

(12) 特許協力条約に基づいて公開された国際出願

(19) 世界知的所有権機関
国際事務局

(43) 国際公開日
2019年9月26日(26.09.2019)



(10) 国際公開番号

WO 2019/182145 A1

(51) 国際特許分類:

B29C 45/76 (2006.01)

(21) 国際出願番号:

PCT/JP2019/012230

(22) 国際出願日:

2019年3月22日(22.03.2019)

(25) 国際出願の言語:

日本語

(26) 国際公開の言語:

日本語

(30) 優先権データ:

特願 2018-055633 2018年3月23日(23.03.2018) JP

(71) 出願人: 株式会社日本製鋼所 (THE JAPAN STEEL WORKS, LTD.) [JP/JP]; 〒1410032 東京都品川区大崎一丁目11番1号 Tokyo (JP).

(72) 発明者: 平野 峻之 (HIRANO Takayuki); 〒7368602 広島県広島市安芸区船越南一丁目


6番1号 株式会社日本製鋼所内 Hiroshima (JP). 佐伯 明彦(SAEKI Akihiro); 〒7368602 広島県広島市安芸区船越南一丁目6番1号 株式会社日本製鋼所内 Hiroshima (JP). 盛井 彰 (MORII Akira); 〒7368602 広島県広島市安芸区船越南一丁目6番1号 株式会社日本製鋼所内 Hiroshima (JP). 大西 浩(ONISHI Hiroshi); 〒7368602 広島県広島市安芸区船越南一丁目6番1号 株式会社日本製鋼所内 Hiroshima (JP).

(74) 代理人: 特許業務法人栄光特許事務所(EIKOH PATENT FIRM, P.C.); 〒1050003 東京都港区西新橋一丁目7番13号 虎ノ門イーストビルディング10階 Tokyo (JP).

(81) 指定国(表示のない限り、全ての種類の国内保護が可能): AE, AG, AL, AM, AO, AT, AU, AZ,

(54) Title: INJECTION MOLDING MACHINE SYSTEM

(54) 発明の名称: 射出成形機システム



(57) Abstract: Provided is an injection molding machine system (1) that performs control of molding conditions in an injection molding machine (2) by an agent (6) including a machine learning device which performs reinforcement learning. In the present learning, physical data obtained from the injection molding machine (2) and a defect type indicating the type of a molding defect in a molded article are used as states, molding conditions are used as actions, and a defect state indicating the defect level of the molding defect is used as a reward.

BA, BB, BG, BH, BN, BR, BW, BY, BZ, CA, CH, CL, CN, CO, CR, CU, CZ, DE, DJ, DK, DM, DO, DZ, EC, EE, EG, ES, FI, GB, GD, GE, GH, GM, GT, HN, HR, HU, ID, IL, IN, IR, IS, JO, KE, KG, KH, KN, KP, KR, KW, KZ, LA, LC, LK, LR, LS, LU, LY, MA, MD, ME, MG, MK, MN, MW, MX, MY, MZ, NA, NG, NI, NO, NZ, OM, PA, PE, PG, PH, PL, PT, QA, RO, RS, RU, RW, SA, SC, SD, SE, SG, SK, SL, SM, ST, SV, SY, TH, TJ, TM, TN, TR, TT, TZ, UA, UG, US, UZ, VC, VN, ZA, ZM, ZW.

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

添付公開書類:

- 一 国際調査報告 (条約第21条(3))

(57) 要約: 射出成形機システム (1) は、強化学習を行う機械学習器を有するエージェント (6) によって射出成形機 (2) における成形条件を調整する。本学習では、射出成形機 (2) から得られる物理データと、成形品の成形不良の種類を表す不良タイプとを状態 (State) として用い、成形条件を行動 (Action) として用い、成形不良の不良度合いを表す不良状態を報酬 (Reward) として用いる。

明 細 書

発明の名称：射出成形機システム

技術分野

[0001] 本発明は、機械学習を利用した射出成形機システムに関する。

背景技術

[0002] 射出成形機は、一般に、射出装置と型締装置とを有する。射出装置は、例えば、加熱シリンダと、加熱シリンダ内に回転方向と軸方向とに駆動可能に設けられているスクリュと、から構成される。一方、型締装置は、例えば、固定側金型が取り付けられている固定盤と、可動側金型が取り付けられている可動盤と、可動側金型を固定側金型に対して型開閉する型締機構と、から構成される。スクリュを回転駆動するとともに樹脂材料を加熱シリンダに供給することで、熔融した樹脂材料が、加熱シリンダの先端にて計量されて型締めされた金型のキャビティに射出されて充填される。そして、樹脂材料の冷却固化を待って可動金型を開くと、所定形状の成形品が得られる。

