

(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2007-257366
(P2007-257366A)

(43) 公開日 平成19年10月4日(2007.10.4)

(51) Int. Cl. F I テーマコード (参考)
G06N 3/00 (2006.01) G06N 3/00 560A 5H223
G05B 23/02 (2006.01) G05B 23/02 302S

審査請求 未請求 請求項の数 36 O L (全 33 頁)

(21) 出願番号 特願2006-81628 (P2006-81628)
 (22) 出願日 平成18年3月23日 (2006.3.23)

(71) 出願人 304028346
 国立大学法人 香川大学
 香川県高松市幸町1番1号
 (71) 出願人 000190297
 新キャタピラー三菱株式会社
 東京都世田谷区用賀四丁目10番1号
 (74) 代理人 100092978
 弁理士 真田 有
 (72) 発明者 清田 雄彦
 香川県高松市林町2217-20 国立大
 学法人香川大学工学部内
 (72) 発明者 バチコフ ガンチョ ルベノフ
 香川県高松市林町2217-20 国立大
 学法人香川大学工学部内

最終頁に続く

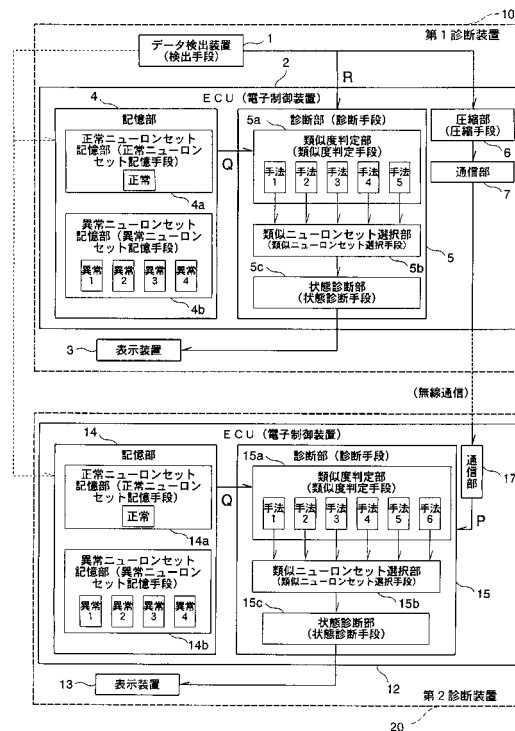
(54) 【発明の名称】 診断装置及び診断方法

(57) 【要約】

【課題】 診断装置及び診断方法に関し、対象体の状態をより正確に診断できるようにする。

【解決手段】 対象体の状態に応じて変動する複数のパラメータからなるデータを検出する検出手段1と、正常状態の対象体から検出されたデータをデータセットとして、ニューラルネットワークの教師なし学習により圧縮した正常ニューロンセットを記憶する正常ニューロンセット記憶手段4aと、異常状態の対象体から検出されたデータをデータセットとして圧縮した異常ニューロンセットを、異常状態の種類とともに複数組記憶する異常ニューロンセット記憶手段4bと、対象体の状態が未確定であるときに検出手段1によって検出されるデータを実データセットとし、実データセットと異常ニューロンセット記憶手段4bに記憶された異常ニューロンセットとに基づいて、対象体における異常状態の種類を診断する診断手段5とを備える。

【選択図】 図1



【特許請求の範囲】

【請求項 1】

対象体の状態を診断するための診断装置であって、

該対象体の該状態に応じて変動する複数のパラメータからなるデータを検出する検出手段と、

正常状態にある該対象体から該検出手段によって検出された複数の該データをデータセットとして、ニューラルネットワークの教師なし学習により圧縮した正常ニューロンセットを記憶する正常ニューロンセット記憶手段と、

異常状態にある該対象体から該検出手段によって検出された複数の該データをデータセットとして、ニューラルネットワークの教師なし学習により圧縮した異常ニューロンセットを、該異常状態の種類とともに複数組記憶する異常ニューロンセット記憶手段と、

該対象体の該状態が未確定であるときに該検出手段によって検出される複数の該データを実データセットとして、該実データセットと該正常ニューロンセット記憶手段に記憶された該正常ニューロンセットとに基づいて、該対象体が正常状態にあるか否かを判定するとともに、該実データセットと該異常ニューロンセット記憶手段に記憶された該異常ニューロンセットとに基づいて、該対象体における該異常状態の種類を診断する診断手段とを備えたことを特徴とする、診断装置。

10

【請求項 2】

該診断手段が、

該実データセットと該異常ニューロンセットとのユークリッド距離が小さいほど、該実データセットの該異常ニューロンセットに対する類似度が高いと判定する類似度判定手段と、

20

該類似度判定手段により該実データセットとの類似度が最も高いと判定された異常ニューロンセットを選択する類似ニューロンセット選択手段と、

該対象体における該異常状態を、該類似ニューロンセット選択手段で選択された該異常ニューロンセットに対応する種類の該異常状態であると診断する状態診断手段とを有することを特徴とする、請求項 1 記載の診断装置。

【請求項 3】

該対象体の該状態が未確定であるときに該検出手段で検出される複数の該データを実データセットとして、ニューラルネットワークの教師なし学習により実ニューロンセットへと圧縮する圧縮手段を備え、

30

該診断手段が、

該圧縮手段で圧縮された実ニューロンセットと該異常ニューロンセットとのユークリッド距離が小さいほど、該実ニューロンセットの該異常ニューロンセットに対する類似度が高いと判定する類似度判定手段と、

該類似度判定手段により類似度が最も高いと判定された異常ニューロンセットを選択する類似ニューロンセット選択手段と、

該対象体における該異常状態を、該類似ニューロンセット選択手段で選択された該異常ニューロンセットに対応する種類の該異常状態であると診断する状態診断手段とを有することを特徴とする、請求項 1 記載の診断装置。

40

【請求項 4】

該類似度判定手段が、該実データセットを構成する各データと該異常ニューロンセットを構成する各ニューロンとの間のユークリッド距離の平均値を演算して該類似度を判定する

ことを特徴とする、請求項 2 記載の診断装置。

【請求項 5】

該異常ニューロンセット記憶手段が、該異常ニューロンセットへの圧縮時に各ニューロン毎のウェイトを演算するとともに、

該類似度判定手段が、該実データセットを構成する各データと該異常ニューロンセットを構成する各ニューロンとの間のユークリッド距離の平均値及び該ウェイトに基づいて該

50

類似度を判定する

ことを特徴とする、請求項 2 記載の診断装置。

【請求項 6】

該類似度判定手段が、該実データセットを構成する各データと該異常ニューロンセットを構成する各ニューロンとの間の最小ユークリッド距離の平均値を演算して該類似度を判定する

ことを特徴とする、請求項 2 記載の診断装置。

【請求項 7】

該異常ニューロンセット記憶手段が、該異常ニューロンセットへの圧縮時に各ニューロン毎のウェイトを演算するとともに、

該類似度判定手段が、該実データセットを構成する各データと該異常ニューロンセットを構成する各ニューロンとの間の最小ユークリッド距離の平均値及び該ウェイトに基づいて該類似度を判定する

ことを特徴とする、請求項 2 記載の診断装置。

【請求項 8】

該類似度判定手段が、該実データセットの重心と該異常ニューロンセットの重心とのユークリッド距離を演算して該類似度を判定する

ことを特徴とする、請求項 2 記載の診断装置。

【請求項 9】

該類似度判定手段が、該実ニューロンセットを構成する各ニューロンと異常ニューロンセットを構成する各ニューロンとの全てのペアのユークリッド距離の平均値を演算して該類似度を判定する

ことを特徴とする、請求項 3 記載の診断装置。

【請求項 10】

該圧縮手段が、該実ニューロンセットへの圧縮時に各ニューロン毎の第 1 ウェイトを演算し、

該異常ニューロンセット記憶手段が、該異常ニューロンセットへの圧縮時に各ニューロン毎の第 2 ウェイトを演算するとともに、

該類似度判定手段が、該実ニューロンセットを構成する各ニューロンと異常ニューロンセットを構成する各ニューロンとの全てのペアのユークリッド距離の平均値、該第 1 ウェイト及び該第 2 ウェイトに基づいて該類似度を判定する

ことを特徴とする、請求項 3 記載の診断装置。

【請求項 11】

該類似度判定手段が、該実ニューロンセットを構成する各ニューロンから該異常ニューロンセットを構成する各ニューロンまでの最小ユークリッド距離の平均値を演算して該類似度を判定する

ことを特徴とする、請求項 3 記載の診断装置。

【請求項 12】

該圧縮手段が、該実ニューロンセットへの圧縮時に各ニューロン毎の第 1 ウェイトを演算するとともに、

該類似度判定手段が、該実ニューロンセットを構成する各ニューロンから該異常ニューロンセットを構成する各ニューロンまでの最小ユークリッド距離の平均値及び該第 1 ウェイトに基づいて該類似度を判定する

ことを特徴とする、請求項 3 記載の診断装置。

【請求項 13】

該圧縮手段が、該実ニューロンセットへの圧縮時に各ニューロン毎の第 1 ウェイトを演算し、

該異常ニューロンセット記憶手段が、該異常ニューロンセットへの圧縮時に各ニューロン毎の第 2 ウェイトとを演算するとともに、

該類似度判定手段が、該実ニューロンセットを構成する各ニューロンから該異常ニュー

10

20

30

40

50

ロンセットを構成する各ニューロンまでの最小ユークリッド距離の平均値，該第1ウェイト及び該第2ウェイトに基づいて該類似度を判定することを特徴とする、請求項3記載の診断装置。

【請求項14】

該類似度判定手段が、該実ニューロンセットの重心と該異常ニューロンセットの重心とのユークリッド距離を演算して該類似度を判定することを特徴とする、請求項3記載の診断装置。

【請求項15】

該診断手段が、該類似度判定手段における該類似度の判定に際し、複数の異なる演算方法を設定する類似度演算方法設定手段を有し、

該類似ニューロンセット選択手段が、該類似度演算方法設定手段で設定された該複数の異なる演算方法毎に、最も類似度の高い異常ニューロンセットを選択するとともに、

該状態診断手段が、該対象体における該異常状態を、該類似ニューロンセット選択手段における選択回数の最も多い該異常ニューロンセットに対応する種類の該異常状態であると診断する

ことを特徴とする、請求項2又は3記載の診断装置。

【請求項16】

該異常ニューロンセット記憶手段が、該実データセットを用いて該異常ニューロンセットを更新又は変更する

ことを特徴とする、請求項1～15の何れか1項に記載の診断装置。

【請求項17】

該実データセットに対応する該対象体の該状態が未知の異常状態にあるか否かを判定する未知異常状態判定手段を備え、

該異常ニューロンセット記憶手段が、該未知異常状態判定手段において判定された該未知の異常状態に対応する該実データセットをニューラルネットワークの教師なし学習により圧縮した未知異常ニューロンセットを、該未知の異常状態の種類とともに新たに記憶する

ことを特徴とする、請求項16記載の診断装置。

【請求項18】

該未知異常状態判定手段が、該実データセットと該異常ニューロンセットとのユークリッド距離に基づいて、該対象体が未知の異常状態にあるか否かを判定する

ことを特徴とする、請求項17記載の診断装置。

【請求項19】

対象体の状態を診断するための診断方法であって、

正常状態にある該対象体から、該対象体の該状態に応じて変動する複数のパラメータからなるデータを検出するとともに、複数の該データを正常データセットとして検出する正常データセット検出ステップと、

該正常データセットをニューラルネットワークの教師なし学習により圧縮した正常ニューロンセットを記憶する正常ニューロンセット記憶ステップと、

異常状態にある該対象体から、該複数のパラメータからなるデータを検出するとともに、複数の該データを異常データセットとして複数組検出する異常データセット検出ステップと、

複数組の該異常データセットをニューラルネットワークの教師なし学習により圧縮した異常ニューロンセットを、該異常状態の種類とともに複数組記憶する異常ニューロンセット記憶ステップと、

該対象体の該状態が未確定であるときに、該複数のパラメータからなるデータを検出するとともに、複数の該データを実データセットとして検出する実データセット検出ステップと、

該実データセットと該正常ニューロンセットとに基づいて、該対象体が正常状態にあるか否かを判定する正常状態判定ステップと、

10

20

30

40

50

該実データセットと該異常ニューロンセットとに基づいて、該対象体における該異常状態の種類を診断する診断ステップと
を備えたことを特徴とする、診断方法。

【請求項 20】

該診断ステップが、

該実データセットと該異常ニューロンセットとの距離が小さいほど、該実データセットの該異常ニューロンセットに対する類似度が高いと判定する類似度判定ステップと、

該類似度判定ステップにおいて、該実データセットとの類似度が最も高いと判定された異常ニューロンセットを選択する類似ニューロンセット選択ステップと、

該対象体における該異常状態を、該類似ニューロンセット選択ステップで選択された該異常ニューロンセットに対応する種類の該異常状態であると診断する状態診断ステップと
からなる

