

(19)日本国特許庁(JP)

(12)公開特許公報(A)

(11)公開番号

特開2022-132895
(P2022-132895A)

(43)公開日 令和4年9月13日(2022.9.13)

(51)国際特許分類 F I テーマコード(参考)
 G 0 5 B 19/418 (2006.01) G 0 5 B 19/418 Z 3 C 1 0 0
 C 2 2 F 1/04 (2006.01) C 2 2 F 1/04 M

審査請求 未請求 請求項の数 19 O L (全23頁)

(21)出願番号	特願2021-31615(P2021-31615)	(71)出願人	000107538 株式会社U A C J 東京都千代田区大手町一丁目7番2号
(22)出願日	令和3年3月1日(2021.3.1)	(74)代理人	100101683 弁理士 奥田 誠司
		(74)代理人	100155000 弁理士 喜多 修市
		(74)代理人	100202197 弁理士 村瀬 成康
		(72)発明者	森口 隆宏 東京都千代田区大手町一丁目7番2号 株式会社U A C J内
		(72)発明者	山本 裕介 東京都千代田区大手町一丁目7番2号 株式会社U A C J内

最終頁に続く


(54)【発明の名称】 合金材料の特性を予測する製造支援システム、予測モデルを生成する方法およびコンピュータプログラム

(57)【要約】

【課題】製造実績のデータ範囲外においても、特性を予測する予測モデルの精度を向上させ、予測モデルを用いて適切な製造条件を選定することが可能となる製造支援システムを提供する。

【解決手段】プロセッサがプログラムに従って、複数の製造パラメータ及び合金材料の少なくとも1つの特性の実測値を取得し、複数の製造パラメータに含まれる第1製造パラメータと、特性の目標値である目標予測値の概算値を表す特性のプレ予測値の関係を記述する予測式を用いて、第1製造パラメータに基づいてプレ予測値を算出し、プレ予測値と特性の実測値の差分を算出し、第2製造パラメータ及び差分を含む学習データセットを用いてモデルを訓練し、少なくとも1つの特性を予測するために用いる学習済みモデルを生成する。

【選択図】図5



【特許請求の範囲】**【請求項 1】**

複数の製造プロセスを経て製造される合金材料の少なくとも 1 つの特性を予測する製造支援システムであって、

プロセッサと、

前記プロセッサの動作を制御するプログラムを記憶するメモリと、

それぞれが、各種の製造プロセスの製造条件を表す複数の製造パラメータ、および、前記製造プロセスの製造条件下で製造された合金材料の前記少なくとも 1 つの特性の実測値を含むデータを記憶した記憶装置と、

を備え、

前記プロセッサは、前記プログラムに従って、

前記記憶装置にアクセスし、前記複数の製造パラメータおよび前記少なくとも 1 つの特性の実測値を取得し、

前記複数の製造パラメータに含まれる第 1 製造パラメータと、前記少なくとも 1 つの特性の目標値である目標予測値の概算値を表す特性のプレ予測値との関係を記述するプレ予測値演算式を取得し、

前記プレ予測値演算式を用いて、前記第 1 製造パラメータに基づいて前記プレ予測値を算出し、

算出した前記プレ予測値と、前記プレ予測値に対応する前記少なくとも 1 つの特性の実測値との差分を算出し、

前記複数の製造パラメータに含まれる、前記第 1 製造パラメータとは異なる第 2 製造パラメータ、および、算出した前記差分を含む学習データセットを用いてモデルを訓練し、前記少なくとも 1 つの特性を予測するために用いる学習済みモデルを生成する、製造支援システム。

【請求項 2】

前記プロセッサは、

学習済みモデルに前記第 2 製造パラメータを入力して、前記目標予測値と前記プレ予測値との差分を補正するための補正值を取得し、

前記プレ予測値、前記補正值および前記目標予測値の関係をモデル化した数式に基づいて、前記プレ予測値および前記補正值から前記目標予測値を算出する、請求項 1 に記載の製造支援システム。

【請求項 3】

前記プレ予測値演算式は、前記第 1 製造パラメータに基づく変数の 2 次式で与えられる、請求項 1 または 2 に記載の製造支援システム。

【請求項 4】

前記第 1 製造パラメータは熱処理時間である、請求項 1 から 3 のいずれかに記載の製造支援システム。

【請求項 5】

前記第 2 製造パラメータは気候データを含む、請求項 4 に記載の製造支援システム。

【請求項 6】

前記第 2 製造パラメータは、合金材料の化学成分、熱処理温度、巻取温度および自然時効時間のいずれかを表す製造パラメータをさらに含む、請求項 5 に記載の製造支援システム。

【請求項 7】

前記第 2 製造パラメータは、合金材料の重量を表す製造パラメータをさらに含む、請求項 6 に記載の製造支援システム。

【請求項 8】

前記第 1 製造パラメータは熱処理時間であり、

前記第 2 製造パラメータは気候データを含み、

前記プロセッサは、前記第 2 製造パラメータを含む前記学習データセットを用いて前記

10

20

30

40

50

モデルを訓練する、請求項 1 に記載の製造支援システム。

【請求項 9】

前記気候データは平均気温である、請求項 7 または 8 に記載の製造支援システム。

【請求項 10】

前記合金材料はアルミニウム合金である、請求項 1 から 9 のいずれかに記載の製造支援システム。

【請求項 11】

前記複数の製造プロセスは、原料配合工程、溶解工程、鋳造工程、均質化工程、熱間圧延工程、熱間押出工程、熱間鍛造工程、冷間圧延工程、箔圧延工程、矯正工程、溶体化工程、焼きなまし工程、時効工程のうち少なくとも 1 つを含む、請求項 10 に記載の製造支援システム。

10

【請求項 12】

前記プロセッサは、さらに、

目標とする特性の設計範囲を規定する少なくとも 1 つの入力設計パラメータを取得し、

前記学習済みモデルに前記入力設計パラメータを入力して、前記設計範囲を満足する 1 または複数の製造条件を表す製造パラメータ群を出力する、請求項 1 から 11 のいずれかに記載の製造支援システム。

【請求項 13】

前記プロセッサは、過去の製造過程から得られた 1 または複数の製造パラメータを利用して前記モデルを訓練した後、さらに、

20

目標とする特性の設計範囲を規定する少なくとも 1 つの入力設計パラメータを取得し、

現在の製造過程において、最初の製造プロセスから実施済みの中間製造プロセスまでに用いた 1 または複数の製造条件を表す製造パラメータ群のうち少なくとも 1 つと、前記入力設計パラメータとを前記学習済みモデルに入力して、前記中間製造プロセスよりも後に続く下工程の製造プロセスにおいて用いる、前記設計範囲を満足する 1 または複数の製造条件を表す下工程製造パラメータ群を出力する、請求項 1 から 11 のいずれかに記載の製造支援システム。

【請求項 14】

前記プロセッサは、過去の製造過程から得られた 1 または複数の製造パラメータを利用して前記モデルを訓練した後、さらに、

30

目標とする特性の設計範囲を規定する少なくとも 1 つの入力設計パラメータを取得し、

現在の製造過程において、最初の製造プロセスから実施済みの中間製造プロセスまでに用いた 1 または複数の製造条件を表す製造パラメータ群のうち少なくとも 1 つと、前記中間製造プロセスよりも後に続く下工程の製造プロセスにおいて用いる 1 または複数の製造条件の予測値を含む第 1 下工程製造パラメータ群と、前記入力設計パラメータと、を前記学習済みモデルに入力して、前記第 1 下工程製造パラメータ群が表す 1 または複数の製造条件とは異なる 1 または複数の製造条件を表す第 2 下工程製造パラメータ群であって、前記設計範囲を満足する第 2 下工程製造パラメータ群を出力する、請求項 1 から 11 のいずれかに記載の製造支援システム。