[0003] 射出速度、射出ストローク、シリンダ温度、型締力、保圧時間等の成形条件は、一般に、成形品ごとに異なっている。良好な成形品を成形するために、通常、射出成形を繰り返し実施して成形条件を調整する。このような成形条件の調整（いわゆる成形条件出し）は、一般に、オペレータの熟練を要する。オペレータは、成形不良が発生しているとき、その種類（具体的には、ヒケ、バリ、ボイド等の不良タイプ）を判断し、不良タイプに応じて成形条件を調整する。例えば、成形品にヒケが生じていれば、射出速度、射出ストローク、保圧圧力等を調整する。

先行技術文献

特許文献

[0004] 特許文献1：日本国特開2017-30152号公報

特許文献2：日本国特開2017-30221号公報

[0005] 特許文献1では、いわゆる強化学習によって学習する機械学習器によって

成形条件を調整する射出成形機システムが提案されている。特許文献 1 に記載の機械学習器は、強化学習により学習しながら、エージェント（Agent）として射出成形機を制御するようになっている。

[0006] 一般に、強化学習においては、制御対象が所定の状態（State）にあるときにエージェントが行動（Action）を選択すると、制御対象の状態が他の状態に遷移し、エージェントが報酬（Reward）を受け取る。エージェントは、所定の方策（Policy）に従って行動を決定し続けたときに、将来に渡って受け取ることができる報酬（即ち、累積の報酬）を表す価値関数を備えている。価値関数には、状態のみにより表される状態価値関数や、ある状態において所定の行動がどのくらい価値があるのかを表す行動価値関数等が含まれる。エージェントは、このような価値関数を、累積の報酬が最大になるように更新するように、学習を重ねる。

[0007] 特許文献 1 に記載のエージェントは、射出成形に関する物理量を状態として用い、操作条件（つまり成形条件）を行動として扱い、計算される報酬を受け取って学習を進める。エージェントは、報酬の計算に関して色々な評価対象を扱うことが可能であるが、例えば、成形の良否を評価対象として用いることができる。この場合、成形品が良品であればプラスの報酬を受け取り、成形不良であればマイナスの報酬を受け取る。評価関数の学習が十分に進めば、所定の状態に対してその評価関数の出力が最大になるような行動（即ち、成形条件）を選択すれば、その状態における最適な成形条件を得ることができる。

[0008] 特許文献 2 では、いわゆる教師あり学習によって学習して射出成形機の異常を診断する異常診断装置が提案されている。特許文献 2 に記載の異常診断装置は、SVMやニューラルネットワーク等のアルゴリズムを有する機械学習器を採用し、入力データとして射出成形機における内的または外的な状態データを用い、出力データ（つまり教師信号）として射出成形機の異常または正常のデータを用いる。射出成形機における内的または外的な状態データとして、例えば、駆動部の負荷、軸の周波数特性、樹脂圧力、アラーム発生

履歴、等が挙げられる。異常診断装置の学習が十分に進めば、所定の状態データに対して射出成形機が正常であるか異常であるかを適正に判定できる。

発明の概要

発明が解決しようとする課題

[0009] オペレータによって射出成形機の成形条件出しが完了すれば、射出成形機を連続的に運転して成形品を量産できる。しかし、特定の成形条件の下で射出成形を繰り返していると、成形不良が発生することがある。別の言い方をすると、外部環境の変化（例えば、外気温の変化や機械温度の変化）による射出成形機の状態の変化や、経年劣化によるスクリュ、逆流防止リング、トグルリンク、ブッシュ等の機械部品の摩耗により、同じ成形条件の下であっても成形不良が生じることがある。成形不良が発生しても、オペレータが成形不良を速やかに発見できれば、成形条件を再調整できる。しかし、夜間の運転等のようにオペレータが射出成形機の近くにいない場合、成形不良が継続する可能性がある。

[0010] そこで、例えば、特許文献1に記載のエージェントによって成形条件を自動的に調整することが考えられる。適切にかつ十分に価値関数が学習されていれば、射出成形機の現在の状態に応じて最適な成形条件が計算され、原理上は成形不良が継続することはない。しかし、特許文献1に記載のエージェントが扱う状態（State）は、射出成形に関する物理量だけである。仮に、あらゆる物理量が対象であれば、理論的には全ての事象に対して対応できる可能性がある。成形品の重量、寸法、成形品の画像データから算出される外観、長さ、角度、面積、体積、等々のあらゆる物理量を状態として用いれば、エージェントは、最適な成形条件を行動（Action）として出力できる。