10

ことを特徴とする、請求項 19 記載の診断方法。

【請求項 21】

該実データセットをニューラルネットワークの教師なし学習により実ニューロンセットへと圧縮する圧縮ステップを備え、

該診断ステップが、

該実ニューロンセットと該異常ニューロンセットとの距離が小さいほど、該実ニューロンセットの該異常ニューロンセットに対する類似度が高いと判定する類似度判定ステップと、

20

該類似度判定ステップにおいて、該実ニューロンセットとの類似度が最も高いと判定された異常ニューロンセットを選択する類似ニューロンセット選択ステップと、

該対象体における該異常状態を、該類似ニューロンセット選択ステップで選択された該異常ニューロンセットに対応する種類の該異常状態であると診断する状態診断ステップと
からなる

ことを特徴とする、請求項 19 記載の診断方法。

【請求項 22】

該類似度判定ステップにおいて、該実データセットを構成する各データと該異常ニューロンセットを構成する各ニューロンとの間のユークリッド距離の平均値を演算して該類似度を判定する

30

ことを特徴とする、請求項 20 記載の診断方法。

【請求項 23】

該異常ニューロンセット記憶ステップにおいて、該異常ニューロンセットへの圧縮時に各ニューロン毎のウェイトを演算し、

該類似度判定ステップにおいて、該実データセットを構成する各データと該異常ニューロンセットを構成する各ニューロンとの間のユークリッド距離の平均値及び該ウェイトに基づいて該類似度を判定する

ことを特徴とする、請求項 20 記載の診断方法。

【請求項 24】

該類似度判定ステップにおいて、該実データセットを構成する各データと該異常ニューロンセットを構成する各ニューロンとの間の最小ユークリッド距離の平均値を演算して該類似度を判定する

40

ことを特徴とする、請求項 20 記載の診断方法。

【請求項 25】

該異常ニューロンセット記憶ステップにおいて、該異常ニューロンセットへの圧縮時に各ニューロン毎のウェイトを演算し、

該類似度判定ステップにおいて、該実データセットを構成する各データと該異常ニューロンセットを構成する各ニューロンとの間の最小ユークリッド距離の平均値及び該ウェイトに基づいて該類似度を判定する

ことを特徴とする、請求項 20 記載の診断方法。

50

【請求項 26】

該類似度判定ステップにおいて、該実データセットの重心と該異常ニューロンセットの重心とのユークリッド距離を演算して該類似度を判定することを特徴とする、請求項 20 記載の診断方法。

【請求項 27】

該類似度判定ステップにおいて、該実ニューロンセットを構成する各ニューロンと異常ニューロンセットを構成する各ニューロンとの全てのペアのユークリッド距離の平均値を演算して該類似度を判定することを特徴とする、請求項 21 記載の診断方法。

【請求項 28】

該圧縮ステップにおいて、該実ニューロンセットへの圧縮時に各ニューロン毎の第 1 ウェイトを演算し、

該異常ニューロンセット記憶ステップにおいて、該異常ニューロンセットへの圧縮時に各ニューロン毎の第 2 ウェイトを演算し、

該類似度判定ステップにおいて、該実ニューロンセットを構成する各ニューロンと異常ニューロンセットを構成する各ニューロンとの全てのペアのユークリッド距離の平均値、該第 1 ウェイト及び該第 2 ウェイトに基づいて該類似度を判定することを特徴とする、請求項 21 記載の診断方法。

10

【請求項 29】

該類似度判定ステップにおいて、該実ニューロンセットを構成する各ニューロンから該異常ニューロンセットを構成する各ニューロンまでの最小ユークリッド距離の平均値を演算して該類似度を判定する

ことを特徴とする、請求項 21 記載の診断方法。

20

【請求項 30】

該圧縮ステップにおいて、該実ニューロンセットへの圧縮時に各ニューロン毎の第 1 ウェイトを記憶し、

該類似度判定ステップにおいて、該実ニューロンセットを構成する各ニューロンから該異常ニューロンセットを構成する各ニューロンまでの最小ユークリッド距離の平均値及び該第 1 ウェイトに基づいて該類似度を判定する

ことを特徴とする、請求項 21 記載の診断方法。

30

【請求項 31】

該圧縮ステップにおいて、該実ニューロンセットへの圧縮時に各ニューロン毎の第 1 ウェイトを演算し、

該異常データセット記憶ステップにおいて、該異常ニューロンセットへの圧縮時に各ニューロン毎の第 2 ウェイトを演算し、

該類似度判定ステップにおいて、該実ニューロンセットを構成する各ニューロンから該異常ニューロンセットを構成する各ニューロンまでの最小ユークリッド距離の平均値、該第 1 ウェイト及び該第 2 ウェイトに基づいて該類似度を判定する

ことを特徴とする、請求項 21 記載の診断方法。

40

【請求項 32】

該類似度判定ステップにおいて、該実ニューロンセットの重心と該異常ニューロンセットの重心とのユークリッド距離を演算して該類似度を判定する

ことを特徴とする、請求項 21 記載の診断方法。

【請求項 33】

該類似度判定ステップにおいて、複数の異なる演算方法を設定することにより、該類似度の判定を複数回繰り返す、

該類似ニューロンセット選択ステップにおいて、該実ニューロンセットとの類似度が最も高いと判定された異常ニューロンセットを複数回繰り返して選択し、

該状態診断ステップにおいて、該対象体における該異常状態を、該類似ニューロンセット選択ステップでの選択回数の最も多い該異常ニューロンセットに対応する種類の該異常

50

状態であると診断する

ことを特徴とする、請求項 20 又は 21 記載の診断方法。

【請求項 34】

該異常ニューロンセット記憶ステップにおいて、該実データセットを用いて該異常ニューロンセットを更新又は変更する

ことを特徴とする、請求項 19 ~ 33 の何れか 1 項に記載の診断方法。

【請求項 35】

該実データセットに対応する該対象体の該状態が未知の異常状態にあるか否かを判定する未知異常状態判定ステップを有し、

該異常ニューロンセット記憶ステップにおいて、該未知異常状態判定ステップで判定された該未知の異常状態に対応する該実データセットをニューラルネットワークの教師なし学習により圧縮した未知異常ニューロンセットを、該未知の異常状態の種類とともに新たに記憶する

ことを特徴とする、請求項 34 記載の診断方法。

【請求項 36】

該未知異常状態判定ステップにおいて、該実データセットと該異常ニューロンセットとのユークリッド距離に基づいて、該対象体が未知の異常状態にあるか否かを判定する

ことを特徴とする、請求項 35 記載の診断方法。

【発明の詳細な説明】

【技術分野】

【0001】

本発明は、ニューラルネットワークの教師なし学習の手法を用いて、各種機械をはじめとする、動植物、微生物等の生命体、天候や天体の運動等の自然現象など種々の対象体の状態を診断するための診断装置及び診断方法に関し、特に、油圧ショベル等の作業機械に生じる異常状態を診断するのに用いて好適な診断装置及び診断方法に関する。

【背景技術】

【0002】

従来、機械類のメンテナンスでは、機械類に故障が発生してから修復する事後保全や、機械類の使用時間を基準にした画一的な予防保全が一般に行われている。事後保全では、修理に大幅な時間やコストがかかってしまい、また、予防保全では、画一的な処理のため、不必要な部品やオイルの廃棄が発生し顧客の費用負担が増大し、また、労働集約型からくる高コスト化という問題があったが、今後はこうした従来からのメンテナンスから脱却して、予知保全への転換を図っていく必要がある。

【0003】

予知保全とは、稼働時の負荷・環境情報、過去のメンテナンス履歴データベース、故障物理の理解などから、推論により健全度を診断して劣化・余寿命を予測することで、機械の異常を早期に発見して安全な動作環境を提供するものである。

例えば、特許文献 1 には、バッチプラントや連続系プラント等の固定機械設備の異常検出装置に関し、自己組織化モデルを用いて対象プラントの異常を検出する技術が開示されている。すなわち、対象プラントが正常状態であるときの正常データを予め収集しておき、この正常データをもとに自己組織化マップ (Self-Organizing Map) を用いて正常データの特徴を抽出するとともに、これをもとに自己組織化マップの出力層における各出力ユニット間の距離関係を表す特徴マップを形成して正常状態モデルとして記憶しておき、この正常状態モデルと未知の入力データ (入力ベクトル) とに基づいて対象プラントの異常を検出するものである。

【0004】

自己組織化マップとは、複雑な多次元変数の持つ特徴を保持させたままその変数の次元を削減することを目的として適用される自己組織化モデルの一つである。例えば、特許文献 1 に記載の技術では、正常状態モデルが、多次元データである正常データを可視化して 2 次元マップに変換したものである。そして、未知

10

20

30

40

50

の入力データと正常状態モデルとを対比して同等の特徴を有するとみなされる場合に、入力データが正常データであると判断する。このような構成により、多次元の入力データに関する総合的な異常検知をリアルタイムに実現することができる。

【0005】

しかし、この技術では、入力データが正常データであるか否かの判定にかかる正常状態モデルが一つしかないため、例えば、機械の運転モードが多数存在するような場合には適用が難しい。すなわち、一つの2次元自己組織化マップ内にこれらの運転モード数と略同数のクラスタが形成されることになるため、各クラスタの面積が小さくなっていき隣接するクラスタとのオーバーラップが強くなり境界が不明確になってしまう。

【0006】

このように、特許文献1に記載の技術は、正常状態モデルの特徴が複数存在する機械に対して、正確な診断を行うことができない。また、どの計測データ、即ちどのパラメータにどの程度の劣化や異常の兆候が生じているのかを予測することまでは困難である。

上記のような課題に対し、特許文献2には、複数の運転動作(運転モード)で動作する機械等の対象体の各動作を判定する技術であって、それぞれの運転モード毎に、個別の分離モデルとしての自己組織化マップを形成したものが開示されている。

【0007】

例えば、油圧ショベル等の作業機械の場合、「バケットで土砂をすくい始めてからすくい終わるまでの動作(運転モード1)」、「土砂をすくった後、車体を旋回させて、土砂を保持したバケットをトラックのベッセルの上方まで運ぶ動作(運転モード2)」、「バケットを開いて土砂のベッセル上への移載を開始してから土砂の移載が完了するまでの動作(運転モード3)」、「バケットを堆積した土砂の位置まで戻して運転モード1に入るまでの動作(運転モード4)」といった4つの運転モードを想定しておく。一方、作業機械から検出されるエンジンの回転数、油圧ポンプの吐出圧、油圧回路内の油温、車体の前進・後進・旋回を制御する作動圧、バケットを制御するバケットシリンダの作動圧、スティックを制御するスティックシリンダの作動圧、ブームを制御するブームシリンダの作動圧等のパラメータのうち、同時刻に検出されたものをまとめて一つの多次元パラメータとして扱い、各運転モードに対応する多次元パラメータの自己組織化マップを個別に形成しておく。このような構成により、作業機械の各動作モードを正確に認識することができ、あるいは、各モードの何れにも当てはまらない場合には、未知モード、異常モードであることを確認することができる。

【特許文献1】特開平11-338848号公報

【特許文献2】特開2005-25351号公報

【発明の開示】

【発明が解決しようとする課題】

【0008】

しかしながら、特許文献2に記載の技術では、「正常ではない」ことを以て未知又は異常であると判定しているに過ぎず、その異常がいかなる内容の異常であるかを診断することはできない。例えば、作業機械の動作モードの判定結果が運転モード1~4の何れにも当てはまらない場合、少なくとも「正常ではない」ことは把握できても、具体的にどのような措置を取るべきかを判断することができず、その結果、従来のメンテナンスと同様に画一的な予防保全措置を取らざるを得ない。

【0009】

このように、従来の技術によれば、劣化や異常を予測することはできても、劣化や異常の種類までは予測することができず、予知保全の観点からより正確な状態判定が望まれている。