【請求項 15】

40

前記中間製造プロセスは冷間圧延工程である、請求項 13 または 14 に記載の製造支援システム。

【請求項 16】

前記下工程は焼きなまし工程を含み、

前記下工程製造パラメータ群は、前記焼きなまし工程における製造条件を表す製造パラメータを含む、請求項 13 から 15 のいずれかに記載の製造支援システム。

【請求項 17】

前記合金材料の少なくとも 1 つの特性は、前記合金材料の力学特性を含む、請求項 1 から 16 のいずれかに記載の製造支援システム。

【請求項 18】

50

複数の製造プロセスを経て製造される合金材料の少なくとも1つの特性を予測するために用いる予測モデルを生成する方法であって、

それぞれが、各種の製造プロセスの製造条件を表す複数の製造パラメータ、および、前記製造プロセスの製造条件下で製造された合金材料の前記少なくとも1つの特性の実測値を含むデータにアクセスして、前記複数の製造パラメータおよび前記少なくとも1つの特性の実測値を取得し、

前記複数の製造パラメータに含まれる第1製造パラメータと、前記少なくとも1つの特性の目標値である目標予測値の概算値を表す特性のプレ予測値と、の関係を記述するプレ予測値演算式を取得し、

前記プレ予測値演算式を用いて、前記第1製造パラメータに基づいて前記プレ予測値を算出し、

算出した前記プレ予測値と、前記プレ予測値に対応する前記少なくとも1つの特性の実測値との差分を算出し、

前記複数の製造パラメータに含まれる、前記第1製造パラメータとは異なる第2製造パラメータ、および、前記差分を含む学習データセットを用いてモデルを訓練し、前記予測モデルを生成することを包含する方法。

【請求項19】

複数の製造プロセスを経て製造される合金材料の少なくとも1つの特性を予測するために用いる予測モデルを生成することをコンピュータに実行させるコンピュータプログラムであって、

前記コンピュータに、

それぞれが、各種の製造プロセスの製造条件を表す複数の製造パラメータ、および、前記製造プロセスの製造条件下で製造された合金材料の前記少なくとも1つの特性の実測値を含むデータにアクセスして、前記複数の製造パラメータおよび前記少なくとも1つの特性の実測値を取得することと、

前記複数の製造パラメータに含まれる第1製造パラメータと、前記少なくとも1つの特性の目標値である目標予測値の概算値を表す特性のプレ予測値と、の関係を記述するプレ予測値演算式を取得することと、

前記プレ予測値演算式を用いて、前記第1製造パラメータに基づいて前記プレ予測値を算出することと、

算出した前記プレ予測値と、前記プレ予測値に対応する前記少なくとも1つの特性の実測値との差分を算出することと、

前記複数の製造パラメータに含まれる、前記第1製造パラメータとは異なる第2製造パラメータ、および、前記差分を含む学習データセットを用いてモデルを訓練し、前記予測モデルを生成することと、を実行させるコンピュータプログラム。

【発明の詳細な説明】

【技術分野】

【0001】

本開示は、合金材料の特性を予測する製造支援システム、予測モデルを生成する方法およびコンピュータプログラムに関する。

【背景技術】

【0002】

多種多様な工業材料が様々な技術分野で用いられている。工業材料は、種々の規格（例えば、JIS、ASTM）に従って分類・試験されるが、個々の製品の特性は、種々の要因（組成、製造プロセス、製造条件（例えば、熱処理の温度、速度または時間）など）で多様化する。したがって、要求される特性に最も適合する材料を選択または開発することは容易ではない。また、工業的には、特性だけでなく、コストや供給安定性、製品寿命なども、材料選択のポイントとなり得る。

【0003】

これまで、製造条件の選定、調整または変更は、主に人の経験に基づいて行われていた

10

20

30

40

50

。すなわち、それらは、属人的な作業となっていた。しかし、近年のICT技術の進展に伴って、コンピュータを利用して、製造条件の選定、調整または変更を支援する技術の開発が進められ、属人的な作業の側面が解消されつつある。

【0004】

特許文献1は、実績データベースに格納された過去の製造条件と予測対象の製造条件との類似度を算出し、類似度を用いて予測モデルを生成し、予測モデルを用いて鋼材の材質を予測する材質予測装置を開示している。この材質予測装置において、類似度で重み付けした評価関数が、予測モデルの予測誤差を評価するために用いられる。予測された鋼材の材質に基づいて鋼材の製造条件が制御される。

【0005】

特許文献2は、過去に製造した製造条件及びその製造条件から得られた品質特性値を格納した品質データベース内のデータに基づいて、要求の品質特性値を満足する、設計者が選択した製造条件以外の製造条件を算出する設計支援装置を開示している。この設計支援装置は、設計者が選択した製造条件と、その条件以外の条件とが要求の品質特性値に及ぼす影響度合いを示す影響係数を、品質データベースに格納された製造条件の近傍データから算出する。

【先行技術文献】

【特許文献】

【0006】

【特許文献1】特開2014-38595号公報

【特許文献2】特許第4623020号

【発明の概要】

【発明が解決しようとする課題】

【0007】

特許文献1に記載の鋼材の材質を予測する方法及び特許文献2に記載の影響係数を算出する方法によれば、いずれも、得られる予測値や影響係数の算出結果は、過去の製造実績の範囲内ではない。したがって、その範囲にない解を得ることが困難となる。

【0008】

本発明は、上記の課題に鑑みてなされたものであり、その目的は、過去の製造実績における製造条件の範囲内のみならずその範囲外においても、合金材料の特性を予測する予測モデルの精度を向上させ、かつ、その予測モデルを利用して、目標とする特性の設計範囲（または規格範囲）を満足する製造条件を選定することが可能となる製造支援システム、予測モデルを生成する方法及びコンピュータプログラムを提供することにある。

【課題を解決するための手段】

【0009】

本開示の製造支援システムは、非限定的で例示的な実施形態において、複数の製造プロセスを経て製造される合金材料の少なくとも1つの特性を予測するシステムであって、プロセッサと、前記プロセッサの動作を制御するプログラムを記憶するメモリと、それぞれが、各種の製造プロセスの製造条件を表す複数の製造パラメータ、および、前記製造プロセスの製造条件下で製造された合金材料の前記少なくとも1つの特性の実測値を含むデータを記憶した記憶装置と、を備え、前記プロセッサは、前記プログラムに従って、前記記憶装置にアクセスし、前記複数の製造パラメータおよび前記少なくとも1つの特性の実測値を取得し、前記複数の製造パラメータに含まれる第1製造パラメータと、前記少なくとも1つの特性の目標値である目標予測値の概算値を表す特性のプレ予測値との関係を記述するプレ予測値演算式を取得し、前記プレ予測値演算式を用いて、前記第1製造パラメータに基づいて前記プレ予測値を算出し、算出した前記プレ予測値と、前記プレ予測値に対応する前記少なくとも1つの特性の実測値との差分を算出し、前記複数の製造パラメータに含まれる、前記第1製造パラメータとは異なる第2製造パラメータ、および、算出した前記差分を含む学習データセットを用いてモデルを訓練し、前記少なくとも1つの特性を予測するために用いる学習済みモデルを生成する。

10

20

30

40

50

【 0 0 1 0 】

本開示の方法は、非限定的で例示的な実施形態において、複数の製造プロセスを経て製造される合金材料の少なくとも1つの特性を予測するために用いる予測モデルを生成する方法であって、それぞれが、各種の製造プロセスの製造条件を表す複数の製造パラメータ、および、前記製造プロセスの製造条件下で製造された合金材料の前記少なくとも1つの特性の実測値を含むデータにアクセスして、前記複数の製造パラメータおよび前記少なくとも1つの特性の実測値を取得し、前記複数の製造パラメータに含まれる第1製造パラメータと、前記少なくとも1つの特性の目標値である目標予測値の概算値を表す特性のプレ予測値と、の関係性を記述するプレ予測値演算式を取得し、前記プレ予測値演算式を用いて、前記第1製造パラメータに基づいて前記プレ予測値を算出し、算出した前記プレ予測値と、前記プレ予測値に対応する前記少なくとも1つの特性の実測値との差分を算出し、前記複数の製造パラメータに含まれる、前記第1製造パラメータとは異なる第2製造パラメータ、および、前記差分を含む学習データセットを用いてモデルを訓練し、前記予測モデルを生成することを包含する。

