

(19) 日本国特許庁(JP)

(12) 公開特許公報(A)

(11) 特許出願公開番号

特開2019-36285
(P2019-36285A)

(43) 公開日 平成31年3月7日(2019.3.7)

(51) Int.Cl. F I テーマコード (参考)
G 0 5 B 23/02 (2006.01) G 0 5 B 23/02 T 3 C 2 2 3

審査請求 有 請求項の数 15 O L 外国語出願 (全 49 頁)

(21) 出願番号 特願2018-41987(P2018-41987)
 (22) 出願日 平成30年3月8日(2018.3.8)
 (31) 優先権主張番号 201721029392
 (32) 優先日 平成29年8月18日(2017.8.18)
 (33) 優先権主張国 インド(IN)

(71) 出願人 510337621
 タタ コンサルタンシー サービスズ リミテッド
 TATA Consultancy Services Limited
 インド国 マハーラシュトラ、ムンバイ 400021、ナリマン ポイント、ナーマル ビルディング 9階
 Nirmal Building, 9th Floor, Nariman Point, Mumbai 400021, Maharashtra, India.
 (74) 代理人 100100158
 弁理士 鮫島 睦

最終頁に続く

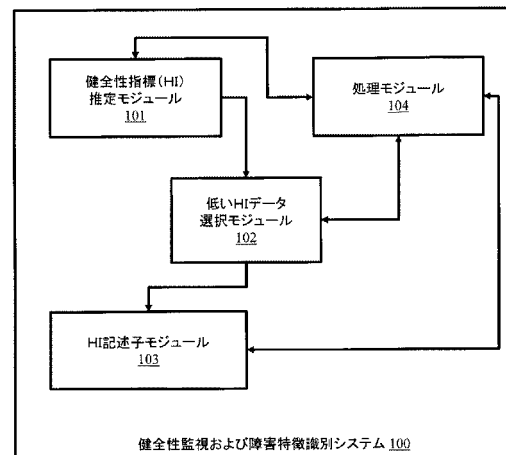
(54) 【発明の名称】 健全性監視及び障害特徴識別の方法及びシステム

(57) 【要約】 (修正有)

【課題】システムの健全性監視及び障害特徴識別のシステム及び方法を提供する。

【解決手段】システムは、時系列データとして、システムの健全性指標(HI)を推定する。推定されるHIに対応するデータを分析することによって、システムは、推定されるHI値のうちの大部分が低い一つ又はそれ以上の時間窓を、低いHI窓として、推定されるHI値のうちの大部分が高い一つ又はそれ以上の時間窓を、高いHI窓として、識別する。監視されるシステムの異常挙動を示す、低いHI窓を識別するときに、システムは、監視されるシステムに対して生成されるローカルベイジアンネットワークに基づいて、各センサに対して明確化指標(EI)を生成する。ここで、EIは、低いHIへのセンサの寄与を定量化するものである。更に、関連するコンポーネントが、システムの異常挙動/障害のある挙動として識別される。

【選択図】 図 1



【特許請求の範囲】**【請求項 1】**

健全性監視及び障害特徴識別システムが、一つ又はそれ以上のハードウェアプロセッサを介して、監視されるシステムの健全性指標（HI）を推定するステップと、

システムの異常挙動がある場合、前記健全性監視及び障害特徴識別システムが、前記一つ又はそれ以上のハードウェアプロセッサを介して、前記システムの異常挙動を識別するステップであって、推定される低いHIが前記異常挙動を示すものとして識別される、ステップと、

前記健全性監視及び障害特徴識別システムが、前記一つ又はそれ以上のハードウェアプロセッサを介して、前記システムに対して生成されるローカルベイジアンネットワークに基づいて、前記異常挙動の原因であるものとしてシステムのうちの少なくとも一つのコンポーネントを検出するステップと、を含む

健全性監視及び障害特徴識別のためのプロセッサ実装方法。

【請求項 2】

前記低いHIは、前記システムの推定されるHIに対応するデータ内の少なくとも一つの低いHI窓の存在に関して識別される、請求項 1 に記載の方法。

【請求項 3】

前記HIは、再帰型ニューラルネットワーク（RNN）を用いて推定される、請求項 1 に記載の方法。

【請求項 4】

前記推定されるHIに対応するデータは、時系列データとして取得される、請求項 1 に記載の方法。

【請求項 5】

前記異常挙動の原因であるものとして少なくとも一つのコンポーネントを検出するステップは、

前記推定されるHIに対応する前記データを分析するステップであって、前記推定されるHIに対応する前記データが様々な時間窓に分割される、ステップと、

低いHI窓が存在する場合、少なくとも一つの低いHI窓を識別するステップであって、低いHI窓のすべてのHI値のうち大部分のHI値がHIの閾値を下回る、ステップと、

少なくとも一つの高いHI窓を識別するステップであって、前記高いHI窓のすべてのHI値のうち大部分のHI値がHIの前記閾値を上回る、ステップと、

前記少なくとも一つの低いHI窓からのデータ、及び前記少なくとも一つの高いHI窓からのデータに基づいて、前記システムに対する前記ローカルBNを生成するステップと、

前記ローカルBNに基づいて、前記HIの推定のためのデータが収集される、少なくとも一つのセンサに対して明確化指標（EI）を生成するステップであって、前記EIは、前記低いHIへの前記センサの寄与を定量化するものである、ステップと、

前記少なくとも一つのセンサに対して生成される前記EIに基づいて、前記システムの、前記低いHIと少なくとも一つのコンポーネントとの間の依存関係を識別するステップと、

を含む、

請求項 4 に記載の方法。

【請求項 6】

プロセッサと、

複数の命令を含むメモリモジュールと、

を含む健全性監視及び障害特徴識別システムであって、

前記複数の命令は、

前記プロセッサに、健全性監視及び障害特徴識別システムのHI推定モジュールを用いて、一つ又はそれ以上のハードウェアプロセッサを介して、監視されるシステムの健全性

10

20

30

40

50

指標（HI）を推定させて、

前記システムの異常挙動がある場合、前記プロセッサに、前記健全性監視及び障害特徴識別システムの低いHIデータ選択モジュールを用いて、前記一つ又はそれ以上のハードウェアプロセッサを介して、前記システムの異常動作を識別させて、このとき、推定される低いHIは異常挙動を示すものとして識別され、

前記プロセッサに、前記健全性監視及び障害特徴識別システムのHI記述子モジュールを用いて、一つ又はそれ以上のハードウェアプロセッサを介して、前記システムに対して生成されるローカルベイジアンネットワーク（BN）に基づいて、前記異常挙動の原因であるものとして前記システムの少なくとも一つのコンポーネントを検出させる、
ように構成される、

健全性監視及び障害特徴識別システム。

【請求項7】

前記低いHIデータ選択モジュールは、前記システムの前記推定されるHIに対応するデータ内の少なくとも一つの低いHI窓の存在に関して前記低いHIを識別するように構成される、請求項6に記載の健全性監視及び障害特徴識別システム。

【請求項8】

前記HI推定モジュールは再帰型ニューラルネットワーク（RNN）を使用して前記HIを推定するように構成される、請求項6に記載の健全性監視及び障害特徴識別システム。

【請求項9】

前記HI推定モジュールは、前記HIを時系列データとして推定するように構成される、請求項6に記載の健全性監視及び障害特徴識別システム。

【請求項10】

前記HI記述子モジュールは、前記異常挙動の原因である前記少なくとも一つのコンポーネントを、

推定されるHIに対応するデータを分析するステップであって、前記推定されるHIに対応するデータは、様々な時間窓に分割される、ステップ、

少なくとも一つの低いHI窓を識別するステップであって、前記少なくとも一つの低いHI窓が存在する場合、前記低いHI窓のすべてのHI値のうちの大部分のHI値は、前記HIの閾値を下回る、ステップ、

少なくとも一つの高いHI窓を識別するステップであって、前記高いHI窓のすべてのHI値のうちの大部分のHI値は、前記HIの閾値を上回る、ステップ、

前記少なくとも一つの低いHI窓からのデータ、及び前記少なくとも一つの高いHI窓からのデータに基づいて、前記システムに対する前記ローカルBNを生成するステップ、

前記ローカルBNに基づいて、前記HI推定のためのデータが収集される、少なくとも一つのセンサに対して、明確化指標（EI）を生成するステップであって、前記EIは、前記低いHIへの前記センサの寄与を定量化するものである、ステップ、及び

少なくとも一つのセンサに対して生成される前記EIに基づいて、前記システムの、前記低いHIデータと、少なくとも一つのコンポーネントとの間の依存関係を識別するステップ、

によって検出するように構成される、

請求項9に記載の健全性監視及び障害特徴識別システム。

【請求項11】

一つ又はそれ以上のハードウェアプロセッサによって実行されるときに、

健全性監視及び障害特徴識別システムが、一つ又はそれ以上のハードウェアプロセッサを介して、監視されるシステムの健全性指標（HI）を推定すること、

システムの異常挙動がある場合に、前記健全性監視及び障害特徴識別システムが、前記一つ又はそれ以上のハードウェアプロセッサを介して、前記システムの異常挙動を識別すること、ここで、推定される低いHIは異常挙動を示すものとして識別される、及び

前記健全性監視及び障害特徴識別システムが、前記一つ又はそれ以上のハードウェアプロセッサ

10

20

30

40

50

ロセッサを介して、前記システムに対して生成されるローカルベイジアンネットワークに基づいて、前記異常挙動の原因であるものとしてシステムのうちの少なくとも一つのコンポーネントを検出すること、

を行う、一つ又はそれ以上の命令を含む、

一つ又はそれ以上の非一時的機械可読情報記憶媒体。

【請求項 1 2】

前記低い H I は、前記システムの推定される H I に対応するデータ内の少なくとも一つの低い H I 窓の存在に関して識別される、請求項 1 1 に記載の一つ又はそれ以上の非一時的機械可読情報記憶媒体。

【請求項 1 3】

前記 H I は、再帰型ニューラルネットワーク (R N N) を使用して推定される、請求項 1 1 に記載の一つ又はそれ以上の非一時的機械可読情報記憶媒体。

【請求項 1 4】

前記推定される H I に対応するデータは時系列データとして取得される、請求項 1 1 に記載の一つ又はそれ以上の非一時的機械可読情報記憶媒体。

【請求項 1 5】

前記異常挙動の原因である少なくとも一つのコンポーネントを検出することは、

前記推定される H I に対応する前記データを分析するステップであって、前記推定される H I に対応するデータが様々な時間窓に分割される、ステップと、

低い H I 窓が存在する場合、少なくとも一つの低い H I 窓を識別するステップであって、低い H I 窓のうちのすべての H I 値のうちの H I 値の大部分が H I の閾値を下回る、ステップと、

少なくとも一つの高い H I 窓を識別するステップであって、前記高い H I 窓のすべての H I 値のうちの H I 値の大部分が H I の前記閾値を上回る、ステップと、

前記少なくとも一つの低い H I 窓からのデータ、及び前記少なくとも一つの高い H I 窓からのデータに基づいて、前記システムに対する前記ローカル B N を生成するステップと、