本発明は、このような課題に鑑みてなされたもので、対象体の状態をより正確に診断できるようにした、診断装置及び診断方法を提供することを目的とする。

【課題を解決するための手段】

【0010】

10

20

30

40

50

上記目的を達成するため、請求項1記載の本発明の診断装置は、対象体の状態を診断するための診断装置であって、該対象体の該状態に応じて変動する複数のパラメータからなるデータを検出する検出手段と、正常状態にある該対象体から該検出手段によって検出された複数の該データをデータセットとして、ニューラルネットワークの教師なし学習により圧縮した正常ニューロンセットを記憶する正常ニューロンセット記憶手段と、異常状態にある該対象体から該検出手段によって検出された複数の該データをデータセットとして、ニューラルネットワークの教師なし学習により圧縮した異常ニューロンセットを、該異常状態の種類とともに複数組記憶する異常ニューロンセット記憶手段と、該対象体の該状態が未確定であるときに該検出手段によって検出される複数の該データを実データセットとして、該実データセットと該正常ニューロンセット記憶手段に記憶された該正常ニューロンセットとに基づいて、該対象体が正常状態にあるか否かを判定するとともに、該実データセットと該異常ニューロンセット記憶手段に記憶された該異常ニューロンセットとに基づいて、該対象体における該異常状態の種類を診断する診断手段とを備えたことを特徴としている。

10

【0011】

請求項2記載の本発明の診断装置は、請求項1記載の診断装置において、該診断手段が、該実データセットと該異常ニューロンセットとのユークリッド距離が小さいほど、該実データセットの該異常ニューロンセットに対する類似度が高いと判定する類似度判定手段と、該類似度判定手段により該実データセットとの類似度が最も高いと判定された異常ニューロンセットを選択する類似ニューロンセット選択手段と、該対象体における該異常状態を、該類似ニューロンセット選択手段で選択された該異常ニューロンセットに対応する種類の該異常状態であると診断する状態診断手段とを有することを特徴としている。

20

【0012】

また、請求項3記載の本発明の診断装置は、請求項1記載の診断装置において、該対象体の該状態が未確定であるときに該検出手段で検出される複数の該データを実データセットとして、ニューラルネットワークの教師なし学習により実ニューロンセットへと圧縮する圧縮手段を備え、該診断手段が、該圧縮手段で圧縮された実ニューロンセットと該異常ニューロンセットとのユークリッド距離が小さいほど、該実ニューロンセットの該異常ニューロンセットに対する類似度が高いと判定する類似度判定手段と、該類似度判定手段により類似度が最も高いと判定された異常ニューロンセットを選択する類似ニューロンセット選択手段と、該対象体における該異常状態を、該類似ニューロンセット選択手段で選択された該異常ニューロンセットに対応する種類の該異常状態であると診断する状態診断手段とを有することを特徴としている。

30

【0013】

また、請求項2記載の診断装置において、該類似度判定手段が、該実データセットを構成する各データと該異常ニューロンセットを構成する各ニューロンとの間のユークリッド距離の平均値を演算して該類似度を判定することが好ましい(請求項4)。

また、請求項2記載の診断装置において、該異常ニューロンセット記憶手段が、該異常ニューロンセットへの圧縮時に各ニューロン毎のウェイトを演算するとともに、該類似度判定手段が、該実データセットを構成する各データと該異常ニューロンセットを構成する各ニューロンとの間のユークリッド距離の平均値及び該ウェイトに基づいて該類似度を判定することが好ましい(請求項5)。

40

【0014】

また、請求項2記載の診断装置において、該類似度判定手段が、該実データセットを構成する各データと該異常ニューロンセットを構成する各ニューロンとの間の最小ユークリッド距離の平均値を演算して該類似度を判定することが好ましい(請求項6)。

また、請求項2記載の診断装置において、該異常ニューロンセット記憶手段が、該異常ニューロンセットへの圧縮時に各ニューロン毎のウェイトを演算するとともに、該類似度判定手段が、該実データセットを構成する各データと該異常ニューロンセットを構成する各ニューロンとの間の最小ユークリッド距離の平均値及び該ウェイトに基づいて該類似度

50

を判定することが好ましい（請求項7）。

【0015】

また、請求項2記載の診断装置において、該類似度判定手段が、該実データセットの重心と該異常ニューロンセットの重心とのユークリッド距離を演算して該類似度を判定することが好ましい（請求項8）。

また、請求項3記載の診断装置において、該類似度判定手段が、該実ニューロンセットを構成する各ニューロンと異常ニューロンセットを構成する各ニューロンとの全てのペアのユークリッド距離の平均値を演算して該類似度を判定することが好ましい（請求項9）。

【0016】

また、請求項3記載の診断装置において、該圧縮手段が、該実ニューロンセットへの圧縮時に各ニューロン毎の第1ウェイトを演算し、該異常ニューロンセット記憶手段が、該異常ニューロンセットへの圧縮時に各ニューロン毎の第2ウェイトを演算するとともに、該類似度判定手段が、該実ニューロンセットを構成する各ニューロンと異常ニューロンセットを構成する各ニューロンとの全てのペアのユークリッド距離の平均値、該第1ウェイト及び該第2ウェイトに基づいて該類似度を判定することが好ましい（請求項10）。

10

【0017】

また、請求項3記載の診断装置において、該類似度判定手段が、該実ニューロンセットを構成する各ニューロンから該異常ニューロンセットを構成する各ニューロンまでの最小ユークリッド距離の平均値を演算して該類似度を判定することが好ましい（請求項11）

20

また、請求項3記載の診断装置において、該圧縮手段が、該実ニューロンセットへの圧縮時に各ニューロン毎の第1ウェイトを演算するとともに、該類似度判定手段が、該実ニューロンセットを構成する各ニューロンから該異常ニューロンセットを構成する各ニューロンまでの最小ユークリッド距離の平均値及び該第1ウェイトに基づいて該類似度を判定することが好ましい（請求項12）。

【0018】

また、請求項3記載の診断装置において、該圧縮手段が、該実ニューロンセットへの圧縮時に各ニューロン毎の第1ウェイトを演算し、該異常ニューロンセット記憶手段が、該異常ニューロンセットへの圧縮時に各ニューロン毎の第2ウェイトとを演算するとともに、該類似度判定手段が、該実ニューロンセットを構成する各ニューロンから該異常ニューロンセットを構成する各ニューロンまでの最小ユークリッド距離の平均値、該第1ウェイト及び該第2ウェイトに基づいて該類似度を判定することが好ましい（請求項13）。

30

【0019】

また、請求項3記載の診断装置において、該類似度判定手段が、該実ニューロンセットの重心と該異常ニューロンセットの重心とのユークリッド距離を演算して該類似度を判定することが好ましい（請求項14）。

請求項15記載の本発明の診断装置は、請求項2又は3記載の診断装置において、該診断手段が、該類似度判定手段における該類似度の判定に際し、複数の異なる演算方法を設定する類似度演算方法設定手段を有し、該類似ニューロンセット選択手段が、該類似度演算方法設定手段で設定された該複数の異なる演算方法毎に、最も類似度の高い異常ニューロンセットを選択するとともに、該状態診断手段が、該対象体における該異常状態を、該類似ニューロンセット選択手段における選択回数最も多い該異常ニューロンセットに対応する種類の該異常状態であると診断することを特徴としている。

40

【0020】

また、請求項1～15の何れか1項に記載の診断装置において、該異常ニューロンセット記憶手段が、該実データセットを用いて該異常ニューロンセットを更新又は変更することが好ましい（請求項16）。

この場合、該実データセットに対応する該対象体の該状態が未知の異常状態にあるか否かを判定する未知異常状態判定手段を備え、該異常ニューロンセット記憶手段が、該未知

50

異常状態判定手段において判定された該未知の異常状態に対応する該実データセットをニューラルネットワークの教師なし学習により圧縮した未知異常ニューロンセットを、該未知の異常状態の種類とともに新たに記憶することが好ましい（請求項17）。

【0021】

さらにこの場合、該未知異常状態判定手段が、該実データセットと該異常ニューロンセットとのユークリッド距離に基づいて、該対象体が未知の異常状態にあるか否かを判定することが好ましい（請求項18）。

請求項19記載の本発明の診断方法は、対象体の状態を診断するための診断方法であって、正常状態にある該対象体から、該対象体の該状態に応じて変動する複数のパラメータからなるデータを検出するとともに、複数の該データを正常データセットとして検出する正常データセット検出ステップと、該正常データセットをニューラルネットワークの教師なし学習により圧縮した正常ニューロンセットを記憶する正常ニューロンセット記憶ステップと、異常状態にある該対象体から、該複数のパラメータからなるデータを検出するとともに、複数の該データを異常データセットとして複数組検出する異常データセット検出ステップと、複数組の該異常データセットをニューラルネットワークの教師なし学習により圧縮した異常ニューロンセットを、該異常状態の種類とともに複数組記憶する異常ニューロンセット記憶ステップと、該対象体の該状態が未確定であるときに、該複数のパラメータからなるデータを検出するとともに、複数の該データを実データセットとして検出する実データセット検出ステップと、該実データセットと該正常ニューロンセットとに基づいて、該対象体が正常状態にあるか否かを判定する正常状態判定ステップと、該実データセットと該異常ニューロンセットとに基づいて、該対象体における該異常状態の種類を診断する診断ステップとを備えたことを特徴としている。

10

20

【0022】

請求項20記載の本発明の診断方法は、請求項19記載の診断方法において、該診断ステップが、該実データセットと該異常ニューロンセットとの距離が小さいほど、該実データセットの該異常ニューロンセットに対する類似度が高いと判定する類似度判定ステップと、該類似度判定ステップにおいて、該実データセットとの類似度が最も高いと判定された異常ニューロンセットを選択する類似ニューロンセット選択ステップと、該対象体における該異常状態を、該類似ニューロンセット選択ステップで選択された該異常ニューロンセットに対応する種類の該異常状態であると診断する状態診断ステップとからなることを特徴としている。

30

【0023】

請求項21記載の本発明の診断方法は、請求項19記載の診断方法において、該実データセットをニューラルネットワークの教師なし学習により実ニューロンセットへと圧縮する圧縮ステップを備え、該診断ステップが、該実ニューロンセットと該異常ニューロンセットとの距離が小さいほど、該実ニューロンセットの該異常ニューロンセットに対する類似度が高いと判定する類似度判定ステップと、該類似度判定ステップにおいて、該実ニューロンセットとの類似度が最も高いと判定された異常ニューロンセットを選択する類似ニューロンセット選択ステップと、該対象体における該異常状態を、該類似ニューロンセット選択ステップで選択された該異常ニューロンセットに対応する種類の該異常状態であると診断する状態診断ステップとからなることを特徴としている。

40

【0024】

また、請求項20記載の診断方法における、該類似度判定ステップにおいて、該実データセットを構成する各データと該異常ニューロンセットを構成する各ニューロンとの間のユークリッド距離の平均値を演算して該類似度を判定することが好ましい（請求項22）。

また、請求項20記載の診断方法における、該異常ニューロンセット記憶ステップにおいて、該異常ニューロンセットへの圧縮時に各ニューロン毎のウェイトを演算し、該類似度判定ステップにおいて、該実データセットを構成する各データと該異常ニューロンセットを構成する各ニューロンとの間のユークリッド距離の平均値及び該ウェイトに基づいて

50

該類似度を判定することが好ましい（請求項 23）。

【0025】

また、請求項 20 記載の診断方法における、該類似度判定ステップにおいて、該実データセットを構成する各データと該異常ニューロンセットを構成する各ニューロンとの間の最小ユークリッド距離の平均値を演算して該類似度を判定することが好ましい（請求項 24）。

また、請求項 20 記載の診断方法における、該異常ニューロンセット記憶ステップにおいて、該異常ニューロンセットへの圧縮時に各ニューロン毎のウェイトを演算し、該類似度判定ステップにおいて、該実データセットを構成する各データと該異常ニューロンセットを構成する各ニューロンとの間の最小ユークリッド距離の平均値及び該ウェイトに基づいて該類似度を判定することが好ましい（請求項 25）。

10

【0026】

また、請求項 20 記載の診断方法における、該類似度判定ステップにおいて、該実データセットの重心と該異常ニューロンセットの重心とのユークリッド距離を演算して該類似度を判定することが好ましい（請求項 26）。

また、請求項 21 記載の診断方法における、該類似度判定ステップにおいて、該実ニューロンセットを構成する各ニューロンと異常ニューロンセットを構成する各ニューロンとの全てのペアのユークリッド距離の平均値を演算して該類似度を判定することが好ましい（請求項 27）。

【0027】

20

また、請求項 21 記載の診断方法における、該圧縮ステップにおいて、該実ニューロンセットへの圧縮時に各ニューロン毎の第 1 ウェイトを演算し、該異常ニューロンセット記憶ステップにおいて、該異常ニューロンセットへの圧縮時に各ニューロン毎の第 2 ウェイトを演算し、該類似度判定ステップにおいて、該実ニューロンセットを構成する各ニューロンと異常ニューロンセットを構成する各ニューロンとの全てのペアのユークリッド距離の平均値、該第 1 ウェイト及び該第 2 ウェイトに基づいて該類似度を判定することが好ましい（請求項 28）。