[0011] しかし、大量の物理量を状態として扱う場合、計算機資源が過剰に必要な。また、計算量が爆発的に増えてしまい、価値関数を適切に学習させることは有限の時間では実質的に不可能である。このことは熟練したオペレータの成形条件の調整方法を考えれば予想できる。熟練したオペレータが成形

条件を調整するとき、全ての条件（即ち、射出速度、射出ストローク、シリンダ温度、保圧時間、保圧圧力等）を一斉には調整しない。オペレータは、不良タイプを判断し、その不良タイプに応じて調整すべき成形条件を選択し、その成形条件の値を大きくするのか小さくするのかを判断している。つまり、オペレータは、不良タイプに応じて調整すべき成形条件を取捨選択している。これによって速やかに成形条件を調整できる。これに対し、特許文献 1 に記載のエージェントは、成形条件を取捨選択するために必要な情報を有さない。そのため、エージェントは、他の物理データからそのような取捨選択と同等の判断を行うことができるように、膨大な学習を必要とすることになる。

[0012] 一方、例えば、特許文献 2 に記載の方法を応用して成形条件を調整することも考えられる。具体的には、ニューラルネットワーク等を使用して、射出成形機に関する色々な物理データを入力データとして制御装置に与え、そのときにおいて最適な成形条件を教師データとして制御装置に与えるようにする。制御装置の学習が進めば、射出成形機に関する現在の物理データを入力すれば、最適な成形条件が制御装置から出力されるはずである。しかしながら、最適な成形条件は一般的に不明であり、学習に必要な大量の教師データを得られない。そのため、成形条件の調整は、教師あり学習による機械学習器では実施することが困難である。

[0013] 本発明の目的の一つは、計算機資源を過剰に消費せず、学習に要する時間やコストが少なく、速やかに成形条件を調整できる射出成形機システムの提供である。

課題を解決するための手段

[0014] [1] 本発明の第 1 の側面において、射出成形機システムは、色々な状態における行動に対して報酬を得て価値関数を学習して前記価値関数に基づいて行動を決定する強化学習を行う機械学習器を有するエージェントと、所定の成形条件に基づいて成形品を製造する射出成形機と、を備え、前記エージェントによって前記成形条件を調整する、射出成形機システム

であって、

前記機械学習器は、

前記状態として、前記射出成形機から得られる物理データと、前記成形品の成形不良の種類を表す不良タイプと、を用い、

前記行動として、前記成形条件を用い、

前記報酬として、前記成形不良の不良度合いを表す不良状態を用いる、ように構成される。

[0015] [2] 本発明の第2の側面では、第1の側面において、

前記成形品を測定する不良判定装置と、教師あり学習により学習する分類器と、を更に備え、

前記機械学習器は、

前記不良タイプ及び前記不良状態として、前記不良判定装置を用いて測定された前記成形品の測定データを含む入力データが学習済みの前記分類器に入力されたときに前記分類器から得られる出力データを、用いる、ように構成される。

[0016] [3] 本発明の第3の側面では、第2の側面において、

前記分類器は、

実物の前記成形品についての前記測定データと前記不良タイプと前記不良状態とを含む複数組の実物データセットと、複数組の疑似データセットと、によって学習され、

前記疑似データセットは、前記実物データセットを加工して得られた前記測定データと前記不良タイプと前記不良状態とを含む、ように構成される。

発明の効果

[0017] 上記第1の側面によれば、エージェントによって射出成形機システムの成形条件を最適に調整できる。ここで、成形条件を最適に調整できるようにエージェントを適切に学習させるべく、状態 (State) として、射出成形機から得られる物理データと、成形品の成形不良の種類を表す不良タイプとを用いる。また、行動 (Action) として、成形条件を用い、報酬 (R

eward) として、成形不良の不良度合いを表す不良状態を用いる。状態に不良タイプを含めることで、エージェントは、熟練したオペレータと同様、不良タイプに応じて調整すべき成形条件を選択し、その成形条件の値を大きくするのか小さくするのかを決定することになる。これにより、エージェントは、比較的短時間で学習を実施でき、学習の効率を高め、学習のコストを低減できる。その結果、エージェントは、学習中に計算機資源を過剰に消費することもない。したがって、本側面の射出成形機システムは、計算機資源を過剰に消費せず、学習に要する時間やコストが少なく、速やかに成形条件を調整できる。

