

(19)日本国特許庁(JP)

(12)特許公報(B2)

(11)特許番号
特許第7470784号
(P7470784)

(45)発行日 令和6年4月18日(2024.4.18)

(24)登録日 令和6年4月10日(2024.4.10)

(51)国際特許分類

F I

G 0 6 F 11/34 (2006.01)

G 0 6 F 11/34 1 4 7

G 0 6 F 11/34 1 6 6

請求項の数 9 (全12頁)

(21)出願番号	特願2022-520973(P2022-520973)	(73)特許権者	520266557
(86)(22)出願日	令和2年10月6日(2020.10.6)		ピーディーエフ ソリューションズ, イ
(65)公表番号	特表2023-501062(P2023-501062		ンコーポレイテッド
	A)		アメリカ合衆国, カリフォルニア州 9
(43)公表日	令和5年1月18日(2023.1.18)		5 0 5 0, サンタクララ, 2 8 5 8 デ
(86)国際出願番号	PCT/US2020/054431		ラ クルズ ブルバード
(87)国際公開番号	WO2021/071854	(74)代理人	100114775
(87)国際公開日	令和3年4月15日(2021.4.15)		弁理士 高岡 亮一
審査請求日	令和5年10月5日(2023.10.5)	(74)代理人	100121511
(31)優先権主張番号	62/911,346		弁理士 小田 直
(32)優先日	令和1年10月6日(2019.10.6)	(74)代理人	100202751
(33)優先権主張国・地域又は機関	米国(US)		弁理士 岩堀 明代
早期審査対象出願		(74)代理人	100208580
			弁理士 三好 玲奈
		(74)代理人	100191086

最終頁に続く

(54)【発明の名称】 異常機器トレース検出および分類

(57)【特許請求の範囲】

【請求項1】

半導体機器トレースデータ内の異常を検出および分類するためのプロセスであって、前記プロセスは、

それぞれの半導体機器センサから複数のオリジナルトレースを受信してプロセッサベースのモデルに組み込むことと、

前記プロセッサベースのモデルを用いて前記複数のオリジナルトレースに関する少なくとも第1のキー特徴を識別することと、

前記プロセッサベースのモデルによって、前記複数のオリジナルトレースのうち少なくとも第1のオリジナルトレースセット内の複数の異常を識別することと、

前記プロセッサベースのモデルを用いて前記第1のキー特徴に基づいて前記第1のオリジナルトレースセットの各々を修正することと、

前記プロセッサベースのモデルを用いて修正された第1のトレースセットの各々から基底特徴セットを生成することと、

前記プロセッサベースのモデルを用いて前記修正された第1のトレースセットおよび前記基底特徴セットから複数の再現されたトレースを作成することと、

前記第1のオリジナルトレースセット、前記修正された第1のトレースセット、および前記再現されたトレースに基づいて異常を検出および分類するために機械学習モデルを訓練することと、

トレースデータ内の異常を識別および分類するために半導体機器の動作環境内に前記機

械学習モデルを展開することと、
を備える、プロセス。

【請求項 2】

前記それぞれの半導体機器センサから追加のトレースを受信することと、
前記追加のトレースの第 1 のセット内の追加の異常を識別することと、
統計的特性の基本セットを除去するために前記追加のトレースを修正することと、
修正された追加のトレースから前記基底特徴セットを生成することと、
前記修正された追加のトレースから再現された追加のトレースを作成することと、
前記第 1 のオリジナルトレースセット、前記修正された追加のトレース、および前記再現された追加のトレースに基づいて前記機械学習モデルを更新することと、
を更に備える、請求項 1 に記載のプロセス。

10

【請求項 3】

前記基底特徴セット内で捕捉されない未知のトレース変動として残差特徴を決定することと、
第 1 の標的特徴に既知の影響を及ぼす補足特徴を決定することと、
前記第 1 のオリジナルトレースセット、前記修正された追加のトレース、前記再現された追加のトレース、前記基底特徴セット、前記残差特徴、および前記補足特徴に基づいて前記機械学習モデルを更新することと、
を更に備える、請求項 2 に記載のプロセス。

【請求項 4】

前記第 1 のオリジナルトレースセットを、第 1 の事前定義された標的特徴を評価するために役立つものとして識別すること
を更に備える、請求項 1 に記載のプロセス。