10

【 0 0 1 1 】

本開示のコンピュータプログラムは、非限定的で例示的な実施形態において、複数の製造プロセスを経て製造される合金材料の少なくとも1つの特性を予測するために用いる予測モデルを生成することをコンピュータに実行させるコンピュータプログラムであって、前記コンピュータに、それぞれが、各種の製造プロセスの製造条件を表す複数の製造パラメータ、および、前記製造プロセスの製造条件下で製造された合金材料の前記少なくとも1つの特性の実測値を含むデータにアクセスして、前記複数の製造パラメータおよび前記少なくとも1つの特性の実測値を取得することと、前記複数の製造パラメータに含まれる第1製造パラメータと、前記少なくとも1つの特性の目標値である目標予測値の概算値を表す特性のプレ予測値と、の関係性を記述するプレ予測値演算式を取得することと、前記プレ予測値演算式を用いて、前記第1製造パラメータに基づいて前記プレ予測値を算出することと、算出した前記プレ予測値と、前記プレ予測値に対応する前記少なくとも1つの特性の実測値との差分を算出することと、前記複数の製造パラメータに含まれる、前記第1製造パラメータとは異なる第2製造パラメータ、および、前記差分を含む学習データセットを用いてモデルを訓練し、前記予測モデルを生成することと、を実行させる。

20

【 発明の効果 】

30

【 0 0 1 2 】

本開示の例示的な実施形態は、過去の製造実績における製造条件の範囲内のみならずその範囲外においても、合金材料の特性を予測する予測モデルの精度を向上させ、かつ、その予測モデルを利用して、目標とする特性の設計範囲を満足する製造条件を選定することが可能となる製造支援システム、予測モデルを生成する方法及びコンピュータプログラムを提供する。

【 図面の簡単な説明 】

【 0 0 1 3 】

【 図 1 】 図 1 は、本開示の実施形態に係る、合金材料の特性を予測する製造支援システムの概略構成を例示するブロック図である。

40

【 図 2 】 図 2 は、データ処理装置のハードウェア構成例を示すブロック図である。

【 図 3 】 図 3 は、膨大なデータを格納したデータベースを有するクラウドサーバーの構成例を示すハードウェアブロック図である。

【 図 4 】 図 4 は、質別記号が T 4 で表されるアルミ合金の製造プロセスを含む一般的な製造フローを例示するフローチャートである。

【 図 5 】 図 5 は、プロセッサが処理するシステムの機能を機能ブロック単位で示す機能ブロック図である。

【 図 6 】 図 6 は、アルミ合金の力学特性を予測する予測モデルを生成する処理手順を例示するフローチャートである。

【 図 7 】 図 7 は、ニューラルネットワークの構成例を示す図である。

50

【図 8】図 8 は、第 1 の実装例による処理手順を示すフローチャートである。

【図 9】図 9 は、第 2 の実装例による処理手順を示すフローチャートである。

【図 10】図 10 は、第 3 の実装例による処理手順を示すフローチャートである。

【図 11】図 11 は、熱処理時間と、引張強さの目標予測値との関係を例示するグラフである。

【図 12 A】図 12 A は、引張強さの予測精度の評価結果を示すグラフである。

【図 12 B】図 12 B は、降伏応力の予測精度の評価結果を示すグラフである。

【発明を実施するための形態】

【0014】

材料の製造メーカーは、例えば、JIS規格に従って、材料を分類し、それぞれについて試験データを蓄積している。例えばアルミニウム合金（以降、「アルミ合金」と表記する。）は、例えばJIS規格の材質記号に基づいて、A1000系、A2000系、A3000系、A4000系、A5000系、A6000系、A7000系に分類される。また、各アルミ合金について、例えばJIS規格に準拠した引張試験が行われ、応力-ひずみ曲線などの試験データが蓄積されている。 10

【0015】

それぞれの合金系統は、引張強さ、耐力、伸びなど力学特性（「機械特性」とも称される。）を示すことが知られている。しかしながら、個別の製品の力学特性は、アルミ合金の組成が同じであっても、製造プロセスや製造条件（例えば、熱処理の温度、速度または時間）によって異なり得る。このように数多く存在する製品の中から、求められる特性等（力学特性だけでなく、コストや供給安定性、製品寿命などを含む。）が最適な製品を効率的に選択することは容易ではない。このような問題は、アルミ合金に限られず、他の合金材料、または高分子材料など、さまざまな材料についても存在している。 20

【0016】

アルミ合金などの合金材料は、多種のプロセスを含む複数の製造プロセスを経て製造される。例えば、熱処理系のアルミ合金の板材（アルミニウム板材）は、鋳造、均質化、熱間圧延、冷間圧延、焼きなましなど種々の製造プロセスを経て製造される。季節変動によって気温などの外乱条件がばらつくために、このような工程を経て製造されるアルミニウム板材に対し求められるアルミ合金の最適な力学特性を得るためには、例えば、焼きなまし工程における製造条件の選定や調整が必要とされる。合金材料の力学特性は冶金的または経験的な予測式に基づいて予測され、その予測式に基づいて製造条件の選定や調整が行われてきた。 30

【0017】

本発明者の検討によれば、予測式に用いる各種パラメータの調整が属人的である点や、その調整に労力や手間がかかる点が大きな課題である。製造条件と力学特性との関係は、深層学習に代表される機械学習または統計モデルを活用して学習することが可能である。しかし、実際の製造現場では、規格外れの不良品を客先に提供することを防止する観点から、要求される力学特性の範囲を満足するように、つまり、力学特性を安定させるように製造条件の制御が行われている。結果として、データベースに蓄積されるデータに偏りが生じてしまう。また、このような制御において、力学特性が変動した後に製造条件を変更しなければならぬ。そのために、力学特性の規格範囲を満足する製造条件を検索した場合、予期せぬ検索結果が得られ、予測される力学特性が規格値から大きく外れる可能性がある。このように、製造条件と力学特性との関係を正しく学習できないという課題がある。これは、いわゆる機械学習モデルを用いる場合に生じ得る内挿・外挿の問題に起因する。 40

【0018】

このような課題に鑑み、本願発明者は、機械学習と理論式とを組み合わせることにより、製造条件から合金材料の特性を予測するモデルを構築し、そのモデルを利用して、機械学習では学習できない範囲、つまり、外挿においても特性の規格範囲を満足する製造条件を選定することが可能な新規な手法を考案するに至った。 50

【 0 0 1 9 】

以下、添付の図面を参照しながら、本開示による、合金材料の特性を予測する製造支援システム、予測方法および予測モデルを生成する方法を詳細に説明する。但し、必要以上に詳細な説明は省略する場合がある。例えば、既によく知られた事項の詳細説明および実質的に同一の構成または処理に対する重複説明を省略する場合がある。これは、以下の説明が不必要に冗長になるのを避け、当業者の理解を容易にするためである。また、実質的に同一の構成または処理に同一の参照符号を付す場合がある。

【 0 0 2 0 】

以下の実施形態は例示であり、本開示による合金材料の特性を予測する製造支援システム、予測方法および予測モデルを生成する方法は、以下の実施形態に限定されない。例えば、以下の実施形態で示される数値、形状、材料、ステップ、そのステップの順序などは、あくまでも一例であり、技術的に矛盾が生じない限りにおいて種々の改変が可能である。また、技術的に矛盾が生じない限りにおいて、一の態様と他の態様とを組み合わせることが可能である。

10

【 0 0 2 1 】

図 1 は、本実施形態に係る、合金材料の特性を予測する製造支援システム 1 0 0 0 の概略構成を例示するブロック図である。製造支援システム（以降、簡単に「システム」と表記する。）1 0 0 0 は、データベース 1 0 0 と、データ処理装置 2 0 0 とを備える。本実施形態において、データベース 1 0 0 は、それぞれが、各種の製造プロセスの製造条件を表す複数の製造パラメータ、および、製造プロセスの製造条件下で製造された合金材料の少なくとも 1 つの特性の実測値を含むデータ群を格納する。