[0018] 上記第2の側面によると、射出成形機システムは、成形品を測定する不良判定装置と教師あり学習により学習する分類器とを備える。機械学習器は、不良タイプと不良状態として、学習済みの分類器に対して不良判定装置で測定された成形品の測定データが入力されたときに得られる出力データを、用いる。つまり、分類器は、成形品の測定データから不良タイプと不良状態を出力し、エージェントに渡す。換言すると、オペレータが介在することなく、分類器からエージェントに情報が渡される。その結果、成形サイクルごとに、そのサイクルにおける状態 (State) に応じて最適な成形条件 (Action) が得られる。これにより、射出成形機を連続運転させながら、成形条件を自動で調整できることになる。なお、不良判定装置の一例として、カメラが挙げられる。不良判定装置としてカメラを用いる場合、測定データの一例として、カメラによって撮影した画像データが挙げられる。

[0019] 上記第3の側面によると、分類器は、実物の成形品についての測定データと不良タイプと不良状態とを含む複数組の実物データセットと、複数組の疑似データセットと、によって学習される。この疑似データセットは、実物データセットを加工して得られた測定データと不良タイプと不良状態とを含む。一般に、教師あり学習により学習する機械学習器に対しては大量のデータセットが適正な学習のために必要になる。しかし、実物の成形不良のサンプルは、それほど多くは得られない。つまり、実物から得られる測定データと

不良タイプと不良状態のデータとを含む実物データセットは、一般に、大量には得られない。しかし、本側面によると、実物データセットを加工することで疑似データセットが得られるので、学習に必要な大量のデータセットを比較的容易に得ることができる。その結果、分類器の学習の効率が高まり、分類器が精度良く成形品の不良タイプと不良状態を出力できることになる。

図面の簡単な説明

[0020] [図1]図1は、本発明の実施形態に係る射出成形機システムを模式的に示すブロック図である。

[図2]図2は、本発明の実施形態に係る射出成形機システムにおける、生成器の処理とオペレータの作業とを説明するフローチャートである。

[図3]図3は、本発明の実施形態に係る射出成形機システムにおける、分類器を示す図である。

[図4]図4は、Actor-Criticのアルゴリズムを採用するエージェントを備えた、本発明の実施形態に係る射出成形機システムを模式的に示すブロック図である。

発明を実施するための形態

[0021] 本実施形態に係る射出成形機システム1は、機械学習を利用して（即ち、いわゆるAIによって）射出成形機2の成形条件を調整するシステムである。射出成形機2は、図1に簡略的に示されているが、従来の射出成形機と同様、型締装置や射出装置等から構成されている。射出成形機2には、射出成形機2によって成形された成形品を取り出す取出機3と、取り出された成形品を撮影するカメラ4とが隣接して設けられている。射出成形機2において成形品が成形されるごとに、カメラ4によって成形品の画像データが取得されるようになっている。

[0022] 射出成形機システム1において成形条件を調整するためのAIシステムは、所定の計算機上に構築されており、複数の機能ブロックを有する。まず、AIシステムは、射出成形機2に対して成形条件を調整するエージェント6を有する。エージェント6は、強化学習によって学習される機械学習器を有

する。エージェント6については後で詳しく説明する。

[0023] AIシステムを構成している他の機能ブロックとして、分類器7と、生成器8と、が挙げられる。分類器7は、後で説明するように、教師あり学習により学習される機械学習器を有する。分類器7は、成形品について不良の有無を判定し、成形不良の種別（即ち、不良タイプと、不良の程度つまり度合いである不良状態）とを出力するようになっている。教師あり学習を実行するために、分類器7に対して、入力データと出力データとを有するデータの組（つまりデータセット）を大量に用意する必要がある。ここで、生成器8は、データセットとして擬似的なデータを含む疑似データセットを大量に生成する。大量のデータセットを用意するために、オペレータが作業すべき内容および生成器8の処理について、以下に説明する。

[0024] データセットとして、入力データと出力データの組み合わせはどのような種類のデータを含んでいてもよく、分類器7が成形品を判定して不良タイプと不良状態とを出力できるようなデータの組み合わせであればよい。本実施形態におけるデータセットは、入力データが成形品の画像データであり、出力データが不良タイプと不良状態とである、組み合わせが採用されている。画像データはカメラ4により撮影される。画像データはどのようなものであってもよく、2方向または3方向から撮影された複数の画像データのセットであってもよいし、単一の方向から撮影した画像データであってもよい。また、異なる方向から光線が投影された複数の画像データから画像データが構成されていてもよい。どのような条件が採用されたとしても、全ての成形品に対して統一された条件により画像データがカメラ4によって撮影されるようにすればよい。