20

【請求項 5】

前記第 1 のオリジナルトレースセットを、複数の事前定義された標的特徴を評価するために役立つものとして識別すること
を更に備える、請求項 1 に記載のプロセス。

【請求項 6】

前記基底特徴セットを生成することは、
前記第 1 のオリジナルトレースセットの統計的特性のセットを計算することと、
前記統計的特性のセットを除去するために前記第 1 のオリジナルトレースセットを修正することと、
修正された第 1 のトレースセットに関するアルゴリズム的解法を計算することと、
を備え、
前記アルゴリズム的解法および前記統計的特性のセットは、前記基底特徴セットを形成する、請求項 1 に記載のプロセス。

30

【請求項 7】

前記複数のオリジナルトレースは、大部分が通常のトレースを含み、前記複数の異常は、わずかな異常のみを表す、請求項 1 に記載のプロセス。

【請求項 8】

選択されたトレース異常をレビューするためのグラフィックユーザインタフェースを提供することと、

40

前記グラフィックユーザインタフェースからの第 1 の入力として、前記選択されたトレース異常に関連付けられることになる複数の事前定義されたクラスのうち 1 つを受信することと、

前記グラフィックユーザインタフェースからの第 2 の入力として、前記選択されたトレース異常に割り当てられることになる複数の事前定義されたアクションのうち 1 つを受信することと、
を更に備える、請求項 1 に記載のプロセス。

【請求項 9】

50

命令を有する非一時的コンピュータ可読媒体であって、前記命令は、プロセッサによって実行されるときに、前記プロセッサに、

それぞれの半導体機器センサから複数のオリジナルトレースを受信してプロセッサベースのモデルに組み込むことと、

前記プロセッサベースのモデルを用いて前記複数のオリジナルトレースに関する少なくとも第1のキー特徴を識別することと、

前記複数のオリジナルトレースのうち少なくとも第1のオリジナルトレースセット内の複数の異常を識別することと、

前期第1のキー特徴に基づいて前記第1のオリジナルトレースセットの各々を修正することと、

修正された第1のトレースセットの各々から基底特徴セットを生成することと、

前記修正された第1のトレースセットおよび前記基底特徴セットから複数の再現されたトレースを作成することと、

前記第1のオリジナルトレースセット、前記修正された第1のトレースセット、および前記再現されたトレースに基づいて異常を検出および分類するために機械学習モデルを訓練するための命令を生成することと、
を行わせ、

前期非一時的コンピュータ可読媒体は、トレースデータ内の異常を識別および分類するために半導体機器の動作環境を監視するプロセッサ内に展開される、非一時的コンピュータ可読媒体。

【発明の詳細な説明】

【技術分野】

【0001】

関連出願の相互参照

本出願は、参照によってその全体が本願に組み込まれる、2019年10月6日に出願された“Equipment Trouble Prevention (ETP): An effective approach to Anomalous Equipment Trace Detection and Classification without Prior Labeling”と題された米国仮特許出願第62/911346号からの優先権を主張するものである。

【0002】

本出願は、半導体機器の障害の検出および分類に関し、特に、未知の異常機器動作条件を検出および分類するためにセンサトレースを監視および処理するための方式に関する。

【背景技術】

【0003】

機器センサの時間トレースを監視することによる機器障害の検出は、半導体製造において長期的に認識されているが非常に難しい問題である。故障検出および分類(FDC)の典型的なアプローチは、センサトレースから要約統計(多くの場合、キー番号またはインジケータと呼ばれる)を計算し、その後、それらの統計を監視し、主に工学知識に基づいて異常を識別することである。

【0004】

たとえば、図1Aにおいて、縦の破線の間にある領域は、半導体プロセスの一部分または1ステップからの4つの異なる機器センサトレース101、102、103、104を表示するプロセスウィンドウ100である。通常、図1Bに示すように、トレースの各ステップについて統計が計算される。しかし、この統計は、トレース104のグラフから図1Aにおいて視覚的に明らかな異常110を示すことに失敗している。このように、統計的プロセス制御技術のみに頼ることによって、重大な異常が見逃され得る。当然、統計的プロセス制御アプローチの効果は変動し、要約統計の品質に大きく依存する。加えて、要約統計を計算するためのルーティンは、プロセス変更に伴い頻繁に更新される必要がある。よって、FDC要約統計ルーティンの構成およびメンテナンスは、希少な資源を大量