20

【 0 0 2 2 】

本実施形態において、合金材料はアルミ合金である。システム 1 0 0 0 は、アルミ合金の特性を予測したり、求められる特性の規格範囲を満足する製造条件を選定したりすることが可能である。ただし、システム 1 0 0 0 は、アルミ合金以外の種々の合金材料の製造を支援するシステムとして利用され得る。以下、求められる特性の規格範囲を満足する製造条件を「最適な製造条件」と記載する。

【 0 0 2 3 】

合金材料の特性の例は力学特性である。合金材料の特性に、電気的特性、熱的特性、磁気的特性、光学的特性などが含まれ得る。本実施形態において、アルミ合金の特性は、例えば降伏応力 $Y S$ 、耐力、引張強さ $T S$ 、伸び $E L$ 、弾性係数（ヤング率）、ポアソン比または $Y S / T S$ 比（降伏比）などの力学特性である。このような力学特性は、例えば、規格に準拠した引張試験によって得られる応力 - ひずみ曲線に基づいて得られる。応力 - ひずみ曲線は、材料の組成や製造プロセス、製造条件、試験条件などによって異なる形状を示す。

30

【 0 0 2 4 】

材料の製造メーカーは、例えば、J I S 規格に従って、材料を分類し、それぞれについて試験データを蓄積している。アルミ合金は、例えば J I S 規格の材質記号に基づいて、A 1 0 0 0 系、A 2 0 0 0 系、A 3 0 0 0 系、A 4 0 0 0 系、A 5 0 0 0 系、A 6 0 0 0 系、A 7 0 0 0 系に分類される。また、各アルミ合金について、例えば J I S 規格に準拠した引張試験が行われ、応力 - ひずみ曲線などの試験データが蓄積されている。

40

【 0 0 2 5 】

材料の製造メーカーは、例えば数年、1 0 年、2 0 年またはそれ以上の長い年月の間、製造の段階で取得された膨大な時系列プロセスデータをデータベース 1 0 0 に蓄積し得る。時系列プロセスデータは、設計・開発の情報や、熱処理の温度、速度または時間、製造時の気候データなどの製造条件、試験データ 7 0 0 などに関連付けられてデータベース 1 0 0 に蓄積され得る。このようなデータ群はビックデータと称される。

【 0 0 2 6 】

本実施形態において、複数の製造プロセスは、原料配合工程、溶解工程、鋳造工程、均質化工程、熱間圧延工程、熱間押出工程、熱間鍛造工程、冷間圧延工程、箔圧延工程、矯

50

正工程、溶体化工程、焼きなまし工程、時効工程のうちの少なくとも1つを含み得る。

【0027】

本実施形態において、複数の製造プロセスにおいて用いる複数の製造条件は、例えば、アルミ合金の種類、Si量、Mg量、Cu量、Fe量、熱延巻取温度()、冷延巻取温度()、熱処理温度()、熱処理時間(秒)、熱処理後における巻取温度()、熱処理時における板材の板幅(mm)、熱処理時における板厚(mm)、熱処理後におけるコイルの重量(kg重)、熱処理後における自然時効日数(日)、自然時効時における気候データを含む。本明細書において、これらを、各製造プロセスの製造条件を表す「製造パラメータ」と記載する。複数の製造パラメータのうち、熱処理時間、巻取温度は、それぞれ、熱処理炉における熱処理時間、巻取温度を意味する。熱処理を行うための設備として、例えば、連続焼鈍ライン(CAL)が用いられ得る。熱処理温度は、熱処理炉の設定温度であってもよいし、熱処理中の板材を計測することにより得られる温度であってもよい。

10

【0028】

本実施形態において、上述した複数の製造パラメータのうち、熱処理温度を「第1製造パラメータ」と記載し、熱処理温度以外のものを「第2製造パラメータ」と記載する。第1製造パラメータと第2製造パラメータの詳細については後述する。

【0029】

アルミ合金の種類は、熱処理合金と非熱処理合金とに大別される。アルミ合金の種類は、例えばJIS規格の材質記号、合金記号、または質別記号に基づいて分類され得る。例えば、アルミ合金の種類は、質別記号に基づいて、溶体化処理後に冷間加工を行い、さらに自然時効させたもの(T3)、または、溶体化処理後に自然時効させたもの(T4)などに分類され得る。

20

【0030】

気候データは、気温、湿度、日照時間、降水量などを含む。例えば、これらの気候データは、気象庁が発表する、製造工場がある地域の気象情報に基づいて取得することができ、1日の平均気温や、1日の平均湿度、1週間の平均気温、1週間の平均湿度、1週間の平均降水量、1週間の平均日照時間などであり得る。

【0031】

データベース100は、例えば、アルミ合金の種類、上述した複数の製造パラメータに、降伏応力YS、耐力、引張強さTS、伸びEL、弾性係数、ポアソン比またはYS/TS比などの力学特性を関連付けしたデータ群を格納することができる。データベース100は、半導体メモリ、磁気記憶装置または光学記憶装置などの記憶装置である。

30

【0032】

データ処理装置200は、データベース100に蓄積された膨大なデータにアクセスして、複数の製造パラメータ、および、それらに関連付けされた少なくとも1つの力学特性の実測値を取得することができる。

【0033】

データ処理装置200は、データ処理装置の本体201および表示装置220を備える。例えば、データベース100に蓄積されたデータを活用してアルミ合金の力学特性を予測する予測モデルを生成するために利用されるソフトウェア(またはファームウェア)、および、学習済み予測モデルを利用して、最適な製造条件を選定するためのソフトウェアが、データ処理装置の本体201に実装されている。そのようなソフトウェアは、例えば光ディスクなどの、コンピュータが読み取り可能な記録媒体に記録され、パッケージソフトウェアとして販売され、または、インターネットを介して提供され得る。

40

【0034】

表示装置220は、例えば液晶ディスプレイまたは有機ELディスプレイである。表示装置220は、例えば、本体201から出力される出力データに基づいてアルミ合金の力学特性の予測値および/または最適な製造条件を表示することができる。

【0035】

50

データ処理装置 200 の典型例は、パーソナルコンピュータである。または、データ処理装置 200 は、製造支援システムとして機能する専用の装置であり得る。

【0036】

図 2 は、データ処理装置 200 のハードウェア構成例を示すブロック図である。データ処理装置 200 は、入力装置 210、表示装置 220、通信 I/F 230、記憶装置 240、プロセッサ 250、ROM (Read Only Memory) 260 および RAM (Random Access Memory) 270 を備える。これらの構成要素は、バス 280 を介して相互に通信可能に接続される。

【0037】

入力装置 210 は、ユーザからの指示をデータに変換してコンピュータに入力するための装置である。入力装置 210 は、例えばキーボード、マウスまたはタッチパネルである。

10

【0038】

通信 I/F 230 は、データ処理装置 200 とデータベース 100 との間でデータ通信を行うためのインタフェースである。データが転送可能であればその形態、プロトコルは限定されない。例えば、通信 I/F 230 は、USB、IEEE 1394 (登録商標)、またはイーサネット (登録商標) などに準拠した有線通信を行うことができる。通信 I/F 230 は、Bluetooth (登録商標) 規格および/または Wi-Fi 規格に準拠した無線通信を行うことができる。いずれの規格も、2.4 GHz 帯または 5.0 GHz 帯の周波数を利用した無線通信規格を含む。

20

【0039】

記憶装置 240 は、例えば磁気記憶装置、光学記憶装置、半導体記憶装置またはそれらの組み合わせである。光学記憶装置の例は、光ディスクドライブまたは光磁気ディスク (MD) ドライブなどである。磁気記憶装置の例は、ハードディスクドライブ (HDD)、フロッピーディスク (FD) ドライブまたは磁気テープレコーダである。半導体記憶装置の例は、ソリッドステートドライブ (SSD) である。

【0040】

プロセッサ 250 は、半導体集積回路であり、中央演算処理装置 (CPU) またはマイクロプロセッサとも称される。プロセッサ 250 は、予測モデルを訓練したり、学習済みモデルを活用したりするための命令群を記述した、ROM 260 に格納されたコンピュータプログラムを逐次実行し、所望の処理を実現する。