ローカル B N に基づいて、前記 H I の推定のためのデータが収集される、少なくとも一つのセンサに対して明確化指標 (E I) を生成するステップであって、前記 E I は、前記低い H I への前記センサの寄与を定量化するものである、ステップと、

前記少なくとも一つのセンサに対して生成される前記 E I に基づいて、前記システムの、前記低い H I と少なくとも一つのコンポーネントとの間の依存関係を識別するステップと、

を含む、

請求項 1 4 に記載の一つ又はそれ以上の非一時的機械可読情報記憶媒体。

【発明の詳細な説明】

【技術分野】

【0 0 0 1】

本出願は、2017年8月18日にインドにて提出されたインドの完全明細書 (発明の名称 : 健全性監視及び障害特徴識別の方法及びシステム) 出願番号 (2 0 1 7 2 1 0 2 9 3 9 2) への優先権を主張する。

【0 0 0 2】

本明細書の開示は、概略、システムの健全性監視に関し、より具体的に言うと、システムの健全性を監視して障害特徴識別を行うことに関する。

【背景技術】

【0 0 0 3】

産業環境に配備される複雑なシステムは、システムの適切な動作を保証するために監視される必要がある。そのようなシステムは、データ収集、データ処理などを行う、センサ及び他のコンポーネントの複数のサブユニットを含み、サブシステムはデータ交換のために互いに通信する場合がある。

10

20

30

40

50

【発明の概要】**【発明が解決しようとする課題】****【0004】**

技術的な問題のために、サブシステムが誤動作する可能性があり、サブシステムの誤動作のために、対応するセンサの読み取り値が変化し得る可能性がある。そのような接続されたシステムにおいて、各コンポーネント/サブシステムのスループットがシステムの最終出力に影響を与えるので、そのような誤動作は、システムの全体的なスループットに悪影響を与える。

【0005】

そのような問題を分析する一つの方法は、システムのコンポーネントの動作を検証するための手動の分析を実行することである。しかしながら、多数のコンポーネント及び複雑なアーキテクチャ/設計を有するシステムのために、手動の分析は、面倒な作業になる。手動の分析は更に、複雑なドメイン知識を要求し、検証の結果の精度は、作業者の知識の量によって変化することもある。

10

【0006】

障害分析のために使用される特定の方法及びシステムが存在する。しかしながら、これらのシステムの一つの欠点は、ランタイム分析を実行する性能が限定されること、あるいは、当該性能を有しないことである。更に、これらのシステムのほとんどは、分析の様々な段階において、手動の介入を必要とする。

【課題を解決するための手段】

20

【0007】

本開示の実施形態は、従来のシステムにおいて本発明者によって認識された上述の技術的課題のうちの一つ又はそれ以上に対する解決策として、技術的な改善を提示する。例えば、一実施形態において、健全性監視及び障害特徴識別のためのプロセッサ実装方法が提供される。この方法において、監視されるシステムに対して、健全性監視及び障害特徴識別によって、一つ又はそれ以上のハードウェアプロセッサを介して健全性指標(HI)が生成される。監視することによって、健全性監視及び障害特徴識別システムは、システムの異常挙動がある場合、一つ又はそれ以上のハードウェアプロセッサを介して、当該システムの異常挙動を識別する。このとき、推定される低いHIは、異常挙動を示すものとして識別される。健全性監視及び障害特徴識別システムは更に、システムに対して生成されるローカルベイジアンネットワークに基づいて、異常挙動の原因であるものとしてシステムの少なくとも一つのコンポーネントを検出する。

30

【0008】

別の態様において、健全性監視及び障害特徴識別システムが提供される。システムは、プロセッサと、複数の命令を含むメモリモジュールとを含む。複数の命令は、プロセッサに、健全性監視及び障害特徴識別システムのHI推定モジュールによって、一つ又はそれ以上のハードウェアプロセッサを介して、監視されるシステムの健全性指標(HI)を推定させるように構成される。更に、健全性監視及び障害特徴識別システムの低いHIデータ選択モジュールは、システムの異常挙動がある場合、一つ又はそれ以上のハードウェアプロセッサを介して、当該システムの異常挙動を識別する。このとき、推定される低いHIは、異常挙動を示すものとして識別される。異常挙動を識別すると、健全性監視及び障害特徴識別システムのHI記述子モジュールは、一つ又はそれ以上のハードウェアプロセッサを介して、システムに対して生成されるローカルベイジアンネットワークに基づいて、異常挙動の原因であるものとしてシステムの少なくとも一つのコンポーネントを検出する。

40

【0009】

前述の概略的な説明及び以下の詳細な説明の両方は、例示的かつ説明的なものに過ぎず、特許請求される本発明を限定するものではないことを理解すべきである。

【0010】

本開示に組み込まれて本開示の一部を構成する添付の図面は、例示的な実施形態を示し

50

、説明と共に、開示される原理を説明する役割を果たす。

【図面の簡単な説明】

【0011】

【図1】図1は、本開示のいくつかの実施形態に係る、健全性監視及び障害特徴識別システムの例示的なブロック図を示す。

【図2】図2は、本開示のいくつかの実施形態に係る、健全性監視及び障害特徴識別システムによる、システムの健全性監視を実行する処理を含むステップを表すフロー図である。

【図3】図3は、本開示のいくつかの実施形態に係る、健全性監視及び障害特徴識別システムによる、障害特徴に基づく、システムの異常挙動の原因である一つ又はそれ以上のコンポーネントを識別する処理に含まれるステップを表すフロー図である。

【図4】図4は、本開示のいくつかの実施形態に係る、健全性監視及び障害特徴識別システムによる、システムのコンポーネントに対する明確化指標（EI）を生成する処理に含まれるステップを表すフロー図である。

【図5a】図5aは、本開示のいくつかの実施形態に係る、例示的な使用事例のシナリオにおいて生成されるベイジアンネットワーク（BN）を表す。

【図5b】図5bは、本開示のいくつかの実施形態に係る、例示的な使用事例のシナリオにおいて生成されるベイジアンネットワーク（BN）を表す。

【図6a】図6aは、本開示のいくつかの実施形態に係る、ターボ機械に対して推定されるサンプルのHI値を表す。

【図6b】図6bは、本開示のいくつかの実施形態に係る、ターボ機械に対して推定されるサンプルのHI値を示す。

【図6c】図6cは、本開示のいくつかの実施形態に係る、ターボ機械に対して推定されるサンプルのHI値を示す。

【図7a】図7aは、本開示のいくつかの実施形態に係る、システムの正常動作と異常動作とにわたって大きく変化するセンサのサンプル分布を表す。

【図7b】図7bは、本開示のいくつかの実施形態に係る、システムの正常動作と異常動作とにわたって大きく変化するセンサのサンプル分布を表す。

【図7c】図7cは、本開示のいくつかの実施形態に係る、システムの正常動作と異常動作とにわたって大きく変化するセンサのサンプル分布を表す。

【図7d】図7dは、本開示のいくつかの実施形態に係る、システムの正常動作と異常動作とにわたって大きく変化するセンサのサンプル分布を表す。

【図7e】図7eは、本開示のいくつかの実施形態に係る、システムの正常動作と異常動作とにわたって大きく変化するセンサのサンプル分布を表す。

【図7f】図7fは、本開示のいくつかの実施形態に係る、システムの正常動作と異常動作とにわたって大きく変化するセンサのサンプル分布を表す。

【図7g】図7gは、本開示のいくつかの実施形態に係る、システムの正常動作と異常動作とにわたって大きく変化するセンサのサンプル分布を表す。

【図7h】図7hは、本開示のいくつかの実施形態に係る、システムの正常動作と異常動作とにわたって大きく変化するセンサのサンプル分布を表す。

【図8a】図8aは、本開示のいくつかの実施形態に係る、アクセラレータペダルポジション（APP）及び冷却剤温度（CT）の正常動作及び異常動作に対して推定されるサンプルHI値を表す。

【図8b】図8bは、本開示のいくつかの実施形態に係る、アクセラレータペダルポジション（APP）及び冷却剤温度（CT）の正常動作及び異常動作に対して推定されるサンプルHI値を表す。

【発明を実施するための形態】

【0012】

例示的な実施形態を、添付の図面を参照して説明する。図において、参照番号の最上位桁は、参照番号が最初に現れる図を特定するものである。有用である限り、図全体にわた

10

20

30

40

50

って、同じ参照番号を、同じ部分又は類似の部分参照するために使用する。開示される原理の例及び特徴を本明細書に記載するが、開示される実施形態の精神及び範囲から逸脱することなく、改良、適用、及び他の実施が可能である。以下の詳細な説明は、例示として考慮されるに過ぎず、真の範囲及び精神は、以下の特許請求の範囲によって示されることを意図している。

【0013】

図面、より具体的に言うと図1～8を参照しながら、好ましい実施形態が示されており、これらの実施形態は以下の例示的なシステム及び/又は方法の文脈において説明される。ここで、同様の参照文字は、図面全体にわたって対応する特徴を一貫して意味している。

10

【0014】

図1は、本開示のいくつかの実施形態に係る、健全性監視及び障害特徴識別システムの例示的なブロック図を示す。健全性監視及び障害特徴識別システム100は、健全性指標(HI)推定モジュール101、低いHIデータ選択モジュール102、HI記述子モジュール103、及び処理モジュール104を含む。システムの健全性を監視する場合、健全性監視及び障害特徴識別システム100が健全性監視及び障害特徴識別のために必要とされる入力を収集できるように、システムは、適切なインターフェースを使用して、健全性監視及び障害特徴識別システム100に接続されてもよい。

【0015】

HI推定モジュール101は、適切な入力インターフェースを使用して、監視されるシステムの一つ又はそれ以上のコンポーネントからのデータを入力として収集するように構成される。ここで、用語「コンポーネント」は、システムのHIに寄与して、障害特徴識別のために監視され得る、分析されるシステムの任意のハードウェアモジュールを参照するために使用される。例えば、コンポーネントは、システムの一つ又はそれ以上の機能を実行する、機械的コンポーネント、電気的コンポーネント、及び/又は電子的コンポーネントであってもよい。これらのコンポーネントのうちの一つ又はそれ以上に関連する一つ又はそれ以上のデータは、適切なセンサを使用して、健全性監視及び障害特徴識別のために、健全性監視及び障害特徴識別システム100のHI推定モジュール101によって収集されて分析される。HI推定モジュール101は更に、収集された入力を処理して、システムのHIを推定する。システムのHIは、システムの健全性状態を表すものである。一実施形態において、HIは、様々な時間間隔のシステムの健全性指標を表す時系列データとして推定される。一実施形態において、HI推定モジュール101は、再帰型ニューラルネットワーク(RNN)を使用して、システムのHIを推定する。この方法において、HI推定モジュール101は、監視されるシステムからの複数センサのデータを、機械の*i*番目のインスタンスに対応する多変量時系列 $X_i = \{x_i^{(1)}, x_i^{(2)}, \dots, x_i^{(l)}\}$ であると考えられる。ここで、「*l*」は、時系列の長さであり、時系列内の各ポイント $x_i^{(t)}$ は、 R^m は、*m*次元ベクトルであり、各次元は、一つのセンサに対応する。モデルは、時系列を予測するように或いは再構成するように健全なシステムからのデータに基づいてトレーニングされる。HI推定モジュール101は、健全な挙動に対応するエラーベクトルが正規分布 $N(\mu, \Sigma)$ に従うものと仮定される。ここで、パラメータ μ 及び Σ は、使用されるトレーニングセットにおいて経時的に最尤推定法を用いて取得されてもよい。 μ 及び Σ に基づいて、HIは、次式のように計算される。