10

20

30

40

50

に投資することを意味する。

【 0 0 0 5 】

任意の中程度に複雑なプロセスステップのセンサを十分に表すために必要な統計の数は、数千または数万にも上ることがあり、疑似信号を大量に関与させる。製品データおよび/またはインラインメトロロジの分析に基づいて関連統計を選択する試みは、疑似信号の低減に役立つことが示されているが、そのような試みは、十分な応答データを必要とする上、過去に観察されていない障害を予測することはできない。

【 0 0 0 6 】

他のアプローチは、トレースの複製を伴い、たとえばオートエンコーダニューラルネットワークまたは主成分と同様に単純な何かを用いて、大部分のトレースを正確に再現し得る限定された基底ベクトルのセットが識別される。残差率の高いトレースは異常であると想定され、異常を検出するために残差二乗和が用いられ得る。しかし、このレプリケータアプローチは、多数のトレースの中で異常を識別するためには効果的であるが、基底ベクトルは多くの場合、明らかな物理的解釈を有さないもので、その情報に基づいてユーザが異常を分類することは難しい。

【 0 0 0 7 】

昨今の機械学習の進化により、異常センサトレースの検出および分類に基づく機器障害検出および分類の能力を向上させる新たな機会が設けられた。しかし、異常トレースの検出および分類のために機械学習を実装するハードルの1つとして、ラベル付きトレースデータを得ることが難しいという点がある。したがって、異常トレースの検出および分類のための真に効果的な方法論は、ラベルを用いない異常トレース識別のための効果的な方策を実施する必要がある、検出および分類を継続的に改善するためにラベルを収集する初期分類を活用する必要がある。

【図面の簡単な説明】

【 0 0 0 8 】

【図 1 A】 4つの機器センサトレースを示すプロセスディスプレイウィンドウである。

【図 1 B】 図 1 A に示すトレースに関する要約統計を用いた表である。

【図 2】 異常検出および分類システムを示す概略ブロック図である。

【図 3】 図 2 の一部の詳細図である。

【図 4 A】 ブーストラップの例のグラフ図である。

【図 4 B】 ブーストラップの例のグラフ図である。

【図 5 A】 トレース異常を分類するためのシステムのブロック図である。

【図 5 B】 トレース異常を分類するためのシステムのブロック図である。

【図 6】 事前定義された異常のクラスおよび対応する可能なアクションの表である。

【図 7 A】 トレース異常の分類をレビューおよび更新するためのシステムのブロック図である。

【図 7 B】 トレース異常の分類をレビューおよび更新するためのシステムのブロック図である。

【発明を実施するための形態】

【 0 0 0 9 】

本明細書で用いられる場合、「センサトレース」という用語は、機器動作中に定期的に重要な物理量を測定する時系列データを指し、「トレース」または「機器トレース」という用語は、処理インスタンスについて識別される全ての重要なセンサに関するセンサトレースの集合を指す。

【 0 0 1 0 】

本開示によって対処される問題は、半導体処理機器の異常動作である。処理中に収集されるセンサデータを監視し、既知の異常動作条件と未知の動作条件とを区別し、迅速な応答を可能にするためにこれらの未知の条件を分類することによって異常機器動作を識別する能力は、長期的に認識されているが、解決が困難な問題である。したがって、本開示の目的は、正常動作トレースと比較した時に顕著な異常を示す任意の機器センサトレースを

10

20

30

40

50

識別するリアルタイム性能を説明することによって、この問題に対処することである。

【 0 0 1 1 】

この問題の評価は、並列処理アーキテクチャの登場および機械学習アルゴリズムの進化によって促進され、これによりユーザは、そのようなアプローチによって妥当かつ現実的となる速度で大量のデータを用いて見識を得、予測を行うことができる。機械学習とは、データから学習することが可能なシステムの構築および研究を伴う人工知能の一分野である。これらの種類のアルゴリズムは、並列処理性能と共に、より大量のデータセットが処理されることを可能にし、多変量解析により適している。

【 0 0 1 2 】

機械学習における能力の大部分は、ノイズの多い高次元空間において正確に分類する能力である。ただし、検出および分類方式の効果は、物理的に意味のある特徴量エンジニアリングで改善され得る。また、優れた特徴量エンジニアリングは、類似する異常トレースの裏にある根本原因の理解を大きく支援し得る。異常トレース検出および分類に対する効果的な機械学習アプローチは、能動学習を促進し、得られた情報を用いて、障害検出および分類の両方の精度を継続的に高める必要がある。