【0028】

また、請求項 21 記載の診断方法における、該類似度判定ステップにおいて、該実ニューロンセットを構成する各ニューロンから該異常ニューロンセットを構成する各ニューロンまでの最小ユークリッド距離の平均値を演算して該類似度を判定することが好ましい（請求項 29）。

30

また、請求項 21 記載の診断方法における、該圧縮ステップにおいて、該実ニューロンセットへの圧縮時に各ニューロン毎の第 1 ウェイトを記憶し、該類似度判定ステップにおいて、該実ニューロンセットを構成する各ニューロンから該異常ニューロンセットを構成する各ニューロンまでの最小ユークリッド距離の平均値及び該第 1 ウェイトに基づいて該類似度を判定することが好ましい（請求項 30）。

【0029】

また、請求項 21 記載の診断方法における、該圧縮ステップにおいて、該実ニューロンセットへの圧縮時に各ニューロン毎の第 1 ウェイトを演算し、該異常データセット記憶ステップにおいて、該異常ニューロンセットへの圧縮時に各ニューロン毎の第 2 ウェイトを演算し、該類似度判定ステップにおいて、該実ニューロンセットを構成する各ニューロンから該異常ニューロンセットを構成する各ニューロンまでの最小ユークリッド距離の平均値、該第 1 ウェイト及び該第 2 ウェイトに基づいて該類似度を判定することが好ましい（請求項 31）。

40

【0030】

また、請求項 21 記載の診断方法における、該類似度判定ステップにおいて、該実ニューロンセットの重心と該異常ニューロンセットの重心とのユークリッド距離を演算して該類似度を判定することが好ましい（請求項 32）。

請求項 33 記載の本発明の診断方法は、請求項 20 又は 21 記載の診断方法における、

50

該類似度判定ステップにおいて、複数の異なる演算方法を設定することにより、該類似度の判定を複数回繰り返し、該類似ニューロンセット選択ステップにおいて、該実ニューロンセットとの類似度が最も高いと判定された異常ニューロンセットを複数回繰り返して選択し、該状態診断ステップにおいて、該対象体における該異常状態を、該類似ニューロンセット選択ステップでの選択回数の最も多い該異常ニューロンセットに対応する種類の該異常状態であると診断することを特徴としている。

【0031】

また、請求項19～33の何れか1項に記載の診断方法における、該異常ニューロンセット記憶ステップにおいて、該実データセットを用いて該異常ニューロンセットを更新又は変更することが好ましい（請求項34）。

10

この場合、該実データセットに対応する該対象体の該状態が未知の異常状態にあるか否かを判定する未知異常状態判定ステップを備え、該異常ニューロンセット記憶ステップにおいて、該未知異常状態判定ステップで判定された該未知の異常状態に対応する該実データセットをニューラルネットワークの教師なし学習により圧縮した未知異常ニューロンセットを、該未知の異常状態の種類とともに新たに記憶することが好ましい（請求項35）。

【0032】

さらにこの場合、該未知異常状態判定ステップにおいて、該実データセットと該異常ニューロンセットとのユークリッド距離に基づいて、該対象体が未知の異常状態にあるか否かを判定することが好ましい（請求項36）。

20

【発明の効果】

【0033】

本発明の診断装置及び診断方法（請求項1，19）によれば、対象体が正常状態であるか否かを判定することができ、また、対象体が正常状態でない場合には、単に異常状態であることだけでなく、異常状態の種類を判定することができる。これにより、対象体の状態をより明確に予測することができ、予知保全が容易となる。

また、対象体の状態に応じて変動する複数のパラメータ全体を一つのデータとして扱っているため、例えば各パラメータを個別に判定するような手法と比較して総括的な判定が可能となる。

【0034】

30

また、本発明の診断装置及び診断方法（請求項2，20）によれば、実データセットとニューロンセットとの距離から導かれる類似度に基づく判定により、対象体の状態を正確に診断することができる。また、検出手段で検出されたデータ群であるデータセットそのものの類似度が演算されるようになっていたため、データの取得後直ちに（すなわちセミリアルタイムに）診断を行うことができる。これにより、例えば対象体の異常状態の早期発見が容易である。

【0035】

また、本発明の診断装置及び診断方法（請求項3，21）によれば、ニューロンセット同士（すなわち、正常ニューロンセット，異常ニューロンセット及び実ニューロンセット）の距離から導かれる類似度に基づく判定により、対象体の稼働状態を正確に診断することができる。また、圧縮手段で圧縮された実ニューロンセットの類似度が演算されるようになっていたため、類似度の演算量（診断負荷）を減少させることができ、診断速度を高めることが可能となる。

40

【0036】

また、本発明の診断装置及び診断方法（請求項15，33）によれば、複数の演算方法に基づく合議判定により、判定結果の信頼性を高めることができる。

また、本発明の診断装置及び診断方法（請求項16，34）によれば、現在の知識ベースにはない新たな異常状態が生じた場合に、その異常状態を表すニューロンからなるモジュールを付け加えたり、古いモジュールを新しいものに置き換えたりすることが可能であり、診断精度をより向上させることができる。

50

【 0 0 3 7 】

また、本発明の診断装置及び診断方法（請求項 17，35）によれば、未確定な状態に対応する任意の実データセットを、未知の異常状態に対応する実データセットとして用いることにより、その実データセットに基づく新たな異常ニューロンセットを作成することができる。つまり、検出手段で検出された実際の未知の状態に対応するモジュールを知識ベースに追加することができる。

【 0 0 3 8 】

また、本発明の診断装置及び診断方法（請求項 18，36）によれば、ユークリッド距離に基づく判定により、任意の実データセットが未知の異常状態であるか否かを正確に判別することができる。

10

【 発明を実施するための最良の形態 】

【 0 0 3 9 】

以下、図面により、本発明の実施の形態について説明する。

図 1 ~ 図 11 は本発明の一実施形態にかかる診断装置を説明するものであり、図 1 は本診断装置の全体構成を示す模式的構成図、図 2 は本診断装置での演算に係るユークリッド距離の概念を説明するための模式図、図 3 (a) ~ (d) は本診断装置での判定に係る類似度の概念を説明するための模式図、図 4 は平均距離 ADP_0 の演算内容を説明するための模式図、図 5 は平均最小距離 AMD_0 の演算内容を説明するための模式図、図 6 は平均距離 ADP の演算内容を説明するための模式図、図 7 は平均最小距離 AMD の演算内容を説明するための模式図、図 8 は加重平均最小距離 $WAMD_2$ の演算内容を説明するための模式図、図 9 は本診断装置におけるニューロンセットのモジュール作成制御内容を示すフローチャート、図 10 は本診断装置の第 1 診断装置における診断制御内容を示すフローチャート、図 11 は本診断装置の第 2 診断装置における診断制御内容を示すフローチャートである。

20

【 0 0 4 0 】

[構成]

[1] 全体構成

図 1 に示すように、本診断装置は、油圧ショベルの状態を診断の対象としたものであり、油圧ショベル上で診断を行うための第 1 診断装置 10 と、油圧ショベルから離れた場所にあるサービスセンターで診断を行うための第 2 診断装置 20 とを備えて構成される。

【 0 0 4 1 】

第 1 診断装置 10 は、油圧ショベルの内部に搭載された装置であり、データ検出装置（検出手段）1，ECU（電子制御装置）2 及び表示装置 3 を備えて構成される。ECU 2 とは、処理プログラムを内蔵した記憶装置（ROM，RAM 等）や中央処理装置（CPU）を備えたコンピュータであり、内部に機能部位として、記憶部 4，診断部（診断手段）5，圧縮部（圧縮手段）6 及び通信部 7 を備えている。

30

【 0 0 4 2 】

一方、第 2 診断装置 20 は、油圧ショベルの外部に設けられた装置であり、ECU 12 及び表示装置 13 を備えている。ECU 12 は、第 1 診断装置 10 の ECU 2 と同様のコンピュータであり、内部に機能部位として、記憶部 14，診断部（診断手段）15 及び通信部 17 を備えている。なお、この第 2 診断装置 20 は、第 1 診断装置 10 が設けられた油圧ショベルを所有、あるいは管理する事業所のサービスセンター内に設けられている。

40

【 0 0 4 3 】

データ検出装置 1 には、油圧ショベルに関する各パラメータ（変動要素）に対応する各種のセンサが設けられている。これらのセンサは、油圧ショベルの動作に応じて変動する各パラメータ値を各動作モード毎に検出するようになっている。

なお、ここで検出されるパラメータとは、センサから直接検出されるデータのほか、ある検出データを演算等によって処理して、対応するパラメータの値を推定値として求めたものを含む。例えば、エンジン回転数，燃料消費量，油圧ポンプ圧力（1つ又は複数の油圧ポンプ圧力），油圧回路内の油温，車体の前進・後進或いは旋回を制御する作動圧，バケットを制御するバケットシリンダの作動圧，スティックを制御するスティックシリンダ

50

の作動圧，ブームを制御するブームシリンダの作動圧などが挙げられる。

【0044】

本診断装置では、これらの同時に検出された各パラメータ（同一の状態下において検出された各パラメータのことを意味し、ここでは同時刻に検出された各パラメータのことをいう）が、ひとつのデータ（データ点） x としてECU2へ入力されるようになっている。

【0045】

[2] 記憶部4

続いて、ECU2の内部構成について説明する。まず記憶部4は、診断の基準となる情報を記憶しており、正常ニューロンセット記憶部（正常ニューロンセット記憶手段）4aと異常ニューロンセット記憶部（異常ニューロンセット記憶手段）4bとを備えて構成される。

10

【0046】

正常ニューロンセット記憶部4aは、油圧ショベルが正常状態にあるときに検出されるデータ群（複数のデータ，データセット）の特徴を記憶する知識ベース（Module Knowledge-Base）である。ここでは、まず正常状態における複数のデータによって構成されるデータセットが作成されるとともに、ニューラルネットワークの教師なし学習によりこのデータセットを圧縮したニューロンセットが、正常ニューロンセットとして記憶されている。なお、知識ベースとは、単なる情報を集積したデータベース（Database）に対して、特定の問題を解決するのに必要な知識（Knowledge）を体系的に集約したものを意味する。

20

【0047】

一方、異常ニューロンセット記憶部4bは、油圧ショベルが異常状態（何らかの部品劣化や装置故障が生じかけている非正常の状態）であるときに検出されるデータ群の特徴を記憶する知識ベースである。ここでは、異常状態として、エンジンの故障や燃料ポンプの劣化，油圧ポンプの故障等といった複数種類の異常状態が想定されており、各異常状態下で検出される複数のデータによって構成されるデータセットが複数組作成されるとともに、ニューラルネットワークの教師なし学習により各データセットを圧縮したニューロンセットが、異常ニューロンセットとして、異常状態の種類とともに複数組記憶されている。

【0048】

[3] 記憶部4に記憶されているニューロンセット

ここで、正常ニューロンセット記憶部4a及び異常ニューロンセット記憶部4bに記憶されているニューロンセットについて詳述する。

30

本実施形態では、油圧ショベルの正常状態の特徴を示すニューロンセット（正常ニューロンセット）と異常状態の特徴を示すニューロンセット（異常ニューロンセット）とを複数個用意して、油圧ショベルの実稼働時に得られる実データセットが何れのニューロンセットに近似しているかを判定することによって、油圧ショベルの状態を診断する。記憶部4に記憶されている各ニューロンセットは、この判定のための基準となる知識であり、油圧ショベルの実稼働前に予め設定されている。

【0049】

まず、正常状態の稼働データセット及び異常状態の稼働データセットを合計Lセット用意するものとする。例えば、正常稼働データセットを1セット，異常稼働データセットを第1異常状態から第4異常状態までの4セット用意する場合、 $L = 5$ である。また、各稼働データセットの通し番号を f と表記して、対応する油圧ショベルの状態を便宜的に表すものとする。例えば、 $f = 1$ が正常状態を示し、 $f = 2 \sim 5$ が第1異常状態～第4異常状態を表すものとする。

40

【0050】

次に、各稼働データセットにおいて、データ検出装置1で検出されるデータを予めM個ずつ取得しておく。この数は、例えば数百～数千個程度であり、これらのデータが油圧ショベルの所定の状態の典型的な動的特性を代表しているものとする。以下、汎用表記のため、各稼働データセットで取得されるデータ数のことを、 M_f ($f = 1, 2, \dots, L$)

50

と表現する。例えば、正常状態の動的特性は、 M_1 個のデータによって代表されるところとし、また、第1異常状態～第4異常状態の各動的特性は、 $M_2 \sim M_5$ 個のデータによって代表されるものとする。

【0051】

また、各データは、同時に検出された、エンジン回転数や燃費、油圧ポンプ圧力等のK種類のパラメータを一組としたデータとする。したがって、各稼働データセットを構成するデータ x_s^f は、以下のようなK次元のベクトルの形で表すことができる。