20

30

40

【数1】

$$h_i^{(t)} = \log(c \cdot \exp\left(\frac{-1}{2}(e_i^{(t)} - \mu)^T \Sigma^{-1}(e_i^{(t)} - \mu)\right)) \cdot \dots \quad (1)$$

ここで、

【数 2】

$$c = \frac{1}{\sqrt{(2\pi)^d |\Sigma|}}$$

であり、及び「 d 」は、エラーベクトルの次元である。HI 推定モジュール 101 は更に、機械インスタンス「 i 」を、 $h_i(t) >$ の場合の時間「 t 」における、健全なクラス、又は不健全なクラスとして分類するように構成されてもよい。ここで、 c は、HI 推定モジュール 101 を用いて構成されるような値であってもよい。

【0016】

一実施形態において、HI 推定モジュール 101 は、特定の時間間隔に対する、すなわち時系列データとして HI 値を、推定する。HI 推定モジュール 101 は更に、各時間窓（タイムウィンドウ）に対する推定される HI データ（すなわち、推定される HI に対応するデータ）を、低い HI データ選択モジュール 102 への入力として提供する。低い HI データ選択モジュール 102 は、時系列の形式である HI データを処理して、低い HI が存在する場合、システムの低い HI に対応するデータを識別する。一実施形態において、低い HI データ選択モジュール 102 は、分析される時系列データ内の一つ又はそれ以上の低い HI 窓の存在に関してシステムの低い HI を識別する。ここで、用語「低い HI 窓」は、HI 値のうち的大部分が HI の閾値よりも小さい時間窓を表す。一実施形態において、低い HI データ選択モジュール 102 は、前の時間窓で取得された HI 値に基づいて閾値を識別する。例えば、すべての又は特定数の前の時間窓内で取得された HI 値を分析することによって、前の時間窓内の HI 値の範囲を識別してもよく、それに応じて、閾値を決定してもよい。別の実施形態において、閾値は、要件/実施基準のとおり、ユーザによって構成される。一実施形態において、低い HI 窓の存在は、システムの一つ又はそれ以上のコンポーネントの異常挙動及び全体としてのシステムの異常挙動に対応するように、或いは、当該異常挙動を表すように識別される。低い HI 選択モジュール 102 の詳細な動作は以下の通りである。

【0017】

取得される時系列データを処理することによって、低い HI 選択モジュール 102 は、時系列データ内の時間窓を低い HI 窓及び高い HI 窓として分類する。一つの時間窓は、複数の HI 値を有してもよく、ここで、時間窓内の HI データの数は、時間窓の長さに依存する。例えば、長さ 20 秒の時間窓は、20 の HI 値（毎秒の一つ）を有してもよい。時間窓内の HI 値に基づいて、低い HI データ選択モジュール 102 は、時間窓を低い HI 窓又は高い HI 窓として分類する。低い HI 窓は、HI 値のうち的大部分が閾値を下回る時間窓であり、高い HI 窓は、HI 値のうち的大部分が閾値を上回る時間窓である。取得される時系列データ内の窓のうちの一つ又はそれ以上が低い HI 窓であることを識別すると、低い HI データ選択モジュール 102 は、システムの異常挙動の原因であるコンポーネントを識別するように HI 記述子モジュール 103 を呼び出して、HI 記述子モジュール 103 に、必要とされる入力を提供する。一実施形態において、HI 値が、システムが正常に機能していることを示す場合、HI 記述子モジュール 103 は呼び出され得ない。

【0018】

HI 記述子モジュール 103 が呼び出されると、当該 HI 記述子モジュール 103 は、（推定される時系列で低い HI 値により表されて、次に、低い HI 窓の存在により表される）システムの低い HI の原因である全てのコンポーネントを識別する。HI 記述子モジュール 103 への入力は、複数の時間窓に対して推定される HI 値である。一実施形態において、HI 記述子モジュール 103 が適切に機能するために、少なくとも二つの時間窓が必要である。ここで、二つの時間窓のうち、一方の時間窓は、低い HI 値（ $h_i(t)$ ）のうち的大部分を伴う時間窓 A であり、他方の時間窓は、高い HI 値（ $h_i(t)$ ）のうち的大部分を伴う時間窓 N である。 A 及び N からのデータ（HI 値）は、ローカル BN を構成するパラメータを学習して、監視されて分析されるシステムに

対するローカルBNを生成するために使用される。HI記述子モジュール103は、システムの一つ又はそれ以上のコンポーネント(センサ)を用いて、推定される低いHI窓をマッピングする目的で、BN内の情報を使用する。その後、HI記述子モジュール103は、ローカルBN、及びマッピングされたシステムのコンポーネントから収集されたデータに基づいて、システムの各センサに対する明確化指標(EI)を取得する。ここで、EIは、推定される低いHI値に対する各センサの寄与を定量化するものである。EIはまた、本明細書においてE(Si)としても表されている。各センサに対して測定されるEIに基づいて、HI記述子モジュール103は、低いHI窓をもたらす障害特徴を伝えるものとして一つ又はそれ以上のセンサを特定して、次に、一つ又はそれ以上の関連するコンポーネントを識別する。

10

【0019】

処理モジュール104は、一つ又はそれ以上の関連するハードウェアプロセッサを使用して、健全性監視及び障害特徴識別システム100のすべての他のコンポーネントと相互作用するように、命令を収集するように、並びに、各モジュールによって処理される機能に関する一つ又はそれ以上のステップを実行するように構成されてもよい。

【0020】

図2は、本開示のいくつかの実施形態に係る、健全性監視及び障害特徴識別システムによる、システムの健全性監視を実行する処理を含むステップを表すフロー図である。健全性監視及び障害特徴識別システム100は、健全性評価のためのシステムを監視しながら、システムの健全性に直接的に及び/又は間接的に関連する、様々なパラメータに関するリアルタイム情報を、入力として収集する。例えば、適切なセンサを使用することによって、監視されるシステムの一つ又はそれ以上のコンポーネントからのデータが入力として収集される。

20

【0021】

収集される入力を処理することによって、健全性監視及び障害特徴識別システム100は、システムの健全性指標(HI)を時系列データとして推定する(202)。健全性監視及び障害特徴識別システム100は更に、時系列データを処理することによって、(一つ又はそれ以上の低いHI窓が存在する場合、)当該一つ又はそれ以上の低いHI窓を識別して、次に、監視されるシステムの低いHIを示す。ここで、一つ又はそれ以上の低いHI窓では、HI値のうち的大部分がHIの閾値を下回る。健全性監視及び障害特徴識別システム100は、低いHIを、システムの異常挙動の指標として識別する(204)。システムの異常挙動が検出された場合、健全性監視及び障害特徴識別システム100は、システムに対して生成されるローカルベイジアンネットワーク(BN)に基づいて、システムの異常挙動に対する(障害の)特徴を伝えるものとして、システムの一つ又はそれ以上のコンポーネントを検出する(208)。図2の様々な動作は、同じ順序で、あるいは異なる順序で実行されてもよい。更に、方法200における動作の一つ又はそれ以上は省略されてもよい。

30

【0022】

図3は、本開示のいくつかの実施形態に係る、健全性監視及び障害特徴識別システムによる、障害特徴に基づく、システムの低いHIの原因である一つ又はそれ以上のコンポーネントを識別する処理に含まれるステップを表すフロー図を示す。推定される低いHIの原因である一つ又はそれ以上のシステムのコンポーネントを識別するために、健全性監視及び障害特徴識別システム100は、監視されるシステムに対するローカルベイジアンネットワークを生成する(302)。ここで、BNは、推定されるHIとシステムの様々なセンサからの特徴との間の依存関係を捕捉する。

40

【0023】

健全性監視及び障害特徴識別システム100は、BN内に存在するデータに基づいて、推定される低いHIに関連するものとして一つ又はそれ以上のシステムのセンサを識別する(304)。ここで、低いHI(次に、システムの異常挙動)の原因であるものとして、BNに基づいて識別される一つ又はそれ以上のコンポーネントから特定のコンポーネン

50

トを識別するために、健全性監視及び障害特徴識別システム100は、明確化指標(EI)を生成する。ここで、EIは、予測される高いHIの範囲と低いHIの範囲との間の、センサが経時的に取得する読み取り値の分布の変化を介して、HIに関する、各センサの影響を定量化するものである。

【0024】

次に、健全性監視及び障害特徴識別システム100は、低いHI及びシステムの異常挙動に寄与するシステムの一つ又はそれ以上の対応するコンポーネント(即ち、低いHIに寄与するものとして識別されたセンサが関連付けられるコンポーネント)を識別する。例えば、EIが、特定のセンサが障害特徴を伝える原因であることを示す場合、対応するコンポーネントは、システムの異常挙動に寄与するものとして識別される。図3の様々な動作は、同じ順序で、あるいは異なる順序で実行されてもよい。更に、方法300における一つ又はそれ以上の動作は省略されてもよい。

10

【0025】

図4は、本開示のいくつかの実施形態に係る、健全性監視及び障害特徴識別システムによる、センサに対する明確化指標(EI)を生成する処理に含まれるステップを表すフロー図である。センサのEIは、分析されるHIデータ(時系列データ)に対するシステムの識別される低いHIに関して、センサの影響を定量化するものである。

【0026】

センサに対するEIを生成するために、健全性監視及び障害特徴識別システム100のHI記述子モジュール103は、分析される時系列データに対して学習された低いHIデータ及び高いHIデータに関する情報を、入力として収集する(402)。HI記述子モジュール103は、ローカルBNに基づいて、識別される低いHIの条件の下でセンサの分布を計算し(404)、識別される高いHIの条件に対して(406)センサの分布を計算する。更に、センサの分布に基づいて、HI記述子モジュール103は、対応するセンサの各々に対してEIを計算する(408)。HI記述子モジュール103によってEIを計算する処理を以下に説明する。

20

【0027】

HIに対応する離散確率変数H、及び「m」個のセンサに対応するm個の離散確率変数 $\{S_1, S_2, \dots, S_m\}$ の集合を考える。m+1個のノードを有するBNは、センサとHIとの間の依存関係をモデル化するために使用される。一実施形態において、システムのセンサとHIとの間の依存関係をモデル化するために、確率変数 $X = \{S_1, S_2, S_m, H\}$ の集合の結合分布 $P(S_1, S_2, S_m, H)$ が用いられる。各センサと健全性指標HIとの間の依存関係をモデル化し得る実際的なシナリオの実施のために、Hが親ノードであり、且つ各 S_i が子ノードであるナイーブベイズモデルが仮定され得る。

30

【0028】

確率変数 X_i は、変数を取り得る値の範囲に対してk個の離散化されたビンに対応するk個の可能なアウトカム $[b_{i^1}, b_{i^2}, \dots, b_{i^k}]$ を有すると考えられる。窓 A 及び N における時点「t」毎に対するセンサ読み取り値 $X^{(t)}$ 及び健全性指標 $h^{(t)}$ のm次元ベクトルは、確率変数の集合 $X = \{S_1, S_2, \dots, S_m, H\}$ に対する一つの結果を産出する。 S_i に対する条件付き確率分布は次式として与えられる。