10

【 0 0 1 3 】

製造環境において、異常トレース例の過去のラベリングは、多くの場合、使用不可能である。したがって、異常トレースの検出のための効果的なシステムは、過去のラベルに依存することができない。しかし、ラベルを提供するプロセスエンジニアの負荷が最小限になり、この利点が明らかになると、そのような試みによってラベリングプロセスへの有用な入力を得られ得る。関連モデルの検出および分類を改善するために、必要に応じて、分類ラベルの精度のレビューが含まれ、再ラベリングが行われる必要がある。

20

【 0 0 1 4 】

異常トレース検出および分類のためのシステム 2 0 0 の概観が図 2 に示される。このシステムは、コンピュータベースであり、様々なモジュールが、従来のオペレーティングシステムを有する最新式の独立型デスクトップコンピュータまたは均等物にインストールされ、そこで実行可能であり、またはインターネットまたは他のネットワークによってアクセス可能なホストサービスを介してユーザに利用可能となる。

【 0 0 1 5 】

モジュール 2 2 0 において、キー特徴および関連する機器トレースデータのセットを識別するために、「特徴量エンジニアリング」が行われる。特徴量エンジニアリング 2 2 0 の結果、標的特徴を評価するために役立つモジュール 2 3 7 内のトレースが識別され用いられる。「ブートストラップ」は、モジュール 2 2 0 で識別されたキー特徴に主に基づいて分類ラベルを作成するために、モジュール 2 4 0 においてトレースに行われる。その結果、モジュール 2 6 0 に保存および格納されるラベルが生じる。

30

【 0 0 1 6 】

ブートストラップモジュール 2 4 0 において十分なラベルが収集され、モジュール 2 6 0 に保存されると、ブートストラップ段階は、モジュール 2 5 0 における継続学習段階に移行し、ここで、異常検出および分類モデルが最初に構築され、継続的に（または定期的に、または時折）更新される。分類（ラベル）は、必要に応じてレビューされ更新される。モデルが構築されると、このモデルは、モジュール 2 8 0 におけるリアルタイム予測を行うためにモジュール 2 7 0 から展開され得る。

40

【 0 0 1 7 】

特徴量エンジニアリングモジュール 2 2 0 は、図 3 により詳しく示され、ステージ 3 2 0 におけるカスタムデータ準備およびステージ 3 3 0 における標準特徴量エンジニアリングの 2 つの主要処理ステージを含む。理想的には、特徴量エンジニアリングは、任意の特定のプロセス知識を必要としないが、多くの場合、これは非現実的である。たとえば、特定の条件下で、インプラントはチューニングサイクルを入力し、その間、センサは、正常動作から著しく変化し、ウェハに直接的に影響を及ぼさないセンサ値を記録する。したがって、一例として、ステージ 3 2 0 のカスタムデータ準備の間、チューニングサイクルで

50

キー特徴が識別され、トレースのその他の部分から分離され、トレースは調整または修正され、この例ではウェハに関するチューニング期間の数、チューニング持続時間、およびチューニング前後の各トレースの変化を表す特徴のカスタムセットが生成される。これらの特徴は、検出および分類モデルへの入力を提供するために、ステージ 338 において、修正されたトレースと結合され得る。

【0018】

これは図3にグラフで表されており、オリジナルトレース 324 は、大部分が通常のトレース 324 N を含み、少数のトレース 324 A が異常を示す。オリジナルトレース 324 は、ステージ 320 において修正され、修正されたトレース 326 は、修正された通常のトレース 326 N および少数の修正された異常トレース 326 A を含む。修正されたトレース 326 は、ステージ 330 に渡され、識別されたカスタム特徴は、検出および分類モデルのための完全特徴セットの一部としてステージ 338 に送信される。