[0025] 出力データの不良タイプは、不良の種類ごとにその有無を表す複数個のデータを含み、ヒケの有無を1／0で示すデータ、バリの有無を1／0で示すデータ等を含む。不良状態は、不良タイプの種類に拘わらず、不良の程度を表すデータである。つまり、不良状態は、不良タイプがヒケであってもボイドであっても、その程度だけを扱うデータである。このデータはどのような

数値で表現されていてもよい。例えば、良品の不良状態を1.0と定義し、不良の程度が小さい場合の不良状態を-0.3と定義し、不良の程度が大きい場合の不良状態を-0.7と定義できる。

[0026] オペレータは、図2においてステップS1で示されているように、成形品の良品と、不良タイプの種類ごとに成形品の不良品のサンプルと、を用意する。例えば、ヒケが発生している不良品を1個または複数個用意し、バリが発生している不良品を1個または複数個用意し、他の不良タイプについても1個または複数個のサンプルを用意する。オペレータは、用意した不良品のサンプルごとに不良状態の数値を定める（ステップS2）。次いで、それぞれの良品および不良品のサンプルの画像データを取得する（ステップS3）。このようにして得られる画像データと不良タイプと不良状態とを有するデータセットは、実物の良品および不良品のサンプルから得られ、上述した「実物データセット」に対応する。

[0027] 生成器8は、実物データセットを計算により加工して疑似データセットを大量に生成する（ステップS4）。疑似データセットの生成は不良タイプごとに行う。例えば、生成器8は、不良タイプがヒケの不良品を対象とする場合には、ヒケの実物データセットを加工する。具体的には、生成器8は、実際のヒケが発生している位置を画像処理の平行移動により移動させたり、画像処理の拡大／縮小によりヒケの大きさを変更したりするように、画像ファイルを加工する。ヒケの大きさを拡大／縮小するときには、ヒケの大きさに応じて不良状態の値も変更する。生成器8は、このようにして疑似データセットを得る。生成器8は、他の不良タイプについても同様に、疑似データセットを生成する。なお、画像処理により機械的に画像データを加工する手法としては、上述したような任意の周知の手法を用いればよい。また、生成器8での処理には、GAN等の機械学習を用いた方法を用いても良い。

[0028] 分類器7は、教師あり学習の学習を行う機械学習器であり、採用されるアルゴリズムの種類については制約はない。例えば、分類器7は、SVM、最小二乗法、ステップワイズ法等を採用できる。ただし、入力データが画像デ

ータであり且つ出力データが不良タイプと不良状態とを含むデータセットの入出力の関係は非線形になることが予想されるので、非線形な入出力関係を表現できるアルゴリズムを採用することが好ましい。本実施形態においては、分類器 7 はニューラルネットワークから構成されている。分類器 7 は、図 3 に示されているように、複数層のニューラルネットワークを有し、入力層のニューロンには画像データが与えられ、出力層のニューロンからは不良タイプと不良状態とが出力されるようになっている。

[0029] そして、実物データセットと疑似データセットとを含む大量のデータセットを使用して、分類器 7 に画像データを入力として与え、対応する不良タイプと不良状態とを教師信号として与えて学習させる。その後、適切に学習された分類器 7 に成形品の画像データを与えると、その不良タイプと不良状態とを精度よく出力できるようになる。本実施形態に係る射出成形機システム 1 では、射出成形機 2 において射出成形されるごとに成形品が取出機 3 によって取り出され、カメラ 4 によって撮影される。そして、カメラ 4 で撮影された画像データが分類器 7 に送られ、分類器 7 が不良タイプと不良状態とを出力する。

[0030] 本実施形態に係るエージェント 6 について説明する。一般的に、強化学習する機械学習器は、制御対象あるいは環境を制御するようになっており、エージェントと呼ばれる。エージェントは、制御対象における状態 s_t (State) に基づいて行動 a_t (Action) を決定し、制御対象では状態 s_t が他の状態 s_{t+1} に遷移する。このとき、エージェントは制御対象から報酬 r_t (Reward) を受け取る。エージェントは、将来に渡って受け取る報酬 r_t の累積が最大になるような行動 a_t を決定するように学習する。これを実現するために、多くのエージェントでは所定の価値関数を設けて学習により更新させる。そして所定の状態 s_t が与えられるとき、学習が進んだ価値関数を使って、その値が最大になるような行動 a_t を決定するようにしている。価値関数についてはどのような種類の価値関数が採用されてもよい。また、学習のアルゴリズムも、Q 学習、SARSA 法、TD 学習、