30

【0041】

データ処理装置 200 は、プロセッサ 250 に加えてまたは代えて、CPU を搭載した FPGA (Field Programmable Gate Array)、GPU (Graphics Processing Unit)、ASIC (Application Specific Integrated Circuit)、ASSP (Application Specific Standard Product)、または、これら回路の中から選択される 2 つ以上の回路の組み合わせを備え得る。

【0042】

ROM 260 は、例えば、書き込み可能なメモリ (例えば PROM)、書き換え可能なメモリ (例えばフラッシュメモリ)、または読み出し専用のメモリである。ROM 260 は、プロセッサの動作を制御するプログラムを記憶している。ROM 260 は、単一の記録媒体である必要はなく、複数の記録媒体の集合であり得る。複数の集合体の一部は取り外し可能なメモリであってもよい。

40

【0043】

RAM 270 は、ROM 260 に格納された制御プログラムをブート時に一旦展開するための作業領域を提供する。RAM 270 は、単一の記録媒体である必要はなく、複数の記録媒体の集合であり得る。

【0044】

以下、本開示のシステム 1000 の代表的な構成例を幾つか説明する。

【0045】

50

第1の構成例において、システム1000は、図1に示すデータベース100およびデータ処理装置200を備える。データベース100は、データ処理装置200とは異なる別のハードウェアである。または、膨大なデータを記憶した光ディスクなどの記憶媒体をデータ処理装置200の本体201に読み込むことによって、データベース100の代わりに記憶媒体にアクセスして膨大なデータを読み出すことが可能となる。

【0046】

第2の構成例において、システム1000はデータ処理装置200の単体である。その場合、膨大な試験データ700は、HDDなど記憶装置240に予め格納されている。この構成例において、データ処理装置200の例は、ラップトップPC、タブレット端末、スマートフォンなどであり得る。

10

【0047】

図3は、膨大なデータを格納したデータベース340を有するクラウドサーバー300の構成例を示すハードウェアブロック図である。

【0048】

第3の構成例におけるある一態様において、システム1000は、図3に示すように、1または複数のデータ処理装置200およびクラウドサーバー300のデータベース340を備える。クラウドサーバー300は、プロセッサ310、メモリ320、通信I/F330およびデータベース340を有する。膨大なデータは、クラウドサーバー300上のデータベース340に格納され得る。例えば、複数のデータ処理装置200は、社内に構築されたローカルエリアネットワーク(LAN)400を介して接続され得る。ローカルエリアネットワーク400は、インターネットプロバイダサービス(IPS)を介してインターネット500に接続される。個々のデータ処理装置200は、インターネット500を経由してクラウドサーバー300のデータベース340にアクセス可能である。

20

【0049】

他の一態様において、システム1000は、1または複数のデータ処理装置200およびクラウドサーバー300を備え得る。その場合、データ処理装置200が備えるプロセッサ250に代えて、あるいはプロセッサ250と協働して、クラウドサーバー300が備えるプロセッサ310は、予測モデルを訓練したり、学習済みモデルを活用したりするための命令群を記述したコンピュータプログラムを逐次実行することができる。または、例えば、同一のLAN400に接続された複数のデータ処理装置200が、そのような命令群を記述したコンピュータプログラムを協働して実行してもよい。このように複数のプロセッサに分散処理をさせることにより、個々のプロセッサに対する演算負荷を低減することが可能となる。

30

【0050】

図4は、質別記号がT4で表されるアルミ合金の製造プロセスを含む一般的な製造フローを例示する。図示される例において、複数の製造プロセスは、鑄造工程、均質化工程、熱間圧延工程、冷間圧延工程、焼きなまし工程および自然時効工程を含む。本実施形態において、これらの工程のうちの、鑄造工程から冷間圧延工程までの製造プロセスを上工程と呼び、焼きなまし工程および自然時効工程を含む製造プロセスを下工程と呼んで両者を区別する。下工程における焼きなまし工程は、例えば連続焼鈍ラインを用いて実施される。

40

【0051】

本実施形態におけるアルミ合金は、例えば、図4に例示されるT4製造フローに従って製造されるA6000系合金である。上述した複数の製造パラメータごとの、降伏応力YS、引張強さTS、伸びELなどの力学特性の実測値が製造実績としてデータベース100に蓄積されている。

【0052】

図5は、プロセッサ250が処理するシステム1000の機能を機能ブロック単位で示す機能ブロック図である。図6は、アルミ合金の力学特性を予測する予測モデルを生成する処理手順を例示するフローチャートである。

50

【 0 0 5 3 】

プロセッサ 2 5 0 は、入力ユニット 2 5 1、プレ予測値演算ユニット 2 5 2、差分演算ユニット 2 5 3、予測モデルユニット 2 5 4、目標予測値演算ユニット 2 5 5 および出力ユニット 2 5 6 を有する。なお、説明の便宜上、各機能ブロック名に「ユニット」を付記し、例えばプレ予測値演算のブロックをプレ予測値演算ユニット 2 5 2 と表記する。典型的には、それぞれのユニットに相当する機能ブロックの処理（またはタスク）は、ソフトウェアのモジュール単位でコンピュータプログラムに記述される。ただし、F P G A などを用いる場合、これらの機能ブロックの全部または一部は、ハードウェア・アクセラレータとして実装され得る。

【 0 0 5 4 】

入力ユニット 2 5 1 は、データベース 1 0 0 にアクセスし、入力変数として、複数の製造パラメータおよび少なくとも 1 つの力学特性の実測値を取得する（ステップ S 1 1 0）。力学特性の実測値は、当該製造プロセスの製造条件下で製造されたアルミ合金の引張試験から得られたものである。図示される例において、入力ユニット 2 5 1 は、過去の製造実績から得られた、上述した第 2 製造パラメータを、入力変数として取得する。

【 0 0 5 5 】

入力ユニット 2 5 1 は、入力変数として、作業員または開発者などのユーザによって選択され得るプレ予測値演算式を取得する（ステップ S 1 2 0）。プレ予測値演算式は、過去の製造実績からは得られなかったデータ未取得の領域における力学特性を、材料工学の冶金的理論式または経験式を用いて予測するための数式を含み、製造現場のノウハウを形式知化したものである。製造を重ねるごとに、冶金的理論式または経験式は蓄積され得る。ユーザは、予測モデルを生成するときに、蓄積された複数の冶金的理論式または経験式の中から、プレ予測値演算式として 1 つを選択し、システム 1 0 0 0 に入力することができる。または、プレ予測値演算式として、ユーザによる選択性を有しない所定の関数を用いてもよい。

【 0 0 5 6 】

入力ユニット 2 5 1 は、さらに、入力変数として、力学特性である引張強さ T S の実測値を取得する。入力ユニット 2 5 1 は、入力変数として、降伏応力 Y S、伸び E L および耐力のうちの少なくとも 1 つの実測値をさらに取得してもよい。以降、引張強さ、降伏応力、耐力および伸びを、それぞれ、T S、Y S、Y S _ 2 および E L と表記する。

【 0 0 5 7 】

入力ユニット 2 5 1 は、データベース 1 0 0 にアクセスし、過去の複数回の製造プロセスから得られた複数のデータセットを取得する。各データセットは、鑄造工程から自然時効工程までの一連の工程を意味する 1 コイル（または 1 ロット）単位ごとに取得される複数の製造パラメータを含む。各データセットは、さらに、コイル毎に測定して得られた T S の実測値を含む。入力ユニット 2 5 1 は、例えば 1 0 0 0 コイル分のデータセットを取得する。

【 0 0 5 8 】

プレ予測値演算ユニット 2 5 2 は、プレ予測値演算式を用いて、第 1 製造パラメータに基づいてプレ予測値を算出する（ステップ S 1 3 0）。プレ予測値演算式は、入力ユニット 2 5 1 が取得した複数の製造パラメータに含まれる第 1 製造パラメータと、力学特性のプレ予測値との関係を記述する。プレ予測値は、力学特性の目標値である目標予測値の概算値を表す。本実施形態において、第 1 製造パラメータは熱処理時間 H T である。T S のプレ予測値 P _ P T S は、T S の目標値である目標予測値 T _ P T S の概算値を表す。プレ予測値演算式は、熱処理時間 H T と T S のプレ予測値 P _ P T S との関係を記述する。