10

【0019】

ステージ 330 において、検出および分類モデルによって必要とされる特徴の多くは、標準化特徴であり、これらの計算は、入力をエンジニアリングすることなく処理される。たとえば、モジュール 332 において「基底セット」特徴が生成される。最初に、各ステップ識別子（「ステップ ID」）における基本統計（中央値および傾斜）が計算され、これらの特徴を除去するためにトレースが修正される。次に、たとえば主成分、オートコーダ、他などの周知のアルゴリズム的解法が用いられ、修正されたトレースに関する包括的な基底セットがアルゴリズム的に計算される。これらの基底セット特徴の完全リストを前提として、許容可能な精度で、オリジナルトレースが復元され得るので、結合すると、これらの特徴（アルゴリズム的基底セット特徴、中央値、および傾斜）が基底セットを形成する。ただし、過去に観察されていない異常トレースは、この基底セットで正確に再現されない。

20

【0020】

モジュール 334 において「補足」特徴が生成され、トレースの複製には用いられないが、異常の根本原因を理解するために役立ち得る。補足特徴は、たとえば標準偏差、ステップ持続時間、ホワイトノイズなどの既知の影響の大きい尺度に焦点を当てて生成され得る。

【0021】

トレース 337 は、基底セット特徴、および再構成の精度を表すためにモジュール 336 において生成された「残差」特徴を用いて、オリジナルトレースの近似として復元される。残差特徴は、基底セット特徴において捕捉されない未知のトレース変動を捕捉する。

30

【0022】

最後に、トレース異常を検出および分類するために構成および訓練される機械学習モデル 270（図2を参照）への入力として、モジュール 332 からの基底セット特徴、モジュール 334 からの補足特徴、およびモジュール 336 からの残差特徴が、オリジナルトレース、修正されたトレース、および復元トレースと結合される。このモデルは、異常トレースを識別し、ユーザフィードバックに基づいてこれらのトレースを分類し、2段階アプローチを用いて実装され得る。

40

【0023】

図2に戻ると、ブートストラップ段階 240 は、初期ラベルを生成するために用いられ、継続学習段階 260 は、過去のラベルが累積されると、新たな学習を収集し、適用する。ブートストラップ段階 240 は、数百から場合によっては数千の範囲で、多数のラベルなしマルチセンサ機器トレースが入力として存在することを想定する。入力データを有するラベルが存在しない場合、モデルは、多くのトレースが通常ツール動作を示すことを想定する。ブートストラップ段階の目的は、特徴量エンジニアリング段階 220 において初期データから識別されたキー特徴に主に基づいて単変量および多変量外れ値を識別することである。

【0024】

50

たとえば、図 4 A および図 4 B は、選択されたプロセスステップにおけるブートストラップの例を示し、ここで、オリジナルトレース 4 0 0 は、第 1 のトレース 4 0 1、第 2 のトレース 4 0 2、第 3 のトレース 4 0 3、第 4 のトレース 4 0 4、第 5 のトレース 4 0 5、および第 6 のトレース 4 0 6 を含む。ここで示すような 4 つの異常トレースに加えて、ブートストラップモジュールに入力された数百（またはそれ以上）の通常または典型的トレースが存在する。

【 0 0 2 5 】

トレースの中央値が計算され、グラフ 4 0 8 にまとめて表示され、このグラフでは、トレース 4 0 1 が外れ値であり異常であることが視覚的に明らかである。オリジナルトレース 4 0 1 ~ 4 0 6 は修正され、中央値調整トレース 4 1 1 ~ 4 1 6 として表示される。

10

【 0 0 2 6 】

その後、中央値調整トレース 4 1 1 ~ 4 1 6 の傾斜が計算され、グラフ 4 1 8 にまとめて表示され、このグラフでは、トレース 4 1 3 が異常であり、トレース 4 1 2 および 4 1 4 が疑わしい。トレース 4 1 1 ~ 4 1 6 は、再び修正され、傾斜調整トレース 4 2 1 ~ 4 2 6 として表示される。中央値および傾斜が知られると、アルゴリズム的基底セット特徴が計算され、残りのトレース変動の大部分を捕捉する特徴が選択される。この単純な例において、顕著な基底特徴は中央値および傾斜だけである。その後、残差特徴（一般に、オリジナルトレースと、基底セット特徴から再現された近似トレースとの二乗誤差の和）が計算される。残差特徴 4 2 8 から、トレース 4 2 4 が異常であり、トレース 4 2 2 が疑わしいことが明らかである。

20

【 0 0 2 7 】

補足特徴は、他の基準に関してフィルタすることによる根本原因解析のために露呈され得る。たとえば、修正されたトレース 4 2 1 ~ 4 2 6 に関するノイズ特徴を抽出した結果、トレース 4 2 2 が異常であることが示されるグラフ 4 2 9 が生じる。