モンテカルロ法、Actor-critic法等の周知のアルゴリズムが採用され得る。つまり、本発明の特徴は、価値関数の種類やアルゴリズムの種類にはなく、本実施形態に係るエージェント6が扱う状態 s_t 、行動 a_t 、報酬 r_t をどのようなデータから構成しているのかにある。

[0031] 本実施形態に係るエージェント6が扱う行動 a_t は、射出速度、射出ストローク、シリンダ温度等の成形条件を含む。所定の状態 s_t が与えられたとき、エージェント6が最適な成形条件を行動 a_t として決定できるようにするためである。本実施形態に係るエージェント6が扱う状態 s_t については、射出成形機2から得られる各種の物理データが含まれる。物理データは、射出圧力、樹脂温度、外気温、等の射出成形機に関連して得られる各種のデータを含む。状態 s_t として、これらの物理データ以外に他のデータが含まれてもよく、他のデータを適宜必要に応じて状態 s_t に追加すればよい。ところで、エージェント6が最適な成形条件を決定できるようにするには、このような状態 s_t だけでは十分でない。調整すべき成形条件を選択できるようにするために、本実施形態に係るエージェント6は、状態 s_t として分類器7が出力する不良タイプを含む。

[0032] 状態 s_t に不良タイプが含まれるので、エージェント6は、不良タイプに応じてどの成形条件を調整の対象とすべきか判断することが可能になり、与えられた状態 s_t 下において最適な成形条件を行動 a_t として適切に決定できることになる。本実施形態に係るエージェント6に与えられる報酬 r_t は、分類器7が出力する不良状態とする。これら状態 s_t 、行動 a_t 、報酬 r_t によってエージェント6は強化学習できる。ここで、不良タイプ毎に、熟練者の知識を活用して、ルールベースで調整の対象とすべき成形条件を絞り込んでもよい。たとえば、バリという不良に対して、射出速度および保圧圧力の行動選択確率を恣意的に上げるルールをエージェント6に与えて学習させてもよい。または、本実施形態の図面等に示すように、不良タイプによる行動の分岐をアルゴリズムに任せて学習させてもよい。

[0033] 本実施形態に係るエージェント6をActor-critic法により強

化学習させる例を説明する。この場合、図4に示されているように、エージェント6は行動器10と評価器11とから構成されることになる。Actor-critic法により行動 a_t を決定するにあたり、評価器11において価値関数として状態価値関数 $V(s_t)$ を設ける。状態価値関数 $V(s_t)$ は、状態 s_t がどのくらい良いのかを示す関数である。状態価値関数 $V(s_t)$ はどのように構成してもよい。例えば、状態 s_t のそれぞれの値に対応して V 値を格納するマトリクスから構成してもよいし、入出力関係を表すSVMやニューラルネットワーク等から構成してもよい。また、状態価値関数 $V(s_t)$ は強化学習によって更新することになるが、どのようなアルゴリズムによって更新してもよい。例えば、TD学習法により更新する場合には、状態価値関数 $V(s_t)$ は、以下の1式のようにして計算できる。

[0034] [数1]

$$V(s_t) \leftarrow V(s_t) + \alpha [r_t + \gamma V(s_{t+1}) - V(s_t)] \quad (1式)$$

ただし、 α : 学習係数 $0 \leq \alpha \leq 1$

γ : 割引率 $0 \leq \gamma \leq 1$

[0035] 射出成形機2において所定の物理データ、不良タイプを有する所定の状態 s_t が与えられたとき、行動 a_t として成形条件を決定して射出成形し成形品が得られる。この成形品に対して分類器7が不良状態を判定し、評価器11が報酬 r_t として受け取る。次いで、分類器7が判定した不良タイプを含む状態 s_t に対して次の成形条件を決定し、射出成形機2が射出成形を行う。このような成形を繰り返すことによって、1式によって状態価値関数 $V(s_t)$ を更新できる。

[0036] 一方、行動器10には、状態 s_t が与えられたとき、どの行動 a_t を決定するのかを表すポリシー $\pi(s_t, a_t; w_t)$ を設ける。ポリシー $\pi(s_t, a_t; w_t)$ は、状態 s_t の下で所定の行動 a_t を決定する確率を表す確率分布関数になっており、 w_t は、ポリシー $\pi(s_t, a_t; w_t)$ を規定する調整パラメータになっている。ポリシー $\pi(s_t, a_t; w_t)$ は、