40

【数3】

$$P(S_i) = [\hat{p}_i^1, \hat{p}_i^2, \dots, \hat{p}_i^k]$$

ここで、

【数4】

$$\hat{p}_i^j$$

は、 S_i のj番目のアウトカムの確率である。HIの値の所与の範囲に対して、 S_i に対する条件付確率分布は、次式で与えられる。

【数5】

$$P(S_i|H) = [\hat{p}_i^1, \hat{p}_i^2, \dots, \hat{p}_i^k]$$

高いHI (P (S_i | H_{>r})) 及び低いHI (P (S_i | H_{<r})) に対応するHのアウトカムに関して条件付けされる確率変数S_iの分布における変化を用いて、HIに関するi番目のコンポーネントの影響を定量化する。R^kのベクトルとしてP (S_i | H_{>r}) 及びP (S_i | H_{<r}) を考慮すると、変化は、EIに関して次式のように定量化される。

【数6】

$$E(S_i) = \|P(S_i|H_{>r}) - P(S_i|H_{<r})\| \cdot \dots \quad (2)$$

10

ここで、センサの明確化指標が高いほど、HIに関するセンサの影響が高くなる。

【0029】

実験結果：

例1：ターボ機械のデータセットに関する

動作についての、6ヶ月の間記録した、温度、圧力、振動などの、58個のセンサからの読み取り値を含むターボ機械のデータセットを考える。これらのセンサは、ターボ機械のベアリング及び冷却剤などの様々なコンポーネントの挙動を捕捉する。ターボ機械は、複数の制御部を有する自動制御システムを介して制御され、当該複数の制御部は、センサの読み取り値を頻繁に変化させて、それによってセンサの読み取り値を予測不能にさせる。ロング ショート ターム メモリ - エンコーダ デコーダ (Long Short Term Memory Encoder Decoder : LSTM - ED) を、HIの推定に用いる。LSTM - EDは、すべての58個のセンサを再構成するようにトレーニングされる。HI推定モジュール101及びHI記述子モジュール103の性能の詳細は、i) コンポーネントC1における異常な温度変動 (Temp - C₁)、ii) コンポーネントC2における異常な温度変動 (Temp - C₂)、及びiii) 異常な振動の読み取り値、に関する、障害の三つのタイプに関して提供される。

20

【0030】

段階1：HI推定モジュール101によるHI推定：-

【表1】

30

データセット	モデル	アーキテクチャ	精度	リコール	F _{0.1} スコア
エンジン	ロング ショート ターム メモリ - 異常検出 (LSTM - AD)	25ユニット, 1層	0.94	0.12	0.89
ターボ機械	ロング ショート ターム メモリ - エンコーダ デコーダ (LSTM - ED)	500ユニット, 1層	0.96	0.41	0.94

40

表：1

【0031】

表1は、正常な挙動及び障害のある挙動を分類するHI推定モジュール101の性能を示す。Temp - C₁ 及び振動障害に対する最も関連性の高いセンサを、それぞれT₁ 及びV₁ として示す。(図6a、6b、及び6cの場合のような、) センサT₁、V₁、負荷、及びHIに対して、正常な挙動及び障害のある挙動に対するサンプル時系列を示すプロットは、正常な挙動に対してはHIが一貫して高いが、障害のある挙動 (異常挙動) に対して、HIは 以下に落ち込むことを示す。

【0032】

50

H I 値が L S T M - E D 時間モデルから利用可能になると、障害の特徴を伝えるセンサを識別して、次にシステムの関連するコンポーネントを識別するために、B N が構築される。構築された B N の例は、図 5 a (ターボ機械データ) 及び図 5 b (エンジンデータ) に示される。

【 0 0 3 3 】

段階 2 : H I 記述子モジュールの動作 :

【表 2】

障害のタイプ	インスタンスの数	明確にされた インスタンス	平均ランク
Temp - C ₁	3	3	1. 0
Temp - C ₂	1	1	1. 0
振動	6	3	3. 0
合計	1 0	7	2. 2

10

表 : 2

【 0 0 3 4 】

H I 記述子モジュール 1 0 3 は、図 5 a のような B N 構造を使用して、低い H I の領域におけるセンサの挙動を分析する。B N を学習するために、 N_A 及び N_N は、長さ = 7 2 0 であると考えられ、その結果、 N_A 内のポイントのうち少なくとも 7 0 % は、 N_N を下回る H I を有する。障害特徴を伝える最も関連性の高いセンサを見出すために、最も高い E I を有するセンサがランク 1 を取得する一方で、最も低い E I を有するセンサがランク 5 8 を取得するように、センサは、1 から 5 8 までランク付けされる。障害のタイプに対して最も関連性の高いセンサが E I に基づいて最も高いランクを取得する場合、障害のインスタンスは、H I 記述子モジュール 1 0 3 によって明確にされることが考えられる。表 2 は、Temp - C₁ 及び Temp - C₂ のうちのすべてのインスタンス、並びに六つの振動に関する障害のうちの一つが最も高いランクのセンサによって明確にされる、一つの障害のタイプに対する結果を示す。残りの三つのインスタンスに対しては、障害のある窓 N_A 及び対応する正常な窓 N_N に対する動作条件が異なり、誤った明確化につながるということが分かった。これらの場合に対して、最も関連性の高いセンサに対するランクは、2、6、及び 7 であった。これらの値は、最も関連性の高いセンサの分布が、正常な動作条件と異常な動作条件とにわたって大きく変化することを示す。分布におけるこの変化は、E I を使用して捕捉され、最も関連性の高いセンサを見出す。図 7 a 及び図 7 b はそれぞれ、Temp - C₁ に関する障害のうちの一つに対する、H I 及び温度センサ T₁ の全体的な分布を示す。図 7 c 及び図 7 d はそれぞれ、低い H I 及び高い H I の条件下におけるセンサ T₁ に対する分布を示す。振動障害のインスタンスのうちの一つに対する結果を図 7 e ~ 図 7 h に示す。

20

30

【 0 0 3 5 】

例 2 : エンジンデータセットに対する

40

このデータセットは、エンジンの動作についての、3 年間記録した、1 2 個のセンサからの読み取り値を含む。このデータセットにおけるセンサの読み取り値は、ある程度予測可能であり、外部の手動の制御、すなわち、アクセラレータペダルポジション (A P P) に依存する。L S T M の異常検出 (L S T M - A D) に基づく H I の推定は、このデータセットに使用される。すべてのセンサデータは、 $m = 1 2$ となるように L S T M - A D に入力される。推定される低い H I の理由への洞察を得るために、A P P 及び冷却剤温度 (C T) の二つのセンサに対して分析が行われる。見出される低い H I の領域は、異常な C T のうちの三つのインスタンスに対応する。

【 0 0 3 6 】

段階 1 : H I 推定モジュール 1 0 1 による H I 推定 : -

50

表 1 は、H I 推定モジュール 1 0 1 の性能を示す。図 8 a 及び 8 b はそれぞれ、データ内の、正常な領域及び障害のある領域のサンプルに対する、C T、A P P、及び H I に対する時系列のプロットを示す。

【 0 0 3 7 】

段階 2 : 低い H I の理由を識別するための H I 記述子モジュール 1 0 3 の動作 : -

H I とセンサと間の依存関係は、図 5 b のようにモデル化される。ドメイン知識から、高い A P P は高い C T につながる一方で、低い A P P は一時的な挙動が観察されるあるタイムラグを伴って経時的に低い C T につながるということが知られている。A P P 及び C T がそのような時間の相関関係を示さない任意の時間窓は、障害がある（異常である）と考えられる。値は、A P P が高いときには C T も高く（A としてマークされる）、A P P が低いときには C T が低くなることを示す。更に、低い H I の領域における A P P 及び C T の結合分布は、低い H I のバーをインタラクティブに選択することによって調整されるが、このことは、H I が低いときに、機械が異常な動作状態 / 障害のある動作状態にあることを示す。この値は更に、健全な状態（正常な動作）に対応するポイントの数が減少して、健全性に欠けること（異常な動作）を示すポイントの数が增加することを示す。

10

【 0 0 3 8 】

記述した説明は、当業者が実施形態を作成して使用することを可能にする本明細書の主題を記載するものである。主題の実施形態の範囲は、特許請求の範囲によって定義され、当業者が思いつく他の改良を含む場合がある。そのような他の改良は、それらが特許請求の範囲の文言と差異のない同様の要素を有する場合に、あるいは、それらが特許請求の範囲の文言との微差を伴う等価な要素を含む場合に、特許請求の範囲内にあるように意図されている。

20

【 0 0 3 9 】

本明細書の本開示の実施形態は、システムの健全性監視の未解決の課題に対処する。実施形態は、監視されるシステムの健全性指標（H I）を推定する仕組みを提供する。更に、本明細書の実施形態は、システムの障害のある挙動 / 異常な挙動に寄与するシステムのコンポーネントを識別する仕組みを提供する。

【 0 0 4 0 】

保護の範囲が、メッセージを内部に有するコンピュータ可読手段に加えて、そのようなプログラムまで拡張されることが理解されるべきである。そのようなコンピュータ可読記憶手段は、プログラムがサーバ、若しくはモバイル装置、又は任意の適切なプログラマブル装置上で動作するときに、方法のうちの一つ又はそれ以上のステップを実行するプログラムコード手段を含む。ハードウェア装置は、例えば、サーバ若しくはパーソナルコンピュータのような任意の種類のコンピュータ、若しくは同様のもの、又はそれらの任意の組み合わせを含む、プログラム可能な任意の種類の装置であってもよい。装置は、例えば、特定用途向け集積回路（A S I C）、フィールドプログラマブルゲートアレイ（F P G A）、又はハードウェア及びソフトウェア手段の組み合わせ、例えば、A S I C 及び F P G A、又はソフトウェアモジュールが配置される少なくとも一つのマイクロプロセッサ及び少なくとも一つのメモリを含んでもよい。手段は、ハードウェア手段とソフトウェア手段との両方を含んでもよい。本明細書に記載される方法の実施形態は、ハードウェア及びソフトウェア内に実装されてもよい。装置は、ソフトウェア手段を含んでもよい。一方で、実施形態は、例えば複数の C P U を用いて、様々なハードウェア装置上に実装されてもよい。

30

40

【 0 0 4 1 】

本明細書の実施形態は、ハードウェア要素及びソフトウェア要素を含んでもよい。ソフトウェア内に実装される実施形態は、ファームウェア、常駐ソフトウェア、マイクロコードなどを含むが、それらに限定するものではない。本明細書に記載される様々なモジュールによって実行される機能は、他のモジュール又は他のモジュールの組み合わせの中に実装されてもよい。この説明のために、コンピュータ使用可能な媒体又はコンピュータ可読媒体は、命令実行システム、機器、又は装置によって使用され、あるいは、これらと接続