【 0 0 2 8 】

ブートストラップ段階 2 4 0 を表すシステム 5 0 0 は、図 5 A および図 5 B に示される。オリジナルトレース 5 0 2 は、大部分が通常のトレースおよび少数の異常を含み、特徴量エンジニアリングモジュール 5 0 4 に入力され、ここでキー特徴が識別され、モジュール 5 0 6 に保存される。モジュール 5 0 8 において、特徴選択からキー特徴の単変量および多変量分布を解析することによって、外れ値のトレースおよび特徴が識別される。その後、外れ値は、グラフィックユーザインタフェース（GUI）5 1 0 においてユーザによって分類される。

30

【 0 0 2 9 】

この例において、GUI 5 1 0 は、使用可能なトレースのリスト 5 1 2 を有して構成され、ユーザは、閲覧するために 1 または複数を選択してよい。この図において、4 つのトレースが選択され、ウィンドウ 5 1 4、5 1 5 における外れ値トレースおよびウィンドウ 5 1 6、5 1 7 における基準トレースとして表示されている。ボタン 5 1 3 は、ユーザが、類似するトレースを更に変更することを選択することを可能にする。ウィンドウ 5 1 4 は、4 つの異常電流トレースを示し、ウィンドウ 5 1 5 は、4 つの異常電圧トレースを示す。ウィンドウ 5 1 6 は、6 つの基準電流トレースを示し、ウィンドウ 5 1 7 は、6 つの基準電圧トレースを示す。電流形状（アルゴリズム的基底セット）特徴は、ウィンドウ 5 1 8 に表示され、ウィンドウ 5 1 9 に表示される電圧形状特徴、ウィンドウ 5 2 0 に表示される電流残差特徴、ウィンドウ 5 2 1 に表示される電圧残差特徴は、ウィンドウ 5 1 4、5 1 5 に表示される 4 つの異常トレースの全てについて異常である。

40

【 0 0 3 0 】

外れ値はボタン 5 2 4 を用いて分類することができ、この例において、ボタン 5 2 4 はプルダウンリストであり、ユーザが、いくつかの事前定義された分類および関連アクションの 1 つを選択し、その分類 / アクションを、ボタン 5 2 6 を介してこの特定の異常に割り当てることを可能にする。たとえば、図 6 は、ボタン 5 2 4 または他の同等のモードを介して実装され得る事前定義されたクラスおよびアクションの表である。通常、疑い、お

50

よび異常という3つのクラスが定義される。各クラスについて、アクションが定義される。ユーザが外れ値を通常に分類した場合、アクションは必要なく、この通常トレースは、検出および分類モデルにおける通常トレースの定義を更新するために用いられる。

【0031】

ユーザが外れ値を疑い、または最終的に異常に分類した場合、図6に示すように、この外れ値が有害であるか、監視を必要とするか、または即時の警告条件をトリガすべきかに関する分類を有する追加のインジケーションが提供される。異常性分類に関する最終決定は、一般に、何らかの形式での専門家のレビューを含む。

【0032】

全ての外れ値にクラスが割り当てられた後、モジュール530において、全ての処理されたトレースデータを機械学習ベースのモデルのための訓練セットとして用いて、初期検出および分類モデルが構築される。このモデルは、その後、独立型またはオンライン異常トレース検出および分類システムとして用いられ得る。

10

【0033】

継続学習モデルにおいて、入力データは、オンライン予測、エンジニアリング対象の特徴、および（オリジナルおよび調整後の）トレースデータを含む。インタラクティブGUIは、能動学習が、正確な異常検出および分類モデルを構築することを容易にする。類似のトレースをアルゴリズム的に識別する能力が、効率的な能動学習のキーである。

【0034】

モデルに組み込まれ得る信頼レベル因子を築くために、好適には、適切なプロセス知識を有するプロセスエンジニアが全ての予測をレビューすべきである。たとえば、図7Aおよび図7Bは、分類レビューのための環境を示す点で図5Aおよび図5Bと同様である。GUI710は、GUI510と同様であり、レビューがトレースを選択し、ボタン724によって適切なクラスおよびアクションを選択し、ボタン726によってクラス/アクションを割り当て、その後、ボタン726を介してモジュール730におけるモデルを新たな学習で更新することを可能にする。