【 0 0 5 9 】

本実施形態において、プレ予測値演算式は、第 1 製造パラメータである熱処理時間 H T に基づく変数の 2 次式で与えられる。ただし、プレ予測値演算式は 2 次式に限定されず、1 次式または 3 次式以上の数式で表され得る。以下に、熱処理系のアルミ合金の場合に利用し得るプレ予測値演算式のモデル例が示される。この例におけるプレ予測値演算式は数

10

20

30

40

50

1 の数式で表される。

[数 1]

$$P_PTS = -206.85HT^2 + 544.63HT - 122.61$$

【 0 0 6 0 】

差分演算ユニット 2 5 3 は、プレ予測値演算ユニット 2 5 2 が算出したプレ予測値と、プレ予測値に対応する少なくとも 1 つの特性の実測値との差分を算出する（ステップ S 1 4 0）。本実施形態において、差分演算ユニット 2 5 3 は、プレ予測値 P_PTS と、プレ予測値 P_PTS に対応する TS の実測値との差分 TS を算出する。差分 TS は、製造実績における TS の実測値と、製造実績における製造条件に基づいてプレ予測値演算式を用いて予測した予測結果である TS の予測値の概算値との差を表す。

10

【 0 0 6 1 】

予測モデルユニット 2 5 4 は、複数の製造パラメータに含まれる、第 1 製造パラメータとは異なる第 2 製造パラメータ、および、差分演算ユニット 2 5 3 が算出した差分 TS を含む学習データセット（または訓練データ）を用いて予測モデルを訓練する（ステップ S 1 5 0）。本実施形態において、第 2 製造パラメータは気候データを含む。気候データの例は、製造実績における過去の平均気温である。

【 0 0 6 2 】

本実施形態において、学習データセットは、入力ユニット 2 5 1 に入力される複数の製造パラメータのうちの、プレ予測値演算ユニット 2 5 2 に入力される入力変数に主として寄与する第 1 製造パラメータを含まず、第 1 製造パラメータとは異なる第 2 製造パラメータを含む。本実施形態の第 1 製造パラメータは熱処理時間 HT である。つまり、学習データセットは熱処理時間 HT を含まない。

20

【 0 0 6 3 】

本実施形態において、予測モデルユニット 2 5 4 は、教師あり予測モデルであり、ニューラルネットワーク（ NN ）で構築される。ニューラルネットワークの例は多層パーセプトロン（ MLP ）である。 MLP は順伝播型ニューラルネットワークとも称される。ただし、教師あり予測モデルはニューラルネットワークに限定されず、例えばサポートベクターマシンまたはランダムフォレストなどであってもよい。

【 0 0 6 4 】

図 7 は、ニューラルネットワークの構成例を示す図である。図示されるニューラルネットワークは、第 1 層である入力層から第 N 層（最終層）である出力層までの N 層から構成される MLP である。 N 層のうちの第 2 層から第 $N - 1$ 層までが中間層（「隠れ層」とも称される。）である。入力層を構成するユニット（「ノード」とも称される。）の数は、入力データである特徴量の次元数と同じ n 個である。本実施形態において、入力層は、学習データセットに含まれる 6 つの製造パラメータに対応する 6 個のユニットから構成される。出力層は 4 個のユニットから構成される。本実施形態において、中間層の数は 3 個であり、ユニットの総数は 3 0 0 個である。

30

【 0 0 6 5 】

MLP において情報が入力側から出力側に一方向に伝播する。1 つのユニットは複数の入力を受け取り、1 つの出力を計算する。複数の入力を $[x_1, x_2, x_3, \dots, x_i]$ (i は 2 以上の整数) とすると、ユニットへの総入力 u は、それぞれの入力 x に異なる重み w を掛けて加算し、これにバイアス b を加算した数 2 の数式で与えられる。ここで、 $[w_1, w_2, w_3, \dots, w_i]$ は各入力に対する重みである。ユニットの出力 z は、総入力 u に対する活性化関数と呼ばれる数 3 の数式の関数 f の出力で与えられる。活性化関数は、一般的には単調増加する非線形関数である。活性化関数の例は、ロジスティックシグモイド関数であり、数 4 の数式で与えられる。数 4 における e はネイピア数である。

40

[数 2]

$$u = x_1 w_1 + x_2 w_2 + x_3 w_3 + \dots + x_i w_i + b$$

[数 3]

50

$$z = f(u)$$

[数4]

$$f(u) = 1 / (1 + e^{-u})$$

【0066】

各層に含まれる全ユニット同士が層間で結合される。これにより左側の層のユニットの出力が右側の層のユニットの入力になり、この結合を通じて信号が右の層から左の層に一方方向に伝播する。重み w およびバイアス b のパラメータを最適化しながら各層の出力を順番に決定していくことで、出力層の最終的な出力が得られる。

【0067】

学習データセットは、さらに、差分演算ユニット 253 から出力される差分 TS を含む。差分 TS は教師データとして利用される。ニューラルネットワークにおける出力層の出力が差分 TS に近づくように、損失関数（二乗誤差）に基づいて重み w およびバイアス b のパラメータが最適化される。本実施形態において、エポック数は 1000 回程度である。予測モデルは、数5の数式で表すことができる。ニューラルネットワークの入力変数である、上述した第2製造パラメータは説明変数であり、製造実績におけるデータ範囲にある。ニューラルネットワークの出力は目的変数である。Adamなどの最適化アルゴリズムを用いて、予測モデルを最適化することが好ましい。

[数5]

$$\text{出力(補正值 } CV) = NN(\text{第2製造パラメータ})$$

【0068】

予測モデルを訓練した結果、学習済みモデルが生成される。予測モデルユニット 254 は、第2製造パラメータである平均気温を含む入力変数を学習済みモデルに入力し、目標予測値 T_PTS とプレ予測値 P_PTS との差分 PTS を補正するための補正值 CV を取得する（ステップ S160）。学習済みモデルに入力する入力変数は、製造実績におけるデータ範囲において、平均気温以外の他の製造パラメータ（例えば巻取温度、自然時効日数）を含み得る。

【0069】

補正值 CV は、製造実績における過去の製造条件に基づいて予測される TS の予測値の概算値（プレ予測値 P_PTS ）と、目標予測値 T_PTS との差分である。補正值 CV は目標予測値 T_PTS の推定誤差を示す。

【0070】

TS と同様に、予測モデルユニット 254 は、 YS の目標値である目標予測値 T_PYS とプレ予測値 P_PTS との差分 PYS を補正するための補正值 CV 、 EL の目標値である目標予測値 T_PEL とプレ予測値 P_PTS との差分 PEL を補正するための補正值 CV 、および、 YS_2 の目標値である目標予測値 T_PYS_2 とプレ予測値 P_PTS との差分 PYS_2 を補正するための補正值 CV を取得する。これらの4つの補正值 CV は、それぞれ、ニューラルネットワークにおける出力層の4つの出力から出力される。

【0071】

YS のための補正值 CV は目標予測値 T_PYS の推定誤差を示す。 EL のための補正值 CV は目標予測値 T_PEL の推定誤差を示す。 YS_2 のための補正值 CV は目標予測値 T_PYS_2 の推定誤差を示す。

【0072】

目標予測値演算ユニット 255 は、プレ予測値、補正值および目標予測値の関係をモデル化した数式に基づいて、プレ予測値および補正值から目標予測値を算出する（ステップ S170）。この関係をモデル化した数式はプレ予測値 P_PTS の1次式で表され、例えば、数6から数9の数式で表される。数6は、プレ予測値 P_PTS 、 TS のための補正值 CV および目標予測値 T_PTS の関係をモデル化する。数7は、プレ予測値 P_PTS 、 YS のための補正值 CV および目標予測値 T_PYS の関係をモデル化する。数8は、プレ予測値 P_PEL 、 EL のための補正值 CV および目標予測値 T_PEL の関係を