【0052】

【数1】

$$x_s^f = [x_{s1}^f, x_{s2}^f, x_{s3}^f, \dots, x_{sK}^f], \quad s = 1, 2, 3, \dots, M_f \quad \dots \text{(式1)}$$

10

【0053】

つまり、一つの稼働データセットは、K種類 $\times M_f$ 個の値によってその状態 f が特徴づけられるものとする。

また、このような稼働セットをLセット用意する。例えば、正常状態の稼働データセットのデータ x_s^1 としては、油圧シヨベルが正常な状態での検出データを用意し、また、第1異常状態～第4異常状態に対応するデータ $x_s^2 \sim x_s^5$ には、模擬的に油圧シヨベルを故障状態にしたときに得られた検出データや、実際に検出されたデータを意図的に改変した試験データ等を用意する。

【0054】

そして、各稼働データセット毎に、 M_f 個のデータ x_s^f を N 個 ($N < M$) のニューロンへと圧縮する。具体的には、 N 個のニューロンをK次元の空間にランダムに配置し、 M_f 個のデータ x_s^f を用いて、ニューラルネットワークの教師なし学習により、各稼働データセットの特徴をニューロンに学習させる。以下、汎用表記のため、各稼働データセットで圧縮されたニューロン数のことを、 N_f ($f = 1, 2, \dots, L$) と表現する。

20

【0055】

学習を終えた N_f 個のニューロンからなるニューロンセットは、油圧シヨベルの状態 f に対応する圧縮データモデルであり、各ニューロンセットを Q_f と記すこととする。例えば、状態 $f = 1$ に対応するニューロンセット(すなわち、正常ニューロンセット)を Q_1 と表し、状態 $f = 2 \sim 5$ に対応するニューロンセット(すなわち、異常ニューロンセット)をそれぞれ、 $Q_2 \sim Q_5$ と表す。また以下、特記なき限り、これらの正常、異常ニューロンセット $Q_1 \sim Q_5$ のうちの何れが任意のニューロンセットのことを、単に記号 Q で表す。このニューロンセット Q を構成する各ニューロン w_q^f は、以下のようなK次元のベクトルの形で表すことができる。

30

【0056】

【数2】

$$w_q^f = [w_{q1}^f, w_{q2}^f, w_{q3}^f, \dots, w_{qK}^f], \quad q = 1, 2, 3, \dots, N_f, q \in Q \quad \dots \text{(式2)}$$

【0057】

なお、上記の式2に示すように、各ニューロン w_q^f のベクトルは、K次元空間内における座標を表すものとみなすことができる。

40

また、各ニューロン w_q^f が、学習の過程において、 M_f 個のデータ x_s^f のうちのいくつかのデータ x_s^f に対する勝者になっているか(すなわち、 M_f 個のデータ x_s^f に対して勝者ニューロン(Winning-neuron)となった割合)を示すウェイト(第2ウェイト) g_q^f を以下の式3に基づいて算出しておく。

【0058】

【数 3】

$$g_q^f = \frac{m_q^f}{M_f} \in [0,1], \quad q=1,2,3,\dots,N_f \quad \dots (式 3)$$

$$\text{ただし、} M_f = \sum_{q=1}^{N_f} m_q^f \quad \dots (式 4)$$

m_q^f , $q=1,2,3,\dots,N_f$ はニューロンセット Q の q 番目のニューロンが勝者となっているデータ数を示す。

10

【0059】

各ニューロンセット Q は、油圧ショベルの正常状態、あるいはある異常状態の特徴を示す最も代表的な情報を持っており、記憶部 4 内部において個別のモジュール（圧縮データモデル）として記憶されている。また、 $f=1$ に対応するニューロンセット Q の各ニューロン w_q^1 及びウェイト g_q^1 は、正常ニューロンセット記憶部 4 a に記憶されており、一方、 $f=2 \sim 5$ に対応するニューロンセット Q の各ニューロン $w_q^2 \sim w_q^5$ 及びウェイト $g_q^2 \sim g_q^5$ は、異常ニューロンセット記憶部 4 b に記憶されている。

【0060】

各ニューロンセット Q における K 次元空間内のニューロン分布は、その形や大きさ、密度が異なり、それぞれのニューロンセット Q が各状態 f に対する動的挙動について最も適切な情報を有している。このようなニューロンセット Q の状態判定基準としての特性から、各ニューロンセット Q のことを単に「モジュール (Module)」とも呼ぶ。つまり、知識ベースとしての記憶部 4 は、想定される油圧ショベルの稼働状態 f に応じた合計 L 個のモジュールを備えている。なお、ニューロンの数 N_f の最適値は、記憶部 4 の記憶容量がコンパクトとなり、かつ、状態判定に支障のない程度の数に、実験や試験を通して経験的に設定されるものとする。

20

【0061】

このようなニューロンセット Q の学習は、油圧ショベルで実際の作業を行う前に、あるいは実際の作業とは切り分けて（本実施形態では、これを油圧ショベルの「予備運転時」ともいう）予め行っておくことが好ましい。したがって、例えば、油圧ショベルが製品として出荷される前に、出荷後行われるであろう一連の動作に沿って油圧ショベルを試験的に正常運転状態（異常が全くない状態）で動作させ、その結果得られた稼働データセットを用いて学習をさせておけばよい。あるいは、出荷前の油圧ショベルを意図的に異常運転状態で動作させて、その結果得られた稼働データセットを用いて学習をさせておけばよい。

30

【0062】

[4] 診断部 5

診断部 5 は、上記の通り予め記憶部 4 に記憶された知識と油圧ショベルの実稼働時にデータ検出装置 1 から得られるデータとを対比して類似度を計算し、油圧ショベルの具体的な診断を実施するものであり、類似度判定部（類似度判定手段、類似度演算方法設定手段）5 a、類似ニューロンセット選択部（類似ニューロンセット選択手段）5 b 及び状態診断部（状態診断手段）5 c を備えて構成される。

40

【0063】

まず、類似度診断部 5 a は、油圧ショベルの状態が未確定である実稼働時において、データ検出装置 1 から入力されるデータ（ニューロンセット Q の形成過程において参照されるデータと区別するために、以下、実データという） x_r の集合と、記憶部 4 に記憶された各ニューロンセット Q との距離を演算し、類似度（近さの程度）を判定するものである。例えば 5 分間程度の短い稼働時間で取得された m 個からなる実データ x_r の集合を実データセット R ($R = \{1, 2, \dots, m\}$) とする。

50

【 0 0 6 4 】

ここでいう距離とは、図 2 に模式的に示すように、K 次元空間内における 2 集合間のユークリッド距離のことを意味する。一つのニューロンセット Q は、K 次元のニューロン N_f 個からなる集合であるから、実データセット R 及びニューロンセット Q は、同一の K 次元空間内に配置することができる。そこで、図 2 に示すように、実データセット R 及びニューロンセット Q の距離が短いほど、実データセット R の特徴とニューロンセット Q の特徴とが類似していると判定し、距離が長いほど、実データセット R の特徴とニューロンセット Q の特徴とが相違していると判定することとする。

【 0 0 6 5 】

また、記憶部 4 に記憶されている各ニューロンセット Q におけるニューロンの分布は、その形や大きさ、密度が異なっているため、各ニューロンセット Q を同一の K 次元空間内に仮想的に配置すると、図 3 (a) ~ (d) に示すように、異なる分布が形成されることになる。そこで、実データセット R は、最も距離の近いニューロンセット Q に対して最も類似していると判定することにする。

【 0 0 6 6 】

なお、実データセット R を構成する各実データ (単にデータ点とも呼ぶ) x_r ($r = 1, 2, \dots, m$) とニューロンセット Q を構成する各ニューロン w_q^f との間のユークリッド距離 $D(r, q)$ は次式で求めることができる。

【 0 0 6 7 】

【 数 4 】

$$D(r, q) = \sqrt{\sum_{j=1}^K (x_{rj} - w_{qj}^f)^2} ; r \in R; q \in Q \quad \dots (式 5)$$

なお、類似度診断部 5 a は、上記の式 4 を用い、より具体的には 5 種類の手法を用いて、K 次元の実データ x_r と K 次元の各ニューロンセット Q との距離を演算するようになっている。以下にその 5 種類の手法を説明する。

【 0 0 6 8 】

(A) 平均距離 ADP_0 の演算

実データセット R を構成する各データ点 x_r と任意のニューロンセット Q を構成する各ニューロン w_q^f との間の全てのペア (組み合わせ) の距離の平均値 $ADP_0(R, Q)$ (mean of All Pairs Distances) を演算する。この平均距離 $ADP_0(R, Q)$ は、以下の式 6 によって与えられる。

【 0 0 6 9 】

【 数 5 】

$$ADP_0(R, Q) = \frac{\sum_{r=1}^M \sum_{q=1}^{N_f} D(r, q)}{m \times N_f} \quad \dots (式 6)$$

つまりこの演算では、図 4 に示すように、全ての実データ x_r と全てのニューロン w_q^f との組み合わせを考慮して、ユークリッド距離 $D(r, q)$ の平均値を演算することになる。実データ x_r とニューロン w_q^f との組み合わせ総数は、 $m \times N_f$ 通りとなる。

【 0 0 7 0 】

(B) ウェイト g_q^f を考慮した加重平均距離 $WADP_0$ の演算

実データセット R を構成する各データ点 x_r とニューロンセット Q を構成する各ニューロン w_q^f との間の全てのペア (組み合わせ) の距離に対して、ニューロン w_q^f のウェイト g_q^f を乗算したものの平均値 (加重平均値) $WADP_0(R, Q)$ (Weighted mean of All Pairs Distances) を演算する。この加重平均距離 $WADP_0(R, Q)$ は、以下の式 7 によって与えられる。

【 0 0 7 1 】

【数 6】

$$WAPD_0(R,Q) = \frac{\sum_{r=1}^M \sum_{q=1}^{N_f} D(r,q) \cdot g_q^f}{m} \quad \dots (式7)$$

【0072】

(C) 平均最小距離AMD₀の演算

実データセットRを構成する各実データ x_r に対して、最もユークリッド距離に近いニューロン w_q^f への距離の平均値(平均最小値)AMD₀(R,Q)(Average Minimum Distance)を演算する。この平均最小距離AMD₀(R,Q)は、以下の式8によって与えられる。

10

【0073】

【数 7】

$$AMD_0(R,Q) = \frac{\sum_{r=1}^M C_{r \min}}{m} \quad \dots (式8)$$

【0074】

ここで $C_{r \min}$ は、各実データ x_r からニューロンセットQまでの最小距離を示し、以下の式9で示される値を持つ。

【0075】

20

【数 8】

$$C_{r \min} = \min_{1 \leq q \leq N_f} D(r,q) \quad \dots (式9)$$

つまりこの演算では、図5に示すように、ニューロンセットQの各ニューロンのうち、実データセットRに近い側のニューロンのみが参照されて、距離が演算されることになる。演算にかかる実データ x_r とニューロン w_q^f との組み合わせ総数は、m通りである。

【0076】

(D) ウェイト g_q^f を考慮した加重平均最小距離WAMD₀の演算

実データセットRを構成する各データ点 x_r に対して最もユークリッド距離に近いニューロン w_q^f への距離に、そのニューロン w_q^f のウェイト g_q^f を乗算したものの平均値(加重平均最小値)WAMD₀(R,Q)(Weighted Average Minimum Distance)を演算する。この加重平均最小距離WAMD₀(R,Q)は、以下の式10によって与えられる。

30

【0077】

【数 9】

$$WAMD_0(R,Q) = \frac{\sum_{r=1}^M C_{r \min} \cdot g_{q^*}^f}{\sum_{q^*=1}^T g_{q^*}^f} \quad \dots (式10)$$

ここで、 q^* は、各実データ x_r から、ニューロンセットQのニューロン q^* までのユークリッド距離 $D(r,q^*)$ が最小になるニューロンの番号を示す。また、TはニューロンセットQの中で最小距離の演算に参加したニューロン q^* の総数(T=N)を示す。

40

【0078】

(E) 重心間距離COGD₀の演算

実データセットRの重心と、ニューロンセットQの重心とをそれぞれ計算し、両重心のユークリッド距離COGD₀(R,Q)(Center-of-Gravity Distance)を演算する。この重心間距離COGD₀(R,Q)は、以下の式11によって与えられる。

【0079】

【数 1 0】

$$COGD_0(R, Q) = \sqrt{\sum_{j=1}^K [COG_R(j) - COG_Q(j)]^2} \quad \dots (式 1 1)$$

$$\text{ただし、} COG_R(j) = \frac{\sum_{r=1}^M x_{rj}}{m}, \quad j = 1, 2, 3, \dots, K \quad \dots (式 1 2)$$

$$COG_Q(j) = \frac{\sum_{q=1}^{N_f} w_{qj} \cdot g_q}{\sum_{q=1}^{N_f} g_q}, \quad j = 1, 2, 3, \dots, K \quad \dots (式 1 3)$$