20

【0035】

継続学習は、既存の検出および分類機械学習モデルを用いて各ウェアに関する最確分類を予測するが、最も近い訓練データと新たなトレースとの間の類似性に基づいて信頼性を予測もする。最も低い信頼度の予測は、強制レビューのためにフラグが付けられ、未知の異常である可能性が最も高い。

30

【0036】

異常検出は、最も基本的には単変量（特徴が通常か否か）であるが、単変量解析からは明らかになりにくい追加の異常を識別するために、多変量方法が用いられ得る。たとえば、温度および圧力の両方の逸脱が発生する例など、いくつかの機器誤作動は、複数のセンサトレースの評価からより容易に観察可能であり、パラメータの1つのみが考慮される場合、アクションが起こる可能性が大幅に高くなり得る。逆に、装置誤作動は通常、複数のセンサにおける複数の異常を発生させ、根本原因の予測には多変量シグネチャが重要である。

【0037】


40

好適には、根本原因分類のための適切な機械学習アルゴリズムは、データ特性とデータ量との関数である。たとえば、データ量が非常に少ない場合、単純な最近傍アルゴリズムが最良の結果をもたらす可能性が高い。データ量が中程度であり、主なデータ変動がエンジニアリング対象の特徴によって捕捉される場合、たとえばエクストリーム勾配ブースティングなどの高度なツリーベースの方法が優れた選択肢であり得る。データ量が十分であり、トレースに根本原因に関連する強力な残差効果がある場合、畳み込みニューラルネットワークが最適な選択肢である可能性が高い。最小限のユーザ入力でこの問題を解決するために、分類モデルを構築するためにクロス検証ベースのモデル選択ルーティンが用いられ、多くの場合、複数のモデルは、複数の予測を結合して単一の予測のために用いられる単純な凝集モデルと共に用いられる。

50

【図面】


【図 1 A】




【図 1 B】

	トレース 1	トレース 2	トレース 3	トレース 4
平均	2.34	2.40	2.47	2.43
シグマ	0.66	0.60	0.54	0.58
最大	4.50	4.35	4.23	4.35
最小	2.00	2.10	2.20	2.10


【図 2】




【図 3】




【図 4 A】




【図 4 B】



【図 5 A】



【図 5 B】



10

20

30


40

50

【 図 6 】

[illegible]


【 図 7 A 】



10

20

【圖 7 B】



30

40

50

フロントページの続き

- 弁理士 高橋 香元
- (72)発明者 バーチ, リチャード
アメリカ合衆国, カリフォルニア州 9 5 0 5 0 , サンタ クララ , 2 8 5 8 デ ラ クルツ ブールバール
- (72)発明者 デイビッド, ジェフェリー, ディー .
アメリカ合衆国, カリフォルニア州 9 5 0 5 0 , サンタ クララ , 2 8 5 8 デ ラ クルツ ブールバール
- (72)発明者 チュー, チン
アメリカ合衆国, カリフォルニア州 9 5 0 5 0 , サンタ クララ , 2 8 5 8 デ ラ クルツ ブールバール
- (72)発明者 本田 智士
アメリカ合衆国, カリフォルニア州 9 5 0 5 0 , サンタ クララ , 2 8 5 8 デ ラ クルツ ブールバール
- (72)発明者 チェオン, リン, リー
アメリカ合衆国, カリフォルニア州 9 5 0 5 0 , サンタ クララ , 2 8 5 8 デ ラ クルツ ブールバール
- 審査官 円子 英紀
- (56)参考文献 米国特許出願公開第 2 0 1 9 / 0 1 4 6 0 3 2 (U S , A 1)
 米国特許出願公開第 2 0 1 7 / 0 1 0 9 6 4 6 (U S , A 1)
 特開 2 0 0 8 - 1 5 4 0 1 0 (J P , A)
 特開 2 0 0 9 - 2 3 7 8 3 2 (J P , A)
 韓国公開特許第 1 0 - 2 0 1 8 - 0 0 4 0 4 5 2 (K R , A)
 米国特許出願公開第 2 0 1 8 / 0 0 3 9 8 9 8 (U S , A 1)
- (58)調査した分野 (Int.Cl. , D B 名)
 G 0 6 F 1 1 / 3 4
 G 0 6 N 3 / 0 0
 G 0 6 N 2 0 / 0 0