10

20

30

40

50

モデル化する。数 9 は、プレ予測値 $P_P Y S_2$ 、 $Y S_2$ のための補正值 $C V$ および目標予測値 $T_P Y S_2$ の関係をモデル化する。

[数 6]

$$T_P T S = P_P T S + C V$$

[数 7]

$$T_P Y S = 0.40 * P_P T S + C V + 28$$

[数 8]

$$T_P E L = -0.065 * P_P T S + C V + 44$$

[数 9]

$$T_P Y S_2 = 0.42 * P_P T S + C V + 112$$

10

【 0 0 7 3 】

目標予測値演算ユニット 255 は、数 6 の数式に基づいて目標予測値 $T_P T S$ を算出する。目標予測値演算ユニット 255 は、数 7 の数式に基づいて目標予測値 $T_P Y S$ を算出する。目標予測値演算ユニット 255 は、数 8 の数式に基づいて目標予測値 $T_P E L$ を算出する。目標予測値演算ユニット 255 は、数 9 の数式に基づいて目標予測値 $T_P Y S_2$ を算出する。

【 0 0 7 4 】

出力ユニット 256 は、表示装置 220 の専用ドライバまたはコントローラ（不図示）に力学特性の予測値を出力して表示装置 220 に表示させることが可能である。例えば、算出した目標予測値 $T_P T S$ 、 $T_P Y S$ 、 $T_P E L$ 及び $T_P Y S_2$ が表示装置 220 に表示される。

20

【 0 0 7 5 】

このように、例えば、作業員や開発者は、製造支援システム 1000 を活用することで、製造実績における過去の製造条件から $T S$ 、 $Y S$ 、 $E L$ 、 $Y S_2$ などの力学特性を予測することが可能となる。

【 0 0 7 6 】

次に、学習済みモデルを利用して、最適な製造条件を選定する方法を説明する。上述した学習済みモデルを利用すれば、機械学習では学習できない範囲、つまり、外挿範囲において最適な製造条件を選定することが可能となる。

【 0 0 7 7 】

最適な製造条件の選定は、本実施形態による学習済みモデルを利用して、様々な処理手順（つまり、アルゴリズム）に従って行うことが可能である。以下、アルゴリズムの第 1 から第 3 の実装例を説明する。それらのアルゴリズムを記述した命令群を含むコンピュータプログラムは、例えば、インターネットを介して提供され得る。以下の説明において、それぞれの処理を実行する主体は、プロセッサ 250 を備えるデータ処理装置 200 とする。

30

【 0 0 7 8 】

[第 1 の実装例]

図 8 は、第 1 の実装例による処理手順を示すフローチャートである。

【 0 0 7 9 】

データ処理装置 200 は、目標とする力学特性の設計範囲を規定する少なくとも 1 つの入力設計パラメータを取得する（ステップ S 210）。例えば、作業員は、目標とする $T S$ の設計範囲または目標予測値 $T_P T S$ を規定する入力設計パラメータを、入力装置 210 を介してデータ処理装置 200 に入力することができる。データ処理装置 200 は、学習済みモデルに入力設計パラメータを入力して、設計範囲を満足する 1 または複数の製造条件を表す製造パラメータ群を出力することができる（ステップ S 220）。

40

【 0 0 8 0 】

本実装例によれば、学習済みモデルを利用して、目標とする力学特性の設計範囲を満足する製造パラメータ群を取得することが可能となる。例えば、目標とする $T S$ の設計範囲を規定する入力設計パラメータをデータ処理装置 200 に入力すれば、その設計範囲を満

50

足する熱処理時間および巻取温度の2つの製造条件を選定することができる。選定された熱処理時間および巻取温度は、選定結果として、例えばシステム1000の表示装置220に表示され得る。

【0081】

[第2の実装例]

図9は、第2の実装例による処理手順を示すフローチャートである。

【0082】

まず、データ処理装置200は、過去の製造過程から得られた1または複数の製造パラメータ、すなわち、製造実績における過去の製造条件を示す1または複数の製造パラメータを利用して予測モデルを訓練する(S310)。この処理は、上述したステップS150におけるモデルの訓練と同じである。 10

【0083】

次に、データ処理装置200は、目標とする力学特性の設計範囲を規定する少なくとも1つの入力設計パラメータを取得する(S320)。例えば、作業者は、目標とするTSの設計範囲または目標予測値T_PTSを規定する入力設計パラメータを、入力装置210を介してデータ処理装置200に入力することができる。

【0084】

次に、データ処理装置200は、現在の製造過程において、最初の製造プロセスから実施済みの中間製造プロセスまでに用いた1または複数の製造条件を表す製造パラメータ群のうち少なくとも1つと、入力設計パラメータとを学習済みモデルに入力する(ステップS330)。 20

【0085】

データ処理装置200は、中間製造プロセスよりも後に続く下工程の製造プロセスにおいて用いる、設計範囲を満足する1または複数の製造条件を表す下工程製造パラメータ群を取得する(ステップS340)。

【0086】

現在進行中のある製造過程において、図4に例示される、例えば、最初の製造プロセスである鑄造工程から中間製造プロセスである冷間圧延工程までの上工程が実施済みであったとする。その場合、データ処理装置200は、鑄造工程から冷間圧延工程までの製造実績における過去の製造条件を表す例えば気候データ(平均気温、平均湿度など)と、入力設計パラメータとを学習済みモデルに入力する。例えば、下工程製造パラメータ群は、焼きなまし工程における製造条件を表す製造パラメータを含み得る。データ処理装置200は、学習済みモデルの出力として、焼きなまし工程に用いる、TSの設計範囲を満足する熱処理時間、熱処理後における巻取温度の2つの製造パラメータを取得することができる。 30

【0087】

本実装例によれば、上工程において実施済みの製造プロセスの製造条件を制約条件とし、学習済みモデルを利用して、目標とする力学特性の設計範囲を満足する、下工程に用いる製造パラメータ群を取得することが可能となる。

【0088】

[第3の実装例]

図10は、第3の実装例による処理手順を示すフローチャートである。

【0089】

まず、データ処理装置200は、製造実績における過去の製造条件を示す1または複数の製造パラメータを利用して予測モデルを訓練する(S410)。この処理は、上述したステップS150におけるモデルの訓練と同じである。

【0090】

次に、データ処理装置200は、目標とする力学特性の設計範囲を規定する少なくとも1つの入力設計パラメータを取得する(S420)。例えば、作業者は、目標とするTSの設計範囲または目標予測値T_PTSを規定する入力設計パラメータを、入力装置210 40

0を介してデータ処理装置200に入力することができる。

【0091】

次に、データ処理装置200は、現在進行中の製造過程において、中間製造プロセスまでに用いた1または複数の製造条件を表す製造パラメータ群のうち少なくとも1つと、中間製造プロセスよりも後に続く下工程の製造プロセスにおいて用いる1または複数の製造条件の予測値を含む第1下工程製造パラメータ群と、入力設計パラメータとを学習済みモデルに入力する(ステップS430)。第2の実装例と同様に、現在進行中のある製造過程において、例えば鋳造工程から冷間圧延工程までの上工程が実施済みであったとする。その場合、例えば、データ処理装置200は、上工程の製造実績における製造条件を表す過去の気候データ(平均気温、平均湿度など)と、下工程の製造プロセスにおいて用いる未来の気候データ(平均気温、平均湿度など)の予測値と、入力設計パラメータとを学習済みモデルに入力する。

10

【0092】

データ処理装置200は、第1下工程製造パラメータ群が表す1または複数の製造条件とは異なる1または複数の製造条件を表す第2下工程製造パラメータ群であって、設計範囲を満足する第2下工程製造パラメータ群を取得する(ステップS440)。例えば、データ処理装置200は、学習済みモデルの出力として、気候データとは異なり、かつ、自然時効工程に用いる製造条件を表し、TSの設計範囲を満足する自然時効日数の製造パラメータを取得することができる。

【0093】

本実装例によれば、上工程および下工程において実施済みの製造プロセスの過去の製造条件を制約条件とし、学習済みモデルを利用して、目標とする力学特性の設計範囲を満足する、下工程の未実施の製造プロセスに用いる未来の製造パラメータ群を取得することが可能となる。