10

【0080】

類似度診断部 5 a は、以上の 5 種類の手法のそれぞれにおいて、実データセット R が最も距離の近いニューロンセット Q を、類似度の高いニューロンセット Q として判定する。ここでの判定結果は、類似ニューロンセット選択部 5 b へ入力されるようになっている。

一方、類似ニューロンセット選択部 5 b は、上記の各手法毎に、最も類似度が高いと判定されたニューロンセット Q を選択する。したがって、ここでは 5 通りの選択結果が得られることになる。

20

【0081】

そこで、状態診断部 5 c は、類似ニューロンセット選択部 5 b における選択結果のうち、最も選択された回数の多いニューロンセット Q をさらに選別するようになっている。つまりここでは、5 種類の手法による 5 通りの判断に基づいて、最終的な判断が多数決でなされることになる。これにより、最も多くの手法によって支持された油圧シヨベルの状態が、当該ニューロンセット Q に対応する種類の状態 f であると診断されて、診断結果が表示装置 3 へ出力されるようになっている。

【0082】

最も選択された回数の多いニューロンセット Q が正常データ記憶部 4 a に記憶された正常ニューロンセット Q_1 ($f = 1$) である場合、状態診断部 5 c は、油圧シヨベルが正常状態にあると診断する。一方、最も選択された回数の多いニューロンセット Q が異常データ記憶部 4 b に記憶された異常ニューロンセット Q_f ($f \neq 1$) である場合には、油圧シヨベルが異常状態にあると診断するとともに、そのニューロンセットが示す状態 f に応じて、どのような種類の異常状態であるかを診断する。例えば、 $f = 2$ の時には、第 1 異常状態であると診断し、 $f = 5$ の時には、第 4 異常状態であると診断する。

30

【0083】

[5] 圧縮部 6, 通信部 7

一方、圧縮部 6 は、データ検出装置 1 から入力されたデータ x_s を一時的に蓄え、所定の稼働時間毎にまとめて圧縮するものであり、例えば、1 日の油圧シヨベルの稼働によって蓄積された数千個以上のデータ x_s を、 n 個のニューロンへと圧縮する。このようなデータ圧縮の手法に関しては、前述の記憶部 4 に記憶された各ニューロンセット Q の作成手法と同様である。ここでデータ x_s を圧縮して得られた実ニューロンの集合 (実ニューロンセット) を P とすると、実ニューロンセット P を構成する各実ニューロン w_p は、以下の式 1 4 に示すように、 K 次元のベクトルで表すことができる。

40

【0084】

【数 1 1】

$$w_p = [x_{p1}, x_{p2}, x_{p3}, \dots, x_{pK}], \quad p = 1, 2, 3, \dots, n \quad \dots (式 1 4)$$

【0085】

50

なお、各実ニューロン w_p のベクトルは、 K 次元空間内における座標を表すものとみなすことができる。

また、圧縮部 6 は、各実ニューロン w_p の学習の過程において、例えば m_0 個のデータ x_s のうちのいくつかのデータ x_s に対する勝者になっているかを示すウェイト（第 1 ウェイト） g_p を、以下の式 15 に基づいて算出する。

【0086】

【数 12】

$$g_p = \frac{m_p}{m_0} \in [0,1], \quad p=1,2,3,\dots,n \quad \dots (式 15)$$

$$\text{ただし、} m_0 = \sum_{p=1}^n m_p \quad \dots (式 16)$$

m_p , $p=1,2,3,\dots,n$ は実ニューロンセット P の p 番目のニューロンが勝者となっているデータ数を示す。

【0087】

圧縮部 6 で算出された実ニューロンセット P の各実ニューロン w_p 及びそれらのウェイト g_p は、通信部 7 へ入力されるようになっている。

通信部 7 は、油圧ショベルの外部へ無線送信を行うためのものであり、圧縮部 6 から入力された情報を、事業所のサービスセンター内に設けられた第 2 診断装置 20 へと送信する。通信部 7 における通信頻度は、圧縮部 6 における圧縮頻度に対応しており、例えば油圧ショベルの稼働終了後に、1 日 1 回送信されるようになっている。

【0088】

[6] 第 2 診断装置 20

第 1 診断装置 10 の通信部 7 から送信された情報は、第 2 診断装置 20 の通信部 17 によって受信され、診断部 15 へと入力されるようになっている。なお、第 2 診断装置 20 の記憶部 14 は、第 1 診断装置 10 の記憶部 4 と全く同一の構成を備えており、正常ニューロンセット記憶部 14 a 及び異常ニューロンセット記憶部 14 b には、正常ニューロンセット記憶部 4 a 及び異常ニューロンセット記憶部 4 b に記憶されているものと同一のニューロンセットが記憶されている。

【0089】

[7] 診断部 15

診断部 15 は、予め記憶部 14 に記憶された知識と通信部 17 から入力された情報とを対比して類似度を計算し、油圧ショベルの具体的な診断を実施するものである。この情報診断部 15 は、第 1 診断装置 10 の情報診断部 5 と同様に、類似度判定部（類似度判定手段）15 a, 類似ニューロンセット選択部（類似ニューロンセット選択手段）15 b 及び状態診断部（状態診断手段）15 c を備えて構成されるが、各機能部における制御内容が若干異なっている。

【0090】

類似度診断部 15 a は、通信部 17 から入力された実ニューロンセット P の各実ニューロン w_p 及びそれらのウェイト g_p と記憶部 14 に記憶された各ニューロンセット Q との距離を演算し、類似度を判定する。つまり、第 1 診断装置 10 では実データセット R と各ニューロンセット Q との対比によって類似度を判定しているが、第 2 診断装置 20 では、ニューロン同士の対比（実ニューロンセット P とニューロンセット Q との対比）によって類似度を判定することになる。実ニューロン w_p は K 次元のニューロン n 個からなる集合であるから、実ニューロン w_p 及びニューロンセット Q は、同一の K 次元空間内に配置することができ、ユークリッド距離を計測できることになる。そこで、類似度診断部 5 a における判定と同様に、実ニューロン w_p 及びニューロンセット Q の距離が短いほど、実ニューロンセット P の特徴とニューロンセット Q の特徴とが類似していると判定する。

また、類似度診断部 15 a は、6 種類の手法を用いて、実ニューロン w_p と各ニューロンセット Q との距離を演算するようになっている。以下にその 6 種類の手法を説明する。

【0091】

(A) 平均距離 ADP の演算

実ニューロンセット P を構成する各実ニューロン w_p と任意のニューロンセット Q を構成する各ニューロン w_q^f との間の全てのペア (組み合わせ) の距離の平均値 ADP(P, Q) (mean of All Pairs Distances) を演算する。まず、実ニューロン w_p とニューロン w_q^f とのユークリッド距離 $D(p, q)$ は、以下の式 17 によって与えられるため、平均距離 ADP(P, Q) は、以下の式 18 のように表すことができる。

【0092】

【数 13】

$$D(p, q) = \sqrt{\sum_{j=1}^K (x_{pj} - w_{qj}^f)^2} ; p \in P; q \in Q \quad \dots (式 17)$$

$$APD(P, Q) = \frac{\sum_{p=1}^n \sum_{q=1}^{N_f} D(p, q)}{n \times N_f} \quad \dots (式 18)$$

つまりこの演算では、図 6 に示すように、実ニューロンセット P の実ニューロン w_p とニューロンセット Q のニューロン w_q^f との全ての組み合わせを考慮して、ユークリッド距離 $D(p, q)$ の平均値を演算することになる。これらのニューロンの組み合わせ総数は、 $n \times N_f$ 通りとなる。

【0093】

(B) ウェイト g_p, g_q^f を考慮した加重平均距離 WADP の演算

実ニューロンセット P を構成する各実ニューロン w_p とニューロンセット Q の各ニューロン w_q^f との間の全てのペア (組み合わせ) の距離に対して、実ニューロン w_p のウェイト g_p 及びニューロン w_q^f のウェイト g_q^f を乗算し、その平均値を加重平均距離 WADP(P, Q) (Weighted mean of All Pairs Distances) として算出する。この加重平均距離 WADP(P, Q) は、以下の式 19 によって与えられる。

【0094】

【数 14】

$$WADP(P, Q) = \frac{\sum_{p=1}^n \sum_{q=1}^{N_f} D(p, q) \cdot g_p \cdot g_q^f}{\sum_{p=1}^n \sum_{q=1}^{N_f} g_p \cdot g_q^f} \quad \dots (式 19)$$

つまり、この演算では、両端のニューロンのウェイト g_p, g_q^f が大きいほど、演算される距離が大きくなる。

【0095】

(C) 平均最小距離 AMD の演算

実ニューロンセット P を構成する各実ニューロン w_p に対して、最もユークリッド距離が近いニューロン w_q^f への距離の平均値 (平均最小値) AMD(P, Q) (Average Minimum Distance) を演算する。この平均最小距離 AMD(P, Q) は、以下の式 20 によって与えられる。

【0096】

10

20

30

40

【数 15】

$$AMD(P, Q) = \frac{\sum_{p=1}^n C_{p \min}}{n} \quad \dots (式 20)$$

ここで $C_{p \min}$ は、各実ニューロン w_p からニューロンセット Q までの最小距離を示し、以下の式 21 で示される値を持つ。

【0097】

【数 16】

$$C_{p \min} = \min_{1 \leq q \leq N_f} D(p, q) \quad \dots (式 21)$$

10

つまりこの演算では、図 7 に示すように、ニューロンセット Q のニューロンのうち、各実ニューロン w_p にとって最も近いものがそれぞれ参照されて、距離が演算されることになる。演算にかかる実ニューロン w_p とニューロン w_q^f との組み合わせ総数は、 n 通りである。

【0098】

(D) ウェイト g_p を考慮した加重平均最小距離 $WAMD_1$ の演算

各実ニューロン w_p からニューロンセット Q までの最小距離 $C_{p \min}$ に対して最もユークリッド距離が近いニューロン w_q^f への距離に、 m_p (実ニューロンセット P の p 番目のニューロンが勝者となっているデータ数) を乗じ稼働データ数 m_0 で除算して、加重平均最小距離 $WAMD_1(P, Q)$ (Weighted Average Minimum Distance, version 1) を演算する。この加重平均最小距離 $WAMD_1(P, Q)$ は、以下の式 22 によって与えられる。

20

【0099】

【数 17】

$$WAMD_1(P, Q) = \frac{\sum_{p=1}^n C_{p \min} \cdot m_p}{\sum_{p=1}^n m_p} = \frac{\sum_{p=1}^n C_{p \min} \cdot m_p}{m_0} \quad \dots (式 22)$$

30

前述の式 15 により、ここでは各実ニューロン w_p からニューロンセット Q までの最小距離 $C_{p \min}$ に対してウェイト g_p が乗算されたものが算出されていることになる。

【0100】

(E) ウェイト g_p, g_q を考慮した加重平均最小距離 $WAMD_2$ の演算

各実ニューロン w_p からニューロンセット Q までの最小距離 $C_{p \min}$ に対してウェイト g_p, g_q を乗じて、加重平均最小距離 $WAMD_2(P, Q)$ (Weighted Average Minimum Distance, version 2) を演算する。この加重平均最小距離 $WAMD_2(P, Q)$ は、以下の式 23 によって与えられる。

【0101】

【数 18】

$$WAMD_2(P, Q) = \frac{\sum_{p=1}^n C_{p \min} \cdot g_p \cdot g_{q^*}^f}{\sum_{p=1}^n g_p \cdot g_{q^*}^f} \quad \dots (式 23)$$

40

ここで、 q^* は、各実ニューロン w_p から、ニューロンセット Q のニューロン q^* までのユークリッド距離 $D(p, q^*)$ が最小になるニューロンの番号を示す。つまりここでは、図 8 に示すように、各実ニューロン w_p からニューロンセット Q までの最小距離 $C_{p \min}$ に関して、その両端のニューロンのウェイト $g_p, g_{q^*}^f$ が大きいほど、演算される距離が大きくなる。

50

【 0 1 0 2 】

(F) 重心間距離 COGD の演算

実ニューロンセット P の重心と、ニューロンセット Q の重心とをそれぞれ計算し、両重心のユークリッド距離 COGD(P,Q) (Center-of-Gravity Distance) を演算する。この重心間距離 COGD(P,Q) は、以下の式 2 4 によって与えられる。

