数のハイパーパラメータを複数の最適化アルゴリズムを用いて最適化し、最適化された1又は複数のハイパーパラメータを含む複数のアルゴリズムを用いて所定の学習モデルの機械学習をそれぞれ行い、前記機械学習に基づき、前記学習モデルの性能を、前記アルゴリズム及び前記最適化アルゴリズムごとに算出する」という特別な技術的特徴を有しているため、発明2に区分する。

1. ☐ 出願人が必要な追加調査手数料をすべて期間内に納付したので、この国際調査報告は、すべての調査可能な請求項について作成した。
2. ☒ 追加調査手数料を要求するまでもなく、すべての調査可能な請求項について調査することができたので、追加調査手数料の納付を求めなかった。
3. ☐ 出願人が必要な追加調査手数料を一部のみしか期間内に納付しなかったため、この国際調査報告は、手数料の納付のあった次の請求項のみについて作成した。
4. ☐ 出願人が必要な追加調査手数料を期間内に納付しなかったため、この国際調査報告は、請求の範囲の最初に記載されている発明に係る次の請求項について作成した。

追加調査手数料の異議の申立てに関する注意

- ☐ 追加調査手数料及び、該当する場合には、異議申立手数料の納付と共に、出願人から異議申立てがあった。
- ☐ 追加調査手数料の納付と共に出願人から異議申立てがあったが、異議申立手数料が納付命令書に示した期間内に支払われなかった。
- ☐ 追加調査手数料の納付はあったが、異議申立てはなかった。

国際調査報告
 パテントファミリーに関する情報

国際出願番号

PCT/JP2020/036328

引用文献			公表日	パテントファミリー文献	公表日
JP	2018-66136	A	26.04.2018	(ファミリーなし)	
JP	5-298277	A	12.11.1993	(ファミリーなし)	
JP	5-61848	A	12.03.1993	(ファミリーなし)	
JP	2019-159769	A	19.09.2019	(ファミリーなし)	
JP	2005-135287	A	26.05.2005	US	2005/0096758 A1