50

して使用される、プログラムを含む、格納する、伝達する、伝搬する、又は搬送する任意の機器である場合がある。

【0042】

示されたステップは、示された例示的な実施形態を説明するために提示しており、継続中の技術開発により、特定の機能を実行する方法が変更されることを予想すべきである。これらの実施例は、説明のために本明細書に提示されるものであって、それらに限定するものではない。更に、機能的な構成ブロックの境界は、説明の便宜上、本明細書において任意に定義されている。指定した機能及びそれらの関係が適切に実行される限り、代わりの境界が定義されてもよい。本明細書に含まれる教示に基づいて、（本明細書に記載されている物の均等物、拡張物、変形物、逸脱物などを含む）代替物は、当業者に明らかである。そのような代替物は、開示された実施形態の範囲及び精神の範囲内に入る。また、単語「comprising」、「having」、「containing」、及び「including」、及び他の類似の形式は、意味が等価であって、これらの単語のいずれかに続く事項がそのような事項を網羅的に記載することを意味するものでも、あるいは記載された事項のみに限定されることを意味するものでもない。本明細書及び添付の特許請求の範囲で使用する単数形「a」、「an」、及び「the」は、文脈上他に明確に指示しない限り、複数の参照物を含むことにも留意すべきである。

10

【0043】

更に、本開示と一致する実施形態を実装する際に、一つ又はそれ以上のコンピュータ可読記憶媒体を利用してもよい。コンピュータ可読記憶媒体は、プロセッサによって読み取り可能な情報又はデータが格納され得る任意のタイプの物理メモリを指す。したがって、コンピュータ可読記憶媒体は、本明細書に記載の実施形態と一致するステップ又は段階をプロセッサに実行させる命令を含む、一つ又はそれ以上のプロセッサによる実行のための命令を格納してもよい。用語「コンピュータ可読媒体」は、有形の物品を含み、搬送波及び過渡信号を除外するように、すなわち非一時的であると理解すべきである。実施例には、ランダムアクセスメモリ（RAM）、読み出し専用メモリ（ROM）、揮発性メモリ、不揮発性メモリ、ハードドライブ、CD-ROM、DVD、フラッシュドライブ、ディスク、及びその他の既知の物理記憶媒体が含まれる。

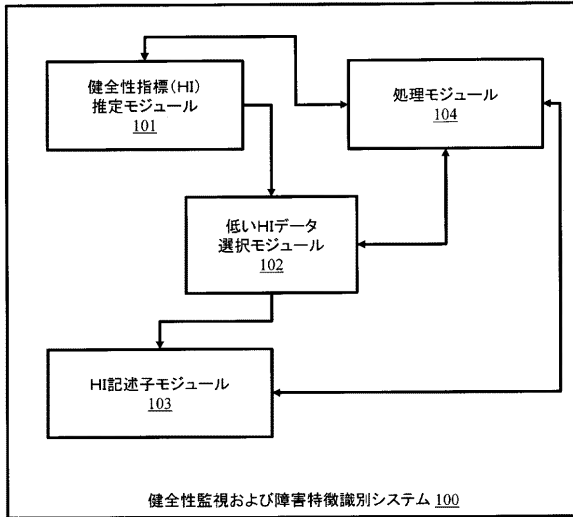
20

【0044】

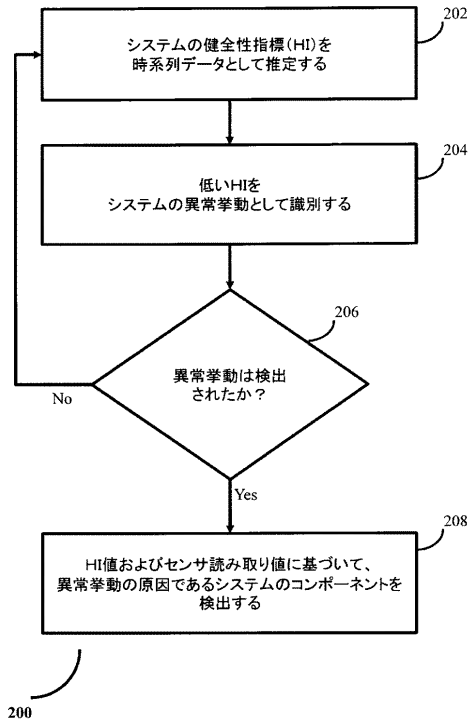
本開示及び実施例は、例示として考慮されるに過ぎず、開示された実施形態の真の範囲及び精神は、添付の特許請求の範囲によって示されることを意図している。

30

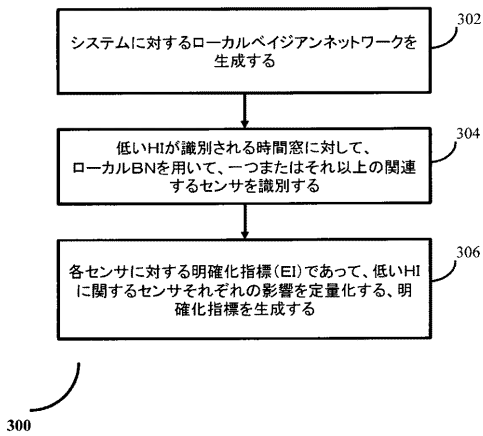
【 図 1 】



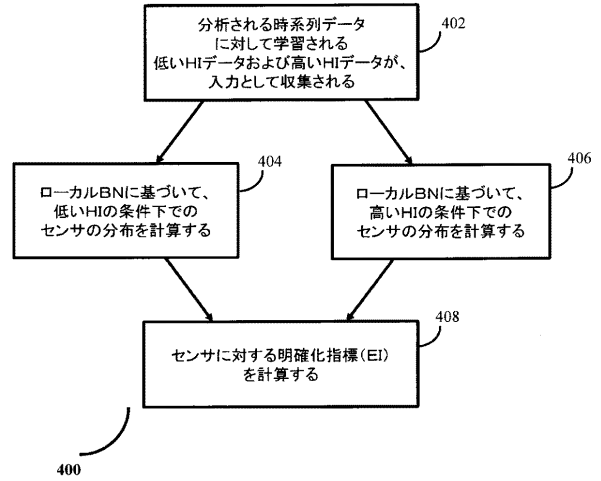
【 図 2 】




【 図 3 】




【 図 4 】




【 図 5 a 】




【 図 5 b 】




【 図 6 a 】




【 図 6 b 】




【 図 6 c 】



【 図 7 a 】




【図 7 b】




センサT₁の全体の分布

【図 7 c】




低いHI条件下でのセンサT₁の分布

【図 7 d】




高いHI条件下でのセンサT₁の分布

【図 7 e】




HI (振動障害)


【図 7 f】




【図 7 g】




【図 7 h】



【図 8 a】



【図 8 b】



フロントページの続き

(74)代理人 100125874

弁理士 川端 純市

(74)代理人 100189544

弁理士 柏原 啓伸

(72)発明者 パンカジ・マルホトラ

インド 2 0 1 3 0 9 ウッタール・プラデーシュ、ノイダ、セクター 6 2、ギャラクシー・ビジネス・パーク、エイ - 4 4 アンド 4 5、タワー・ディ、タタ・コンサルタンシー・サービシーズ・リミテッド

(72)発明者 ヴィシュヌ・トゥヴ

インド 2 0 1 3 0 9 ウッタール・プラデーシュ、ノイダ、セクター 6 2、ギャラクシー・ビジネス・パーク、エイ - 4 4 アンド 4 5、タワー・ディ、タタ・コンサルタンシー・サービシーズ・リミテッド

(72)発明者 ナレンダル・ググロトゥ

インド 2 0 1 3 0 9 ウッタール・プラデーシュ、ノイダ、セクター 6 2、ギャラクシー・ビジネス・パーク、エイ - 4 4 アンド 4 5、タワー・ディ、タタ・コンサルタンシー・サービシーズ・リミテッド

(72)発明者 ロベカシュ・ヴィグ

インド 1 2 2 0 0 3 ハリヤーナー、グルガオン、グウォール・パハリ、グルガオン - ファリダバド・ロード、エイエスエフ・インシグニア、キングズ・キャニオン、ブロック・シー、タタ・コンサルタンシー・サービシーズ・リミテッド

(72)発明者 プニート・アガルワル

インド 2 0 1 3 0 9 ウッタール・プラデーシュ、ノイダ、セクター 6 2、ギャラクシー・ビジネス・パーク、エイ - 4 4 アンド 4 5、タワー・ディ、タタ・コンサルタンシー・サービシーズ・リミテッド

(72)発明者 ゴータム・シュロフ

インド 1 2 2 0 0 3 ハリヤーナー、グルガオン、グウォール・パハリ、グルガオン - ファリダバド・ロード、エイエスエフ・インシグニア、キングズ・キャニオン、ブロック・シー、タタ・コンサルタンシー・サービシーズ・リミテッド

F ターム(参考) 3C223 AA18 BA01 CC01 DD01 EB01 EB02 FF04 FF22 FF24 FF26

GG01

【外国語明細書】

TITLE

METHOD AND SYSTEM FOR HEALTH MONITORING AND FAULT SIGNATURE IDENTIFICATION

CROSS-REFERENCE TO RELATED APPLICATIONS AND PRIORITY

[0001] The present application claims priority to Indian complete specification (Title: METHOD AND SYSTEM FOR HEALTH MONITORING AND FAULT SIGNATURE IDENTIFICATION) Application No. (201721029392), filed in India on 18th of August, 2017.

TECHNICAL FIELD

[001] The disclosure herein generally relates to health monitoring of systems, and, more particularly, to monitor health of a system and to perform fault signature identification.

BACKGROUND

[002] Complex systems deployed in an industry environment need to be monitored to ensure proper working of the system. Such systems would include multiple sub-units of sensors and other components which perform data collection, data processing and so on, and the sub-systems may be communicating each other for data exchange.

[003] It is possible that due to technical issues a sub-system may malfunction, and due to the malfunctioning of the sub-system, readings of corresponding sensors change. In such a connected system, as the throughput of each component/sub-system affects final output of the system, any such malfunction would adversely affect overall throughput of the system.

[004] One way of analyzing such issues is by performing a manual analysis for verifying working of the system components. However, for systems with the large number of components and complex architecture/design, manual analysis would be a tedious task. Manual analysis further demands complex

domain knowledge, and based on amount of knowledge a person has, accuracy of results of verification can also vary.

[005] There are certain methods and systems being used for fault analysis. However, one disadvantage of these systems is that they have limited or no capability of performing a runtime analysis. Furthermore, most of these systems require manual intervention at different stages of the analysis.

SUMMARY

[006] Embodiments of the present disclosure present technological improvements as solutions to one or more of the above-mentioned technical problems recognized by the inventors in conventional systems. For example, in one embodiment, a processor-implemented method for health monitoring and fault signature identification is provided. In this method, for a system being monitored, a Health Index (HI) is generated via one or more hardware processors, by the health monitoring and fault signature identification. By monitoring, the health monitoring and fault signature identification system identifies abnormal behavior of the system, if any, via the one or more hardware processors, wherein an estimated low HI is identified as indicative of the abnormal behavior. The health monitoring and fault signature identification system further detects at least one component of the system as responsible for the abnormal behavior, based on a local Bayesian Network generated for the system.