【 0 1 0 3 】

【 数 1 9 】

$$COGD(P,Q) = \sqrt{\sum_{j=1}^K [COG_P(j) - COG_Q(j)]^2} \quad \dots (式 2 4)$$

10

$$\text{ただし、} COG_P(j) = \frac{\sum_{p=1}^n w_{pj} \cdot g_p}{\sum_{p=1}^n g_p}, \quad j=1,2,3,\dots,K \quad \dots (式 2 5)$$

$$COG_Q(j) = \frac{\sum_{q=1}^{N_f} w_{qj} \cdot g_q}{\sum_{q=1}^{N_f} g_q}, \quad j=1,2,3,\dots,K \quad \dots (式 2 6)$$

20

【 0 1 0 4 】

以上の通り、類似度診断部 1 5 a は、6 種類の手法のそれぞれにおいて、各実ニューロン w_p の実ニューロンセット P にとって最も距離が近いニューロンセット Q を、類似度の高いニューロンセット Q として判定する。ここでの判定結果は、類似ニューロンセット選択部 1 5 b へ入力されるようになっている。

一方、類似ニューロンセット選択部 1 5 b は、上記の各手法毎に、最も類似度が高いと判定されたニューロンセット Q を選択する。したがって、ここでは 6 通りの選択結果が得られることになる。

【 0 1 0 5 】

30

そして、状態診断部 1 5 c は、類似ニューロンセット選択部 1 5 b における選択結果のうち、最も選択された回数が多いニューロンセット Q を選別し、油圧シヨベルの状態が、当該ニューロンセット Q に対応する種類の状態 f であると診断されて、診断結果が表示装置 1 3 へ出力されるようになっている。

【 0 1 0 6 】

[フローチャート]

本実施形態に係る診断装置は、上述のように構成されており、その処理は図 9 ~ 図 1 1 に示すフローチャートに沿って実行される。本フローチャートは、E C U 2 及び 1 2 内において実行される制御内容を示しており、図 9 のフローは油圧シヨベルの予備運転時に診断基準となるニューロンセット Q の各モジュールを設定するために予め実行されるものであり、図 1 0 , 図 1 1 のフローは油圧シヨベルの実稼働時において診断を行うべく、所定周期で繰り返し実行されるものである。

40

【 0 1 0 7 】

(A) ニューロンセット Q のモジュール作成フロー

図 9 に示すフローチャートにおいて、 $f = 1$ に対応する正常状態の稼働データセットから $f = 5$ に対応する第 4 異常状態の稼働データセットを用いて、5 種類のニューロンセット (モジュール) $Q_1 \sim Q_5$ が作成される。

まずステップ A 1 0 では、状態の種類 f が $f = 1$ に設定される。続くステップ A 2 0 では、状態 $f = 1$ に対応する、上記の式 1 に示されるデータ x^1_s が M_1 個検出されて読み込まれる。ここで読み込まれるデータ x^1_s は、K 次元のベクトルの形をなしている。

50

【0108】

一方、ステップA30では、上記の式2に示される N_1 個のニューロンが K 次元の空間にランダムに配置され、続くステップA40において、ニューラルネットワークの教師なし学習によりデータ x_s^1 が N_1 個のニューロン w_q^1 に圧縮される。これにより、各ニューロン w_q^1 は、データ x_s^1 の特徴、すなわち、状態 $f=1$ に対する動的挙動についての適切な情報を備えることになる。

【0109】

また続くステップA50では、前ステップで得られた各ニューロン w_q^1 のウェイト g_q^1 が、上記の式3、式4に基づいて算出される。そして、ステップA60において、 $f=1$ の状態に対応する各ニューロン w_q^1 及びウェイト g_q^1 が正常稼働時に対応するニューロンセット(モジュール) Q_1 として、正常ニューロンセット記憶部4aに記憶される。

10

その後、ステップA70では、状態 f が $f=L$ であるか否かが判定される。ここで、 $f=L$ である場合には、ステップA80へ進んで f に $f+1$ が代入され、ステップA20以降のフローが繰り返される。つまり、 $f=1$ の状態のモジュールの作成が完了すると、 $f=2$ の状態のモジュール、 $f=3$ の状態のモジュールと、続けて各モジュールが作成されることになる。このように、状態 f の順に正常ニューロンセット Q_1 及び異常ニューロンセット $Q_2 \sim Q_5$ の各モジュールが作成され、正常ニューロンセット記憶部4a及び異常ニューロンセット記憶部4bへ記憶される。

【0110】

一方、ステップA70において $f=L$ である場合には、全ての稼働データセットに対応するモジュールが作成されたものとみなされて、このフローは終了する。

20

【0111】

(B)第1診断装置10における診断フロー

図10に示すフローチャートのステップB10では、第1診断装置10の診断部5において、データ検出装置1から入力される実データセットRのデータ点 x_r が m 個読み込まれる。

【0112】

続くステップB20～ステップB60では、類似度判定部5aにおいて実データセットRとの類似度の高いニューロンセットQが、それぞれのステップで選択され、5種類の選択結果が累積して記憶される。

30

まずステップB20では、上記の式6に基づき、各データ点 x_r と各ニューロンセットQを構成する各ニューロン w_q^f との間の全てのペアの距離の平均値 $ADP_0(R, Q)$ が演算される。つまりここでは、実データセットRとニューロンセットQとの平均値 $ADP_0(R, Q)$ が、油圧ショベルの状態 f に対応する5つのニューロンセット $Q_1 \sim Q_5$ に対して演算されることになる。そして類似度判定部5aでは、この演算で最も類似度が高いと判定されたニューロンセットQが選択される。

【0113】

続いてステップB30では、上記の式7に基づき、実データセットRを構成する各データ点 x_r とニューロンセットQを構成する各ニューロン w_q^f との間の全てのペアの距離に対して、ニューロン w_q^f のウェイト g_q^f を乗算したものの平均値 $WAPD_0(R, Q)$ が演算される。

40

つまりここでは、前ステップとは異なる手法で、実データセットRとニューロンセットQとの類似度が測られることになる。類似度判定部5aによる、前ステップでの選択結果とは別に、最も類似度が高いと判定されたニューロンセットQが選択される。

【0114】

ステップB40では、上記の式8に基づき、実データセットRを構成する各データ点 x_r に対して、最もユークリッド距離が近いニューロン w_q^f への距離の平均値 $AMD_0(R, Q)$ が演算される。そして前ステップと同様に、上記の選択結果からは独立して、最も類似度が高いと判定されたニューロンセットQが選択される。

また、ステップB50では、上記の式10に基づき、実データセットRを構成する各データ点 x_r に対して最もユークリッド距離が近いニューロン w_q^f への距離に、そのニュー

50

ロン w^f_q のウェイト g^f_q を乗算したものの平均値 $WAMD_0(R, Q)$ が演算されてニューロンセット Q が選択され、ステップ B 60 では、上記の式 11 に基づき、実データセット R の重心とニューロンセット Q の重心との間の距離 $COGD_0(R, Q)$ が演算されてニューロンセット Q が選択される。

【0115】

そして、ステップ B 70 では、類似ニューロンセット選択部 5b において、ステップ B 20 ~ ステップ B 60 での選択結果のうち、最も選択された回数の多いニューロンセット Q が選別される。これにより、ステップ B 80 では、状態診断部 5c において、前ステップで最終的に選別されたニューロンセット Q に対応する状態 f が、各データ点 x_r の特徴と最も類似しているとみなされ、診断結果が表示装置 3 へ出力されて、このフローは終了する。

10

【0116】

(C) 第2診断装置 20 における診断フロー

図 11 に示すフローチャートのステップ C 10 では、第2診断装置 20 の診断部 15 において、通信部 7, 17 を介して入力される実ニューロンセット P の各実ニューロン w_p 及びウェイト g_p がそれぞれ n 個読み込まれる。つまり、第1診断装置 10 では、データ検出装置 1 で得られた生データ（圧縮加工がなされていないデータ）を用いて油圧ショベルの稼働状態を診断するのに対し、第2診断装置 20 は、データ検出装置 1 で得られた生データを圧縮加工したニューロンを用いて油圧ショベルの稼働状態を診断する。

【0117】

続くステップ C 20 ~ ステップ C 70 では、類似度判定部 15a において実ニューロンセット P との類似度の高いニューロンセット Q が、それぞれのステップで選択され、6種類の選択結果が累積して記憶される。

20

まず、ステップ C 20 では、上記の式 17 に基づき、類似度判定部 15a において実ニューロンセット P を構成する各実ニューロン w_p と任意のニューロンセット Q を構成する各ニューロン w^f_q との間の全てのペアの距離の平均値 $ADP(P, Q)$ が演算される。そして、この演算で最も類似度が高いと判定されたニューロンセット Q が選択される。

【0118】

次に、ステップ C 30 では、上記の式 19 に基づき、実ニューロンセット P の各実ニューロン w_p とニューロンセット Q の各ニューロン w^f_q との間の全てのペアの距離に対して、実ニューロン w_p のウェイト g_p 及びニューロン w^f_q のウェイト g^f_q を乗算したものの平均値 $WAPD(P, Q)$ が演算され、最も類似度が高いとニューロンセット Q が選択される。

30

続くステップ C 40 ~ C 70 においても、上記の式 20 ~ 式 26 に基づき、それぞれ、平均最小距離 $AMD(P, Q)$ 、加重平均最小距離 $WAMD_1(P, Q)$ 、加重平均最小距離 $WAMD_2(P, Q)$ 及び重心間距離 $COGD(P, Q)$ が演算され、それぞれの手法において最も類似度が高いと判定されたニューロンセット Q が選択される。

【0119】

そして、ステップ C 80 では、類似ニューロンセット選択部 51b において、ステップ C 20 ~ ステップ C 70 での選択結果のうち、最も選択された回数の多いニューロンセット Q が選別される。これにより、ステップ C 90 では、状態診断部 15c において、前ステップで最終的に選別されたニューロンセット Q に対応する状態 f が、各実ニューロン w_p の特徴と最も類似しているとみなされ、診断結果が表示装置 13 へ出力されて、このフローは終了する。

40

【0120】

[効果]

本発明の一実施形態に係る診断装置は、以下のような効果を奏する。

まず、油圧ショベル内に設けられた第1診断装置 10 では、データ検出装置 1 で得られた生の実データからなる実データセット R と記憶部 4 に記憶されたニューロンセット Q とを対比することによって診断を行うため、データの取得後、迅速に診断を行うことができる。つまり、セミリアルタイムの診断が可能であり、例えば表示装置 3 を油圧ショベルの

50

キャブ内に設置しておけば、油圧シヨベルのオペレータ（操作者）に診断結果を報知することができ、自主的な予知保全メンテナンスを促すことができる。なお、油圧系統やエンジン油温、作動油温等、比較的状态変化の速い異常状態を診断する場合には、このようなセミリアルタイムの診断が有効であると考えられる。

【0121】

一方、サービスセンター内に設けられた第2診断装置20は、圧縮された実ニューロンからなる実ニューロンセットPと記憶部14に記憶されたニューロンセットQとを対比することによって診断を行うようになっていたため、通信部7、17同士の通信データ量を大幅に削減することができ、診断にかかる通信コストを低減させることができる。特に、油圧シヨベルの月例点検や年次点検のように、診断結果に即時性が求められない内容の診断を行いたい場合には、第2診断装置20による診断が有利である。例えば、異常状態として、車載バッテリーの寿命を診断する場合や、エアコンのフィルタ清掃状態を診断する場合など、比較的状态変化が緩慢な異常状態を診断する場合が挙げられる。

10

【0122】

また、上記の何れの診断装置10、20においても、記憶部4、14に同一のニューロンセットQが記憶されているため、構成が簡素であるだけでなく、診断基準となる知識ベースを規格化することができ、診断の信憑性を高めることができる。

また、記憶部4、14に記憶される各ニューロンセットQは、予め設定された状態f毎にモジュール化されているため、交換や置換、追加が極めて容易である。本実施形態では構成を簡略化して、1つの正常状態と4つの異常状態とを診断する場合を説明しているが、正常状態、異常状態ともに想定しうる状態の数には制限がなく、知識ベースを限りなく増強することが可能である。

20

【0123】

また、本診断装置によれば、まず油圧シヨベルが正常状態であるか否かを判定することができるだけでなく、異常状態である場合にはその異常の種類まで診断することができる。つまり、従来の診断装置では、少なくとも「正常ではない」ことを以て異常状態を把握していたが、本診断装置では具体的に「第1異常状態」であることや「第4異常状態」であることを把握することができる。また、上記の通り、知識ベースを増強することにより、本診断装置が診断しうる劣化や異常状態の種類を限りなく増加させることもできる。したがって、油圧シヨベルの状態をより明確に把握することができ、診断された異常状態に応じたメンテナンスが可能となり、予知保全が容易となる。