例えば、平均 μ 、標準偏差 σ とする正規分布 $N(\mu, \sigma)$ により表現すると、調整パラメータ w_t を調整することは、実質的に w_t の関数として表現された平均 μ 、標準偏差 σ を調整することであると言える。調整パラメータ w_t を学習により調整して、ポリシー $\pi(s_t, a_t; w_t)$ が適切な確率分布関数になると、所定の状態 s_t が与えられたときに適切な行動 a_t を決定する確率が高くなり、不適切な行動 a_t を決定する確率は低くなる。調整パラメータ w_t の調整方法として、例えば、以下の方法が挙げられる。まず、ポリシー $\pi(s_t, a_t; w_t)$ が適正であるか否かの度合いを、適正度 e_t として2-1式で定義する。次いで、履歴付き適正度 D_t を、割引率 β を使って2-2式のように定義する。そうすると、不良状態として受け取る報酬 r_t と、状態価値関数 $V(s_t)$ とから、式2-3式により調整パラメータ w_t を更新できる。

[0037] [数2]

$$e_t = \frac{\partial}{\partial w_t} \log(\pi(a_t, s_t; w_t)) \quad (2-1 \text{ 式})$$

$$D_t = e_t + \beta D_{t-1} \quad (2-2 \text{ 式})$$

ただし、 β : 割引率 $0 \leq \beta \leq 1$

$$w_t \leftarrow w_t + \alpha \delta_t D_t \quad (2-3 \text{ 式})$$

ただし、 α : 学習係数 $0 \leq \alpha \leq 1$

δ_t : TD誤差 $\delta_t = r_t + \gamma V(s_{t+1}) - V(s_t)$

[0038] 学習を繰り返すと状態価値関数 $V(s_t)$ もポリシー $\pi(s_t, a_t; w_t)$ も、ともに収束してTD誤差 δ_t は0に近づく。即ち、強化学習により学習された状態になる。このような状態になったポリシー $\pi(s_t, a_t; w_t)$ によって状態 s_t が与えられると、最適な行動 a_t （つまり最適な成形条件）を計算できる。

[0039] 本実施形態に係るエージェント6は、異なる構成を採ることもできる。例えば、価値関数として行動価値関数 $Q(s_t, a_t)$ を設け、この行動価値

関数 $Q(s_t, a_t)$ によって最適な行動 a_t つまり最適な成形条件を決定できる。行動価値関数 $Q(s_t, a_t)$ は、状態 s_t において、所定の行動 a_t がどのくらい良いのかを示す評価関数である。行動価値関数 $Q(s_t, a_t)$ も、状態価値関数 $V(s_t)$ と同様に色々な構成をとることができる。例えば、行動価値関数 $Q(s_t, a_t)$ として状態 s_t 、行動 a_t のそれぞれの値に対応して Q 値を格納するマトリクス、つまり Q テーブルから構成してもよい。行動価値関数 $Q(s_t, a_t)$ は例えば Q 学習によって次式で更新できる。

[0040] [数3]

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha [r_{t+1} + \gamma \max_a Q(s_{t+1}, a_t) - Q(s_t, a_t)] \quad (3式)$$

ただし、 α : 学習係数 $0 \leq \alpha \leq 1$

γ : 割引率 $0 \leq \gamma \leq 1$

[0041] 射出成形を繰り返し、学習を繰り返すと、やがて行動価値関数 $Q(s_t, a_t)$ は収束し、学習された行動価値関数 $Q(s_t, a_t)$ を使って最適な成形条件を決定できる。即ち、所定の状態 s_t が与えられたとき、行動価値関数 $Q(s_t, a_t)$ が最大となるような行動 a_t を探す。このような行動 a_t が、最適な成形条件となる。

[0042] なお、行動価値関数 $Q(s_t, a_t)$ を Q テーブルから構成する場合、状態 s_t 、行動 a_t を離散値として扱うことになる。 Q テーブルのマトリクスを巨大にすれば、実質的に連続値として扱うこともできるが、計算負荷が大きくなってしまう。これに対し、例えば、行動価値関数 $Q(s_t, a_t)$ をニューラルネットワーク等のいわゆる関数近似器から構成するようにすれば、状態 s_t や行動 a_t を連続的に扱うことができ、かつ計算負荷も比較的少なくて済む。