[007] In another aspect, a health monitoring and fault signature identification system is provided. The system comprising a processor; and a memory module comprising a plurality of instructions. The plurality of instructions are configured to cause the processor to estimate Health Index (HI) of a system being monitored, via one or more hardware processors, by a HI estimation module of the health monitoring and fault detection system. Further, a low HI data selection module of the health monitoring and fault detection system identifies abnormal behavior of the system, if any, via the one or more hardware processors, wherein an estimated low HI is identified as indicative of the abnormal behavior. Upon identifying the abnormal behavior, a HI descriptor

module of the health monitoring and fault detection system detects at least one component of the system as responsible for the abnormal behavior, based on a local Bayesian Network generated for the system, via the one or more hardware processors.

[008] It is to be understood that both the foregoing general description and the following detailed description are exemplary and explanatory only and are not restrictive of the invention, as claimed.

BRIEF DESCRIPTION OF THE DRAWINGS

[009] The accompanying drawings, which are incorporated in and constitute a part of this disclosure, illustrate exemplary embodiments and, together with the description, serve to explain the disclosed principles:

[0010] FIG. 1 illustrates an exemplary block diagram of health monitoring and fault signature identification system according to some embodiments of the present disclosure.

[0011] FIG. 2 is a flow diagram depicting steps involved in the process of performing health monitoring of a system, by the health monitoring and fault signature identification system, according to some embodiments of the present disclosure.

[0012] FIG. 3 illustrates a flow diagram depicting steps involved in the process of identifying one or more components responsible for an abnormal behavior of the system, based on faulty signatures, by the health monitoring and fault signature identification system, in accordance with some embodiments of the present disclosure.

[0013] FIG. 4 illustrates a flow diagram depicting steps involved in the process of generating Explainability Index (EI) for a system component, by the health monitoring and fault signature identification system, in accordance with some embodiments of the present disclosure.

[0014] FIGS 5a and 5b depict Bayesian Networks (BN) generated in an example use-case scenario, in accordance with some embodiments of the present disclosure.

[0015] FIGS 6a through 6c depict sample HI values estimated for a Turbomachinery, in accordance with some embodiments of the present disclosure.

[0016] FIGS 7a through 7h depict sample distributions of sensors which change significantly across the normal and abnormal operations of the system, in accordance with some embodiments of the present disclosure.

[0017] FIGS 8a, and 8b depict sample HI values estimated for normal

operation and abnormal operation of an Accelerator Pedestal Position (APP) and Coolant Temperature (CT) respectively, in accordance with some embodiments of the present disclosure.

DETAILED DESCRIPTION OF EMBODIMENTS

[0018] Exemplary embodiments are described with reference to the accompanying drawings. In the figures, the left-most digit(s) of a reference number identifies the figure in which the reference number first appears. Wherever convenient, the same reference numbers are used throughout the drawings to refer to the same or like parts. While examples and features of disclosed principles are described herein, modifications, adaptations, and other implementations are possible without departing from the spirit and scope of the disclosed embodiments. It is intended that the following detailed description be considered as exemplary only, with the true scope and spirit being indicated by the following claims.

[0019] Referring now to the drawings, and more particularly to FIG. 1 through 8, where similar reference characters denote corresponding features consistently throughout the figures, there are shown preferred embodiments and these embodiments are described in the context of the following exemplary system and/or method.

[0020] FIG. 1 illustrates an exemplary block diagram of health monitoring and fault signature identification system according to some embodiments of the present disclosure. The health monitoring and fault signature identification system 100 includes a Health Index (HI) estimation module 101, a low HI data selection module 102, a HI descriptor module 103, and a processing module 104. When health of a system is to be monitored, the system can be connected with the health monitoring and fault signature identification system 100 using appropriate interfaces such that the health monitoring and fault signature identification system 100 can collect inputs required for the health monitoring as well as for the fault signature identification.

[0021] The HI estimation module 101 is configured to collect, using an appropriate input interface, data from one or more components of the system being monitored, as inputs. Here, the term 'component' is used to refer to any hardware module of the system being analyzed which contributes to HI of the system, and which can be monitored for fault signature identification purpose. For example, the component can be a mechanical component, an electrical

component, and/or an electronic component, that performs one or more functionalities of the system. Using appropriate sensor(s), one or more data associated with one or more of these components are collected and analyzed by the HI estimation module 101 of the health monitoring and fault signature identification system 100, for the purpose of health monitoring and fault signature identification. The HI estimation module 101 further processes the collected inputs, and estimates HI of the system, wherein the HI of the system represents health status of the system. In an embodiment, the HI is estimated as a time-series data that represents health index of a system for different time intervals. In an embodiment, the HI estimation module 101 estimates the HI of the system, using a Recurring Neural Network (RNN). In this method, the HI estimation module 101 considers a multi-sensor data from the system being monitored, to be multivariate time series $x_i = \{x_i^{(1)}, x_i^{(2)}, \dots, x_i^{(l)}\}$ corresponding to i^{th} instance of a machine, where 'l' is length of time series, and each point $x_i^{(t)} \in R^m$ in the time series is an m-dimension vector with each dimension corresponding to a sensor. A model is trained, based on data from a healthy system, to predict or reconstruct the time series. The HI estimation module 101 assumes that error vectors corresponding to healthy behavior are to follow a normal distribution $N(\mu, \Sigma)$, wherein the parameters μ and Σ can be obtained using Maximum Likelihood Estimation method over time series in a training set used. Based on μ and Σ , the HI is computed as:

$$h_i^{(t)} = \log \left(c \cdot \exp \left(\frac{-1}{2} \left(e_i^{(t)} - \mu \right)^T \Sigma^{-1} \left(e_i^{(t)} - \mu \right) \right) \right) \text{ ---- (1)}$$

where $c = \frac{1}{\sqrt{(2\pi)^d |\Sigma|}}$ and 'd' is dimension of error vector. The HI estimation module 101 can be further configured to classify machine instance 'i' as healthy or unhealthy class at time 't' if $h_i^{(t)} > \tau$, where τ can be a value as configured with the HI estimation module 101.

[0022] In an embodiment, the HI estimation module 101 estimates the HI values for specific time intervals i.e. as a time-series data. The HI estimation

module 101 further provides the estimated HI data (i.e. data corresponding to the estimated HI) for each time window as an input to the low HI data selection module 102. The low HI data selection module 102 processes the HI data that is in the form of time-series, and identifies data corresponds to low HI of the system if present. In an embodiment, the low HI data selection module 102 identifies low HI of the system in terms of presence of one or more low HI windows in the time-series data being analyzed, where the term 'low HI window' represents a time window in which majority of HI values are less than a threshold value of HI. In an embodiment, the low HI data selection module 102 identifies the threshold value based on HI values obtained in previous time windows. For instance, by analyzing the HI values obtained in all or certain number of previous time windows, can identify range of HI values in the previous time windows, and accordingly determine the threshold value. In another embodiment, the threshold value is configured by a user, as per requirements/implementation standards. In an embodiment, the presence of low HI window(s) is identified as corresponding to or representing an abnormal behavior of one or more components of the system, and of the system as a whole. The detailed working of the low HI selection module 102 is as follows:

[0023] By processing the obtained time series data, the low HI selection module 102 classifies time windows in the time series data as low HI window(s) and high HI window(s). One time window can have multiple HI values, wherein the number of HI data in a time window depends on the length of the time window. For example, a time window of length 20 seconds can have 20 HI values (one at each second). Based on HI values in a time window, the low HI data selection module 102 classifies the time window as a low HI window or a high HI window. A low HI window is the time window in which majority of HI values are below the threshold, and high HI window is the time window in which majority of HI values are above the threshold. Upon identifying that one or more of the windows in the obtained time series data are low HI windows, the low HI data selection module 102 invokes the HI descriptor module 103 so as to identify component(s) that is responsible for the abnormal behavior of the system, and

provides required inputs to the HI descriptor module 103. In an embodiment, the HI descriptor module 103 is not to be invoked if the HI values indicate a normal functioning of the system.

[0024] The HI descriptor module 103, when invoked, identifies all component(s) responsible for the low HI of the system (which is represented by the low HI values in the estimated time series, and in turn by presence of low HI windows). Input to the HI descriptor module 103 is HI values estimated for multiple time windows. In an embodiment, at least two time windows are required for proper functioning of the HI descriptor module 103, wherein one of the two time windows; one time window ω_A with a majority of low HI values ($h_t^{(e)} \leq \tau$) and the other time window ω_N with a majority of high HI values ($h_t^{(e)} \geq \tau$). The data (HI values) from ω_A and ω_N are used to learn parameters that would constitute the local BN, and generate the local BN for the system being monitored and analyzed. The HI descriptor 103 uses information in the BN for the purpose of mapping an estimated low HI window with one or more components (sensors) of the system. The HI descriptor module 103 then obtains an Explainability Index (EI) for each sensor of the system, based on the local BN and the data collected from the mapped system components, wherein the EI quantifies contribution of each sensor to the estimated low HI value. EI is also represented as $E(S_i)$ in the description. Based on the EI measured for each sensor, the HI descriptor module 103 identifies one or more sensors as carrying faulty signatures that result in the low HI window, and in turn, one or more associated components.

[0025] The processing module 104 can be configured to interact with all other components of the health monitoring and fault signature identification system 100, collect instruction and execute one or more steps with respect to function(s) being handled by each module using one or more associated hardware processors.

[0026] FIG. 2 is a flow diagram depicting steps involved in the process of performing health monitoring of a system, by the health monitoring and fault

signature identification system, according to some embodiments of the present disclosure. The health monitoring and fault signature identification system 100 while monitoring a system for health assessment, collects real-time information pertaining to various parameters that are directly and/or indirectly associated with health of a system, as inputs. For instance, by using appropriate sensors, data from one or more components of the system being monitored is collected as inputs.

[0027] By processing the collected inputs, the health monitoring and fault signature identification system 100 estimates (202) a Health Index (HI) of the system, as a time-series data. The health monitoring and fault signature identification system 100 further identifies, by processing the time-series data, one or more low HI windows (if present) in which majority of the HI values are below a threshold value of HI, which in turn indicates low HI of the system being monitored. The health monitoring and fault signature identification system 100 identifies (204) the low HI as an indicative of abnormal behavior of the system. If an abnormal behavior of the system is detected, then the health monitoring and fault signature identification system 100, based on a local Bayesian Network (BN) generated for the system, detects (208) one or more components of the system as carrying the (faulty) signature(s) for the abnormal behavior of the system. Various actions in Fig. 2 can be performed in the same order or in a different order. Further, or one or more of the actions in method 200 can be omitted.

[0028] FIG. 3 illustrates a flow diagram depicting steps involved in the process of identifying one or more components responsible for a low HI of the system, based on faulty signatures, by the health monitoring and fault signature identification system, in accordance with some embodiments of the present disclosure. In order to identify one or more system components that are responsible for an estimated low HI, the health monitoring and fault signature identification system 100 generates (302) a local Bayesian network for the system being monitored, wherein the BN captures dependencies between estimated HI and signatures from different sensors of the system.