30

【0124】

また、診断手法に関して、油圧シヨベルの状態に応じて変動する複数のパラメータ全体を一つのデータとして扱うようになっていたため、例えば各パラメータを個別に判定するような手法では事実上困難である総括的な判定が可能となる。

また、同時に検出された複数のパラメータを、ある状態を示す「点」として捉えることにより、点の集合同士の距離を「状態の近さ」として捉え直すことができる。また、これに加えて、診断のアルゴリズムに関して、検出データに基づく集合（実データセットRや実ニューロンセットP）とニューロンセットQとの距離によって二つの集合の類似度を判定するようになっていたため、検出データに基づく集合の特徴を正確に把握することができる。

40

【0125】

また、状態診断部5cにおいては、5種類の手法による5通りの判断に基づき、最終的な判断が多数決でなされるため、判定結果の信憑性を高めることができる。

なお、本診断装置では、類似度の判定に係る演算手法が第1診断装置10では5種類、第2診断装置20では6種類挙げられており、これらの演算手法は、互いに診断の確かさ（信憑性、信頼性）に優劣が付けられるものではない。

【0126】

[その他]

以上、本発明の一実施形態を説明したが、本発明はかかる実施形態に限定されるもので

50

はなく、本発明の趣旨を逸脱しない範囲で種々変形して実施することができる。

例えば、上述の実施形態では、記憶部 4 が、図 9 に示されたような過程を経て、診断の基準となるモジュールを予め記憶するようになっていたが、例えば記憶部 4 を書き換え可能なメモリで構成すれば、現在の知識ベースにはない新たな異常状態が生じた場合に、その異常状態を表すニューロンからなるモジュールを付け加えたり、古いモジュールを新しいものに置き換えたりすることも可能であり、診断精度をより向上させることができる。

【0127】

なお、このようなモジュールの更新や変更時には、実データセットに対応する状態が、「未知の異常状態」にあるか否かを判定する手段（未知異常状態判定手段）を備えることが好ましい。例えば、実データセットと異常ニューロンセットとのユークリッド距離に基づき、実データセットが何れの異常ニューロンセットに対しても類似していない場合（実データセットと各異常ニューロンセットとのユークリッド距離が、何れも、予め設定された所定距離よりも大きい場合など）に、対象体が未知の異常状態にあると判定する判定部を ECU 2, 12 内に設けておいてもよいし、あるいは、実データセットを観察しているオペレータや管理者の判断で、「未知の異常状態」を判定するようにしてもよい。

【0128】

何れの場合においても、未確定な状態に対応する任意の実データセットを、「未知の異常状態」に対応する実データセットとして用いることにより、その実データセットに基づく新たな異常ニューロンセットを作成することができる。つまり、検出手段で検出された実際の未知の状態に対応するモジュールを知識ベースに追加することができる。

また、上述の実施形態では、類似度判定部 5a が 5 種類の手法を用いて、K 次元の実データセット R, 実ニューロンセット P と K 次元のニューロンセット Q との距離を演算するようになっていたが、これらの距離の演算手法についてはこれに限定されるものではない。また、類似度判定部 15a における 6 種類の手法についても同様である。逆に、これらの手法のうち少なくとも何れかの手法を用いて、集合同士の距離を演算する構成としてもよい。

【0129】

また、上述の実施形態では、状態診断部 5c が類似ニューロンセット選択部 5b における選択結果のうち、最も選択された回数が多いニューロンセット Q をさらに選別するようになっていたが、最終的な選別方法はこれに限定されない。例えば、各手法で演算された距離の合計が最も小さいものを選別する構成としてもよいし、各手法毎に、選択結果の信頼性の重み付けを行うようにしてもよい。

【0130】

なお、本実施形態では、診断の対象として油圧ショベルを例に挙げたが、対象体はこれに限定されるものではなく、例えばトラック・バス、船舶等の乗物類、及び、産業機械をはじめとした各種機械類の動作の良否判定等に広く適用できるほか、動植物や微生物等の生命体の状態の良否判定等や、天候或いは地球等、天体の変化の推定等にも適用することができる。

【図面の簡単な説明】

【0131】

【図 1】本発明の一実施形態にかかる診断装置の全体構成を示すブロック構成図である。

【図 2】本診断装置での演算に係るユークリッド距離の概念を説明するための模式図である。

【図 3】本診断装置での判定に係る類似度の概念を説明するための模式図である。

【図 4】本診断装置における平均距離 ADP_0 の演算内容を説明するための模式図である。

【図 5】本診断装置における平均最小距離 AMD_0 の演算内容を説明するための模式図である。

【図 6】本診断装置における平均距離 ADP の演算内容を説明するための模式図である。

【図 7】本診断装置における平均最小距離 AMD の演算内容を説明するための模式図である。

。

10

20

30

40

50

【図 8】本診断装置における加重平均最小距離 $WAMD_2$ の演算内容を説明するための模式図である。

【図 9】本診断装置におけるニューロンセットのモジュール作成制御内容を示すフローチャートである。

【図 10】本診断装置の第 1 診断装置における診断制御内容を示すフローチャートである。

【図 11】本診断装置の第 2 診断装置における診断制御内容を示すフローチャートである。

【符号の説明】

【 0 1 3 2 】

1 データ検出装置 (検出手段)

2, 12 ECU

3, 13 表示装置

4, 14 記憶部

4a, 14a 正常ニューロンセット記憶部 (正常ニューロンセット記憶手段)

4b, 14b 異常ニューロンセット記憶部 (異常ニューロンセット記憶手段)

5, 15 診断部 (診断手段)

5a, 15a 類似度判定部 (類似度判定手段, 類似度演算方法設定手段)

5b, 15b 類似ニューロンセット選択部 (類似ニューロンセット選択手段)

5b, 15c 状態診断部 (状態診断手段)

6 圧縮部 (圧縮手段)

7, 17 通信部

10 第 1 診断装置

20 第 2 診断装置

P: 実ニューロンセット

Q: ニューロンセット (モジュール)

Q_1 : 正常ニューロンセット


$Q_2 \sim Q_5$: 異常ニューロンセット

R: 実データセット

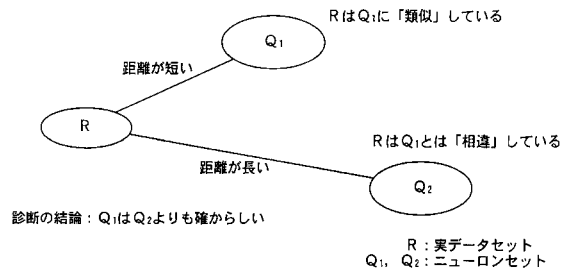
10

20


【図1】



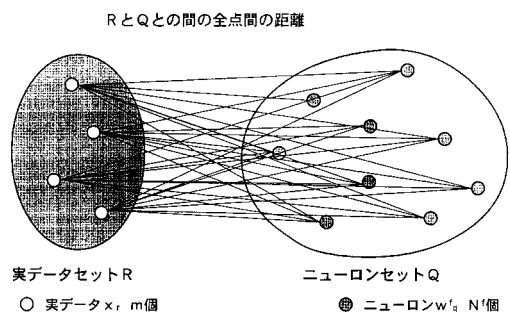
【図2】




【図3】



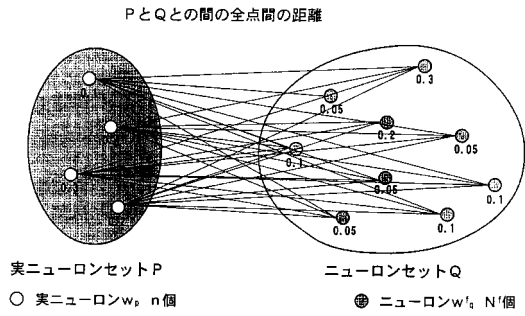
【図4】



【図5】




【 図 6 】




【 図 8 】

ウェイトを考慮したPとQとの間の平均最小距離



【 図 7 】

PとQとの間の平均最小距離

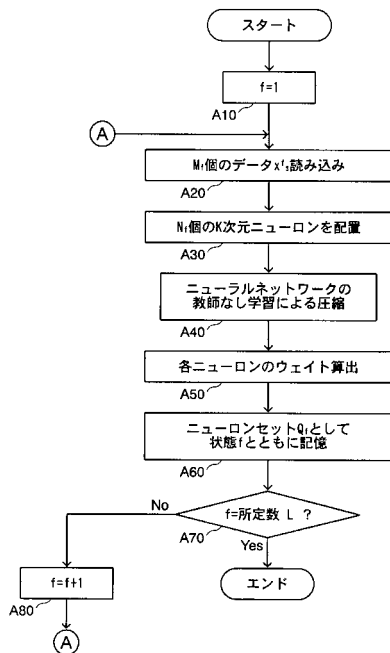


実ニューロンセットPの実ニューロン w_p が勝者となった稼働データ数(ウェイト)の合計: $8+5+10+7+2+3=35$
 ニューロンセットQのニューロン w'_q が勝者となった稼働データ数(ウェイト)の合計: $5+2+8+4+3+7+1=30$

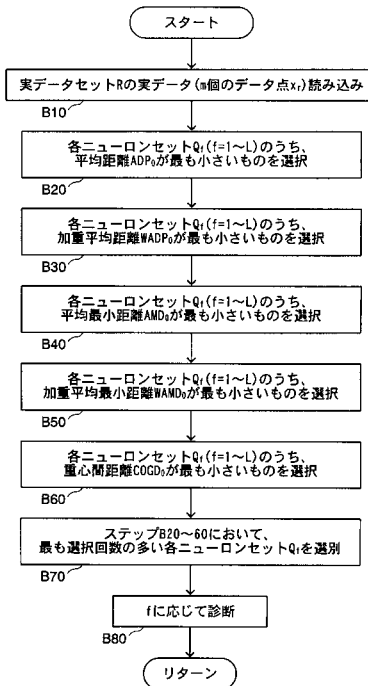
$$WAMD_2(P,Q) = \frac{\frac{8 \cdot 5 \cdot d_1}{35 \cdot 30} + \frac{5 \cdot 2 \cdot d_2}{35 \cdot 30} + \frac{10 \cdot 2 \cdot d_3}{35 \cdot 30} + \frac{7 \cdot 5 \cdot d_4}{35 \cdot 30} + \frac{2 \cdot 3 \cdot d_5}{35 \cdot 30} + \frac{3 \cdot 1 \cdot d_6}{35 \cdot 30}}{\frac{8 \cdot 5}{35 \cdot 30} + \frac{5 \cdot 2}{35 \cdot 30} + \frac{10 \cdot 2}{35 \cdot 30} + \frac{7 \cdot 5}{35 \cdot 30} + \frac{2 \cdot 3}{35 \cdot 30} + \frac{3 \cdot 1}{35 \cdot 30}}$$

$$= \frac{8 \cdot 5 \cdot d_1 + 5 \cdot 2 \cdot d_2 + 10 \cdot 2 \cdot d_3 + 7 \cdot 5 \cdot d_4 + 2 \cdot 3 \cdot d_5 + 3 \cdot 1 \cdot d_6}{8 \cdot 5 + 5 \cdot 2 + 10 \cdot 2 + 7 \cdot 5 + 2 \cdot 3 + 3 \cdot 1}$$

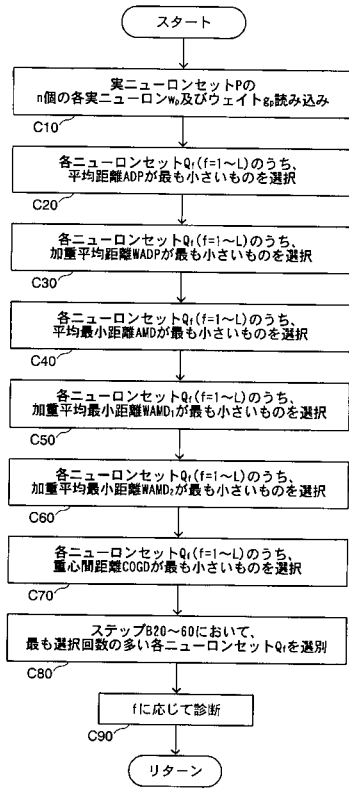
【 図 9 】



【 図 10 】



【 図 1 1 】



フロントページの続き

- (72)発明者 小松 孝二
香川県高松市林町2217-20 国立大学法人香川大学工学部内
- (72)発明者 田中 三郎
東京都世田谷区用賀四丁目10番1号 新キャタピラー三菱株式会社内
- (72)発明者 藤井 敏
東京都世田谷区用賀四丁目10番1号 新キャタピラー三菱株式会社内
- (72)発明者 室田 功
東京都世田谷区用賀四丁目10番1号 新キャタピラー三菱株式会社内
- Fターム(参考) 5H223 AA17 DD03 DD07 EE29