20

【0094】

図11は、熱処理時間と、目標予測値TPTSとの関係を例示するグラフである。縦軸は目標予測値TPTSを示し、横軸は熱処理時間を示す。図中において、機械学習のみを用いる従来手法によるシミュレーション結果が破線で示され、本実施形態に係る、機械学習と論理式とを組み合わせたハイブリッド手法によるシミュレーション結果が実線で示されている。本実施形態とは異なり、従来手法においては、機械学習時の訓練データに熱処理時間が含まれている点に留意されたい。

30

【0095】

従来手法を用いる場合、熱処理時間の変化量に対する目標予測値TPTSの変化量、つまり、グラフの傾きが小さい。これは、製造パラメータとして訓練データに熱処理時間を含め、TSの特性が、目標とする設計範囲に収まるように熱処理時間を調整していることに起因している。結果として、熱処理時間がその他の因子(製造条件)に与え得る影響が相殺されてしまうこととなる。そのため、従来手法を用いて最適な製造条件を検索すると、極端に大きいまたは小さい製造条件(規格外れの条件)がシステムから提案される可能性がある。

【0096】

本実施形態によるハイブリッド手法を用いる場合、従来手法と比べ、熱処理時間の変化量に対する目標予測値TPTSの変化量が大きい。これは、製造パラメータとして、訓練データの代わりに、論理式の入力変数に熱処理時間を含め、その他の因子に対する熱処理時間の影響を論理式に反映させているためである。その結果、熱処理時間とその他の因子とが互いに及ぼし合う影響を分離することができ、機械学習の範囲外、つまり、外挿範囲においても適切な製造条件を選定することが可能となる。

40

【0097】

特に、入力変数として平均気温などの気候データの予測値を用い、その予測値を学習済みモデルに入力することによって未来の適切な製造条件を選定することができる。そのため、システムが規格外れの条件を提案する可能性を低減することができる。その結果、熱

50

処理時間の小さな変更によって、目標とする設計範囲を満足する最適な製造条件を選定することが可能となる。

【 0 0 9 8 】

本願発明者は、本実施形態によるハイブリッド手法と従来手法との間で、材料特性の予測精度及び最適な製造条件の選定を、交差検証を行うことによって比較した。ここで、材料特性の予測精度は、学習済みモデルにおける内挿に関連し、最適な製造条件の選定は外挿に関連する。材料特性の予測精度は、両者で同程度であり、最適な製造条件の選定については、ハイブリッド手法が従来手法よりも優れていることがわかった。

【 0 0 9 9 】

さらに、本願発明者は、目標予測値と実測値とを比較することによって、材料特性の予測精度の吟味を行った。図 1 2 A、1 2 B は、本実施形態によるハイブリッド手法による材料特性の予測精度の評価結果を示すグラフである。図 1 2 A に、目標予測値 T_PTS と TS の実測値とを比較した結果が示され、図 1 2 B に、目標予測値 T_PYS と YS の実測値とを比較した結果が示されている。図中の縦軸は実測値を示し、横軸は目標予測値を示している。 TS 、 YS の決定係数 R^2 は、それぞれ、 0.61 、 0.66 となった。この結果、目標予測値 T_PTS 、 T_PYS はそれぞれ精度よく予測できていることがわかる。

10

【産業上の利用可能性】

【 0 1 0 0 】

本開示の技術は、製造条件から合金材料の特性を予測することに加え、材料特性の規格範囲を満足する製造条件を選定するために用いられる製造支援ツールにおいて広く用いられ得る。

20

【符号の説明】

【 0 1 0 1 】

- 1 0 0、3 4 0 : データベース
- 2 0 0 : データ処理装置
- 2 0 1 : 本体
- 2 1 0 : 入力装置
- 2 2 0 : 表示装置
- 2 3 0 : 通信 I / F
- 2 4 0 : 記憶装置
- 2 5 0 : プロセッサ
- 2 5 1 : 入力ユニット
- 2 5 2 : プレ予測値演算ユニット
- 2 5 3 : 差分演算ユニット
- 2 5 4 : 予測モデルユニット
- 2 5 5 : 目標予測値演算ユニット
- 2 5 6 : 出力ユニット
- 2 6 0 : ROM
- 2 7 0 : RAM
- 2 8 0 : バス
- 3 0 0 : クラウドサーバー
- 3 1 0 : プロセッサ
- 3 2 0 : メモリ
- 3 3 0 : 通信 I / F
- 4 0 0 : ローカルエリアネットワーク
- 5 0 0 : インターネット
- 1 0 0 0 : 製造支援システム (システム)


30

40


50

【 図 面 】

【 図 1 】




【 図 2 】

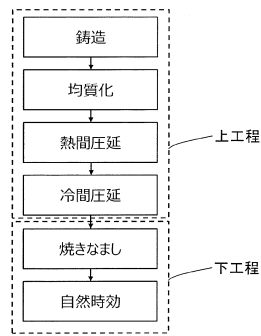


10

【 図 3 】



【 図 4 】




20

30

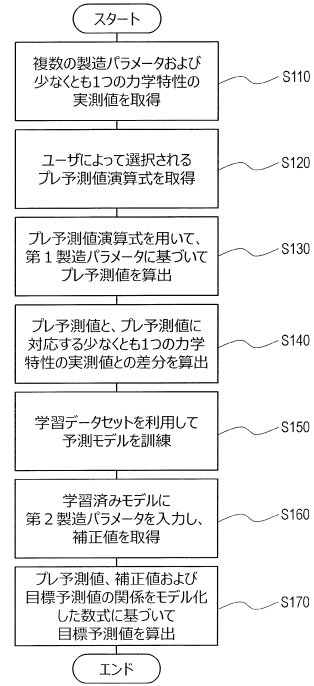
40

50

【 図 5 】




【 図 6 】



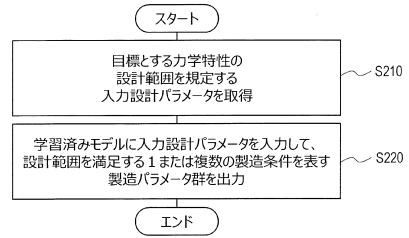
10

20

【 図 7 】



【 図 8 】

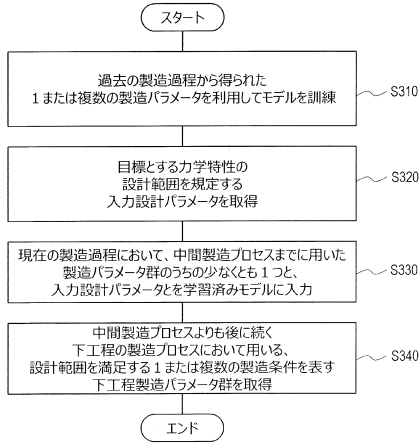


30

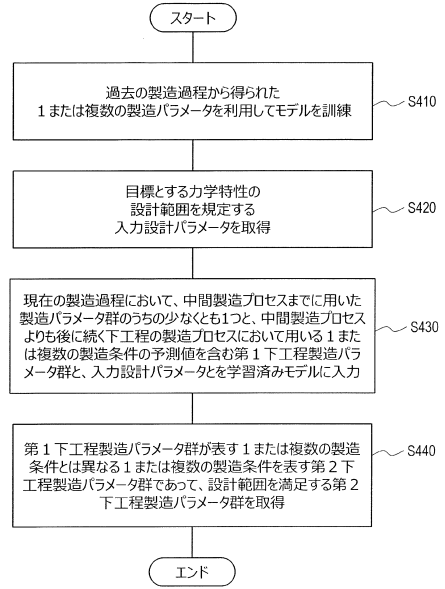
40

50

【 図 9 】




【 図 10 】




10

【 図 11 】



【 図 12 A 】




20

30

40

50

【 1 2 B】



10

20

30

40

50

フロントページの続き

Fターム(参考) 3C100 AA22 AA57 AA58 AA70 BB05 BB13 BB15 BB27 BB29 BB33
EE10