[0029] The health monitoring and fault signature identification system

100, based on the data present in the BN, identifies (304) one or more system sensors as associated with the estimated low HI. Now, in order to identify specific component out of the one or more components identified based on the BN, as responsible for the low HI (and in turn the abnormal behavior of the system), the health monitoring and fault signature identification system 100 generates (306) an Explainability Index (EI), wherein the EI quantifies the effect of each sensor on the HI through the change in distribution of the readings a sensor takes over time between predicted high HI and low HI ranges, and in turn identifies one or more corresponding components of the system (i.e. the component with which the sensor that has been identified as contributing to the low HI is associated with) that contribute to the low HI and the abnormal behavior of the system. For example, if EI indicates that a particular sensor is responsible for carrying the faulty signature, then the corresponding component(s) is identified as contributing to the abnormal behavior of the system. Various actions in Fig. 3 can be performed in the same order or in a different order. Further, or one or more of the actions in method 300 can be omitted.

[0030] FIG. 4 illustrates a flow diagram depicting steps involved in the process of generating Explainability Index (EI) for a sensor, by the health monitoring and fault signature identification system, in accordance with some embodiments of the present disclosure. The EI of a sensor quantifies effect of the sensor on an identified low HI of the system for a HI data (time-series data) being analyzed.

[0031] In order to generate the EI for a sensor, the HI descriptor module 103 of the health monitoring and fault signature identification system 100 collects (402) information pertaining to low HI data and high HI data learnt for the time-series data being analyzed, as inputs. The HI descriptor module 103, based on the local BN, calculates (404) sensor distribution under the identified low HI condition, and for the identified high HI condition (406). Further, based on the sensor distribution, the HI descriptor module 103 computes (408) EI for each of the corresponding sensors. The process of computing the EI by the HI descriptor module 103 is explained below:

[0032] Consider a discrete random variable H corresponding to HI, and a set of m discrete random variables $\{S_1, S_2, \dots, S_m\}$ corresponding to 'm' sensors. A BN with $m + 1$ nodes is used to model dependence between the sensors and HI. In an embodiment, for the purpose of modelling dependence between sensors of the system and HI, a joint distribution $P(S_1, S_2, S_m, H)$ of a set of random variables $X = \{S_1, S_2, S_m, H\}$. For a practical scenario practice in which dependence between each sensor and the health index HI is to be modelled, a naive Bayes model with H being the parent node and each S_i being a child node can be assumed.

[0033] A random variable $X_i \in X$ is considered to have k possible outcomes $[b_i^1, b_i^2, \dots, b_i^k]$ corresponding to k discretized bins for the range of values the variable can take. An m -dimensional vector of sensor readings $X^{(t)}$ and health index $h^{(t)}$ for every time instant 't' in windows ω_A and ω_N yield one observation for the set of random variables $X = \{S_1, S_2, \dots, S_m, H\}$. A marginal probability distribution for S_i is given as $P(S_i) = [\hat{p}_i^1, \hat{p}_i^2, \dots, \hat{p}_i^k]$, where \hat{p}_i^j is probability of j^{th} outcome of S_i . For a given range of values of HI, conditional probability distribution for S_i is given by $P(S_i|H) = [\hat{p}_i^1, \hat{p}_i^2, \dots, \hat{p}_i^k]$. A change in distribution of random variable S_i conditioned on outcomes of H corresponding to high HI ($P(S_i | H_{>r})$) and low HI ($P(S_i | H_{<r})$) is used to quantify the effect of i^{th} component on HI. Considering $P(S_i | H_{>r})$ and $P(S_i | H_{<r})$ as vectors in R^k , change is quantified in terms of EI as:

$$E(S_i) = \|P(S_i | H_{>r}) - P(S_i | H_{<r})\| \quad \dots (2)$$

where, higher the Explainability index of a sensor, higher is the effect of the sensor on the HI.

Experimental Results:

Example 1:- On a Turbomachinery Dataset

[0034] Consider a turbomachinery dataset containing readings from 58 sensors such as temperature, pressure, and vibration, recorded for 6 months of

operation. These sensors capture behavior of different components such as bearing and coolant of the turbomachinery. The turbomachinery is controlled via an automated control system having multiple controls making the sensor readings change frequently, and hence, unpredictable. A Long Short Term Memory-Encoder Decoder (LSTM-ED) is used for HI estimation. A LSTM ED is trained to reconstruct all 58 sensors. Performance details of the HI estimation module 101 and the HI descriptor module 103 are provided on three types of faults, related to: i) abnormal temperature fluctuations in component C_1 (Temp- C_1), ii) abnormal temperature fluctuations in component C_2 (Temp- C_2), and iii) abnormal vibration readings.

Stage 1: HI estimation by HI estimation module 101:-

Dataset	Model	Architecture	precision	Recall	$F_{0.1}$ score
Engine	Long Short Term Memory – Anomaly Detection (LSTM-AD)	25 units, 1 layer	0.94	0.12	0.89
Turbomachinery	Long Short Term Memory – Encoder Decoder (LSTM-ED)	500 units, 1 layer	0.96	0.41	0.94

Table: 1

[0035] Table 1 shows the performance of HI estimation module 101 for classifying normal and faulty behavior. Most relevant sensor for Temp-C₁ and Vibration faults are denoted as T₁ and V₁, respectively. A plot depicting sample time series for normal and faulty behavior for sensors T₁, V₁, Load, and HI (as in Figs. 6a, 6b, and 6c) indicate that while HI is consistently high for normal behavior, it drops below r for faulty behavior (abnormal behavior).

[0036] Once HI values are available from LSTM-ED temporal model, a BN is built for the purpose of identifying sensors that carry faulty signature, and in turn the associated component(s) of the system. Examples of BNs built are given in Fig. 5a (turbomachinery data) and Fig. 5b (Engine data).

Stage 2: HI descriptor module operation:

Fault Type	Number of instances	Explained instances	Average Rank
Temp-C ₁	3	3	1.0
Temp-C ₂	1	1	1.0
Vibration	6	3	3.0
Total	10	7	2.2

Table. 2

[0037] The HI descriptor module 103 uses the BN structure as in Fig. 5a to analyze sensor behavior in regions of low HI. For learning BN, ω_A and ω_N are considered to be of length $\omega=720$, such that at least 70% of points in ω_A have HI below r . To find the most relevant sensor carrying the fault signature, the sensors are ranked from 1 to 58 such that the sensor with highest EI gets rank 1 while sensor with lowest EI gets rank 58. A fault instance is considered to be explained by the HI descriptor module 103, if the most relevant sensor for the fault type gets the highest rank based on EI. Table 2 shows the results for the three fault types where all the instances of Temp-C₁ and Temp-C₂, and 3 out of 6 vibration related faults could be explained by the highest ranked sensor. For the remaining

three instances, it has been found that operating conditions for the faulty window ω_A and the corresponding normal window ω_N were different leading to incorrect explanations. Thus for these cases, the ranks for the most relevant sensor were 2, 6, and 7. These values indicate that distribution of the most relevant sensor changes significantly across the normal and abnormal operating conditions. This change in distribution is captured using EI to find the most relevant sensor. Figures 7a and 7b show overall distributions of HI and temperature sensor T_1 , respectively, for one of the faults related to Temp- C_1 . Figures 7c and 7d show the distributions for sensor T_1 under low HI and high HI conditions, respectively. The results for one of the instances of vibration fault are shown in Figures 7e-7h.

Example 2: For Engine Dataset

[0038] This dataset contains readings from 12 sensors, recorded for 3 years of engine operation. The sensor readings in this dataset are quasi-predictable and depend on an external manual control, namely, Accelerator Pedal Position (APP). LSTM Anomaly Detection (LSTM-AD) based HI Estimation is used for this dataset. All sensors data are input to LSTM-AD such that $m = 12$. Analysis is done for two of the sensors: APP and Coolant Temperature (CT) to get insights into the reasons for estimated low HI. The low HI regions found correspond to three instances of abnormal CT.

Stage 1: HI estimation by HI estimation module 101:-

[0039] Table 1 shows the performance of the HI estimation module 101. Figures 8a and 8b show the time series plots for CT, APP, and HI for samples of normal and faulty regions in the data, respectively.

Stage 2: Working of HI descriptor module 103 for identifying reason for low HI:-

[0040] Dependency between HI and sensors is modelled as in Fig. 5b. From domain knowledge, it is known that high APP leads to high CT, while low APP leads to low CT over time with a certain time lag where transient behavior is observed. Any time window over which APP and CT do not exhibit such a temporal correlation is considered faulty (abnormal). Values indicate that when APP is high, CT is also high (marked as A), and when APP is low, CT is low.

Further, joint distribution of APP and CT on the low HI regions is conditioned by interactively selecting low HI bars, which indicate that when HI is low, machine is in an abnormal/faulty operation state. The values further indicate that number of points corresponding to healthy state (normal working) decrease and those indicating poor health (abnormal working) increase when HI is low.

[0041] The written description describes the subject matter herein to enable any person skilled in the art to make and use the embodiments. The scope of the subject matter embodiments is defined by the claims and may include other modifications that occur to those skilled in the art. Such other modifications are intended to be within the scope of the claims if they have similar elements that do not differ from the literal language of the claims or if they include equivalent elements with insubstantial differences from the literal language of the claims.

[0042] The embodiments of present disclosure herein addresses unresolved problem of health monitoring of a system. The embodiment, thus provides a mechanism for estimating Health Index (HI) of a system being monitored. Moreover, the embodiments herein further provides a mechanism for identifying system component(s) that contribute to the faulty/abnormal behavior of the system.

[0043] It is to be understood that the scope of the protection is extended to such a program and in addition to a computer-readable means having a message therein; such computer-readable storage means contain program-code means for implementation of one or more steps of the method, when the program runs on a server or mobile device or any suitable programmable device. The hardware device can be any kind of device which can be programmed including e.g. any kind of computer like a server or a personal computer, or the like, or any combination thereof. The device may also include means which could be e.g. hardware means like e.g. an application-specific integrated circuit (ASIC), a field-programmable gate array (FPGA), or a combination of hardware and software means, e.g. an ASIC and an FPGA, or at least one microprocessor and at least one memory with software modules located therein. Thus, the means can

include both hardware means and software means. The method embodiments described herein could be implemented in hardware and software. The device may also include software means. Alternatively, the embodiments may be implemented on different hardware devices, e.g. using a plurality of CPUs.

[0044] The embodiments herein can comprise hardware and software elements. The embodiments that are implemented in software include but are not limited to, firmware, resident software, microcode, etc. The functions performed by various modules described herein may be implemented in other modules or combinations of other modules. For the purposes of this description, a computer-usable or computer readable medium can be any apparatus that can comprise, store, communicate, propagate, or transport the program for use by or in connection with the instruction execution system, apparatus, or device.

[0045] The illustrated steps are set out to explain the exemplary embodiments shown, and it should be anticipated that ongoing technological development will change the manner in which particular functions are performed. These examples are presented herein for purposes of illustration, and not limitation. Further, the boundaries of the functional building blocks have been arbitrarily defined herein for the convenience of the description. Alternative boundaries can be defined so long as the specified functions and relationships thereof are appropriately performed. Alternatives (including equivalents, extensions, variations, deviations, etc., of those described herein) will be apparent to persons skilled in the relevant art(s) based on the teachings contained herein. Such alternatives fall within the scope and spirit of the disclosed embodiments. Also, the words “comprising,” “having,” “containing,” and “including,” and other similar forms are intended to be equivalent in meaning and be open ended in that an item or items following any one of these words is not meant to be an exhaustive listing of such item or items, or meant to be limited to only the listed item or items. It must also be noted that as used herein and in the appended claims, the singular forms “a,” “an,” and “the” include plural references unless the context clearly dictates otherwise.

[0046] Furthermore, one or more computer-readable storage media may

be utilized in implementing embodiments consistent with the present disclosure. A computer-readable storage medium refers to any type of physical memory on which information or data readable by a processor may be stored. Thus, a computer-readable storage medium may store instructions for execution by one or more processors, including instructions for causing the processor(s) to perform steps or stages consistent with the embodiments described herein. The term “computer-readable medium” should be understood to include tangible items and exclude carrier waves and transient signals, i.e., be non-transitory. Examples include random access memory (RAM), read-only memory (ROM), volatile memory, nonvolatile memory, hard drives, CD ROMs, DVDs, flash drives, disks, and any other known physical storage media.

[0047] It is intended that the disclosure and examples be considered as exemplary only, with a true scope and spirit of disclosed embodiments being indicated by the following claims.

CLAIMS

We Claim:

1. A processor-implemented method for health monitoring and fault signature identification, said method comprising:
 - estimating Health Index (HI) of a system being monitored, via one or more hardware processors, by a health monitoring and fault signature identification system;
 - identifying abnormal behavior of the system, if any, via the one or more hardware processors, by the health monitoring and fault signature identification system, wherein an estimated low HI is identified as indicative of the abnormal behavior; and
 - detecting at least one component of the system as responsible for the abnormal behavior, based on a local Bayesian Network generated for the system, via the one or more hardware processors, by the health monitoring and fault signature identification system.
2. The method as claimed in claim 1, wherein the low HI is identified in terms of presence of at least one low HI window in data corresponding to the estimated HI of the system.
3. The method as claimed in claim 1, wherein the HI is estimated using a Recurring Neural network (RNN).
4. The method as claimed in claim 1, wherein data corresponding to the estimated HI is obtained as a time series data.
5. The method as claimed in claim 4, wherein detecting the at least one component responsible for the abnormal behavior comprises of:
 - analyzing the data corresponding to the estimated HI, wherein the data corresponding to the estimated HI is split in different time windows;
 - identifying at least one low HI window, if present, wherein a majority of HI values of all HI values of a low HI window are

below a threshold value of HI;
identifying at least one high HI window, wherein a majority of HI values of all HI values of the high HI window are above the threshold value of HI;
generating the local BN for the system, based on data from the at least one low HI window, and data from the at least one high HI window;
generating an Explainability Index (EI) for at least one sensor from which data for the HI estimation is collected, based on the local BN, wherein the EI quantifies contribution of the sensor to the low HI; and
identifying dependency between the low HI and at least one component of the system, based on the EI generated for the at least one sensor.

6. A health monitoring and fault signature identification system, said system comprising:
 - a processor; and
 - a memory module comprising a plurality of instructions, said plurality of instructions configured to cause the processor to:
 - estimate Health Index (HI) of a system being monitored, via one or more hardware processors, by a HI estimation module of the health monitoring and fault detection system;
 - identify abnormal behavior of the system, if any, via the one or more hardware processors, by a low HI data selection module of the health monitoring and fault detection system, wherein an estimated low HI is identified as indicative of the abnormal behavior; and
 - detect at least one component of the system as responsible for the abnormal behavior, based on a local Bayesian Network (BN) generated for the system, via the one or more hardware processors, by a HI descriptor module of the health monitoring

and fault detection system.

7. The health monitoring and fault detection system as claimed in claim 6, wherein the low HI data selection module is configured to identify the low HI in terms of presence of at least one low HI window in data corresponding to the estimated HI of the system.
8. The health monitoring and fault detection system as claimed in claim 6, wherein the HI estimation module is configured to estimate the HI using a Recurring Neural network (RNN).
9. The health monitoring and fault detection system as claimed in claim 6, wherein the HI estimation module is configured to estimate the HI as a time series data.
10. The health monitoring and fault detection system as claimed in claim 9, wherein the HI descriptor module is configured to detect the at least one component responsible for the abnormal behavior by:
 - analyzing data corresponding to the estimated HI, wherein the data corresponding to the estimated HI is split in different time windows;
 - identifying at least one low HI window, if present, wherein a majority of HI values of all HI values of the low HI window are below a threshold value of HI;
 - identifying at least one high HI window, wherein a majority of HI values of all HI values of the high HI window are above the threshold value of HI;
 - generating the local BN for the system, based on data from the at least one low HI window, and data from the at least one high HI window;
 - generating an Explainability Index (EI) for at least one sensor from which data for the HI estimation is collected, based on the local BN, wherein the EI quantifies contribution of the sensor to the low HI; and
 - identifying dependency between the low HI data and at least one

component of the system, based on the EI generated for at least one sensor.

11. One or more non-transitory machine readable information storage mediums comprising one or more instructions which when executed by one or more hardware processors causes:
 - estimating Health Index (HI) of a system being monitored, via one or more hardware processors, by a health monitoring and fault signature identification system;
 - identifying abnormal behavior of the system, if any, via the one or more hardware processors, by the health monitoring and fault signature identification system, wherein an estimated low HI is identified as indicative of the abnormal behavior; and
 - detecting at least one component of the system as responsible for the abnormal behavior, based on a local Bayesian Network generated for the system, via the one or more hardware processors, by the health monitoring and fault signature identification system.
12. The one or more non-transitory machine readable information storage mediums of claim 11, wherein the low HI is identified in terms of presence of at least one low HI window in data corresponding to the estimated HI of the system.
13. The one or more non-transitory machine readable information storage mediums of claim 11, wherein the HI is estimated using a Recurring Neural network (RNN).
14. The one or more non-transitory machine readable information storage mediums of claim 11, wherein data corresponding to the estimated HI is obtained as a time series data.
15. The one or more non-transitory machine readable information storage mediums of claim 14, wherein detecting the at least one component responsible for the abnormal behavior comprises of:
 - analyzing the data corresponding to the estimated HI, wherein the

data corresponding to the estimated HI is split in different time windows;

identifying at least one low HI window, if present, wherein a majority of HI values of all HI values of a low HI window are below a threshold value of HI;

identifying at least one high HI window, wherein a majority of HI values of all HI values of the high HI window are above the threshold value of HI;

generating the local BN for the system, based on data from the at least one low HI window, and data from the at least one high HI window;

generating an Explainability Index (EI) for at least one sensor from which data for the HI estimation is collected, based on the local BN, wherein the EI quantifies contribution of the sensor to the low HI; and

identifying dependency between the low HI and at least one component of the system, based on the EI generated for the at least one sensor.

ABSTRACT**METHOD AND SYSTEM FOR HEALTH MONITORING AND FAULT
SIGNATURE IDENTIFICATION**

System and method for health monitoring and fault signature identification of a system are disclosed. In an embodiment, the system, estimates Health Index (HI) of the system as time series data. By analyzing data corresponding to the estimated HI, the system identifies one or more time windows in which majority of the estimated HI values are low as a low HI window, and one or more time windows in which majority of the estimated HI values are high as a high HI window. Upon identifying a low HI window, which indicates an abnormal behavior of the system being monitored, the system, based on a local Bayesian Network generated for the system being monitored, generates an Explainability Index (EI) for each sensor, wherein the EI quantifies contribution of the sensor to the low HI. Further, associated component(s) is identified as contributing to the abnormal/faulty behavior of the system.

Fig. 1

Sheet No: 1
Total No. of Sheets: 18

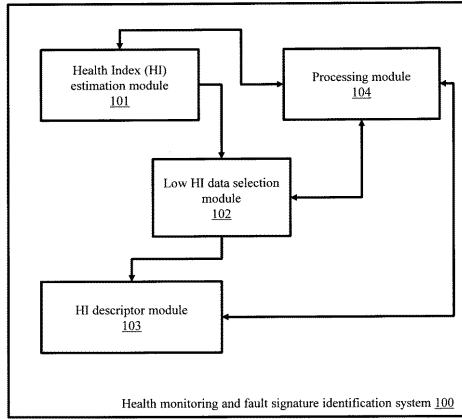


Fig. 1

Sheet No: 2
Total No. of Sheets: 18

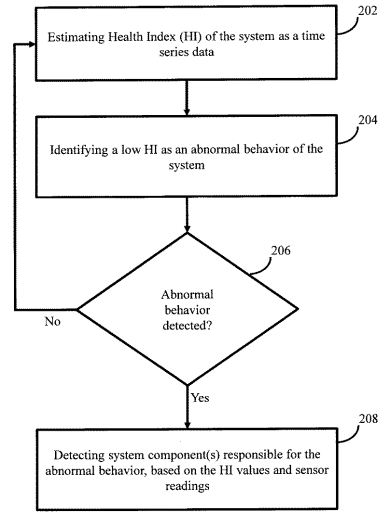


Fig. 2

200

Sheet No: 3
Total No. of Sheets: 18

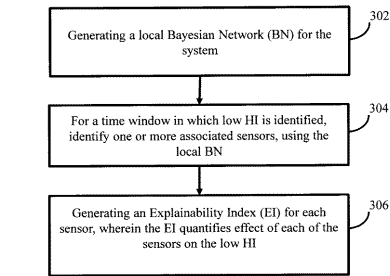


Fig. 3

300

Sheet No: 4
Total No. of Sheets: 18

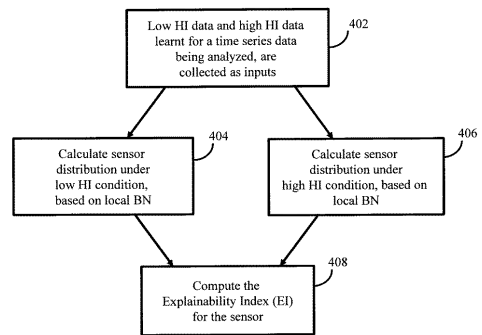


Fig. 4

400

Sheet No: 5
Total No. of Sheets: 18




Fig. 5a





Fig. 5b


Sheet No: 6
Total No. of Sheets: 18



(Normal Operation)


Fig. 6a

Sheet No: 7
Total No. of Sheets: 18



(Temp-C₁ Fault)
Fig. 6b

Sheet No: 8
Total No. of Sheets: 18



(Vibration Fault)
Fig. 6c

Sheet No: 9
Total No. of Sheets: 18

Sheet No: 10
Total No. of Sheets: 18




Fig. 7a




Fig. 7b

Sheet No: 11
Total No. of Sheets: 18

Sheet No: 12
Total No. of Sheets: 18




Fig. 7c




Fig. 7d

Sheet No: 13
Total No. of Sheets: 18

Sheet No: 14
Total No. of Sheets: 18




Fig. 7e




Fig. 7f

Sheet No: 15
Total No. of Sheets: 18

Sheet No: 16
Total No. of Sheets: 18




Fig. 7g




Fig. 7h

Sheet No: 17
Total No. of Sheets: 18

Sheet No: 18
Total No. of Sheets: 18




Fig. 8a




Fig. 8b