[0043] 本発明は上記各実施形態に限定されることはなく、本発明の範囲内において種々の変形例を採用できる。例えば、本発明は、上述した実施形態に限定されるものではなく、適宜、変形、改良、等が可能である。その他、上述し

た実施形態における各構成要素の材質、形状、寸法、数、配置箇所、等は本発明を達成できるものであれば任意であり、限定されない。

[0044] 例えば、上記実施形態では、学習が収束をすることを前提として記述したが、アルゴリズムによっては、最終状態の収束が保証されなくてもよい。また、アルゴリズムは、Actor-criticの例で説明したように方策（ポリシー）を明示的に更新してもよいし、Q学習の例で説明したように価値関数の更新にとどめるようにしても良い。

[0045] 更に、例えば、上記実施形態では、価値関数の学習は、実際に成形を繰り返して実施してするように説明した。つまり、実際に成形を繰り返す中での学習、つまりオンラインでの学習をするように説明した。しかし、予め価値関数をオフラインで学習させるようにしてもよい。実際に成形を繰り返さなくても、状態 s_t 、行動 a_t 、報酬 r_t の関係についてある程度のデータが事前に入手できれば、これを使って価値関数を学習させておくことができる。価値関数の学習をある程度進めた状態で、前記したように実際に成形を行いながら学習するようにすると収束が早くなる。

[0046] 更に、他の変形例として、分類器7に対する入力データを変形することもできる。本実施形態においては、分類器7に対する入力データは成形品の画像データのみであるように説明したが、成形品に関する物理データ、例えば成形品重量、成形品の色度、屈折率等を入力データとして与えてもよい。これにより、より多くの種類の不良タイプについても判定できるようになる。

[0047] 更に、本発明に係る射出成形機システムは、複数台の射出成形機を有するシステムとして構成することもできる。即ち、同じ成形品を複数台の成形機で成形する場合、エージェント同士で情報交換を行ってもよい。情報交換により群強化学習を行えば、学習効率を高めることができる。

[0048] 更に、エージェント6が扱う状態 s_t 、行動 a_t はどのようなデータとして扱ってもよい。行動 a_t として扱う成形条件は、射出速度、射出ストローク、シリンダ温度等について、その実際の値を扱ってもよい。また、成形条件の変更分を扱ってもよい。つまり、射出速度の変更分、射出ストロークの

変更分、シリンダ温度の変更分等である。また、状態 *s t*、行動 *a t*、報酬 *r t* の各データを扱うとき、予め正規化して数値範囲が 0～1 になるように変換したり、あるいは -1～1 の数値範囲になるよう変換して扱うようにしてもよい。

[0049] 更に、本実施形態では、カメラ 4 を用いて撮影した画像データが、成形品の不良判定などにおいて用いられている。しかし、本発明に係る射出成形機システムでは、成形品の外観等を測定し得る限り、カメラ 4 とは異なる他の不良判定装置およびその不良判定装置によって測定された測定データが、成形品の不良判定などにおいて用いられてもよい。

[0050] 本出願は、2018年3月23日出願の日本特許出願（特願2018-055633）に基づくものであり、その内容はここに参照として取り込まれる。

産業上の利用可能性

[0051] 本発明による射出成形機システムは、計算機資源を過剰に消費せず、学習に要する時間やコストが少なく、速やかに成形条件を調整できる。この効果を有する本発明は、例えば、樹脂材料の射出成形を行うシステムに利用され得る。

符号の説明


[0052]	1	射出成形機システム
	2	射出成形機
	3	取出機
	4	カメラ（不良判定装置）
	6	エージェント
	7	分類器
	8	生成器
	10	行動器
	11	評価器

請求の範囲


- [請求項1] 色々な状態における行動に対して報酬を得て価値関数を学習して前記価値関数に基づいて行動を決定する強化学習を行う機械学習器を有するエージェントと、所定の成形条件に基づいて成形品を製造する射出成形機と、を備え、前記エージェントによって前記成形条件を調整する、射出成形機システムであって、
- 前記機械学習器は、
- 前記状態として、前記射出成形機から得られる物理データと、前記成形品の成形不良の種類を表す不良タイプと、を用い、
- 前記行動として、前記成形条件を用い、
- 前記報酬として、前記成形不良の不良度合いを表す不良状態を用いる、
- 射出成形機システム。
- [請求項2] 請求項1に記載の射出成形機システムであって、
- 前記成形品を測定する不良判定装置と、教師あり学習により学習する分類器と、を更に備え、
- 前記機械学習器は、
- 前記不良タイプ及び前記不良状態として、前記不良判定装置を用いて測定された前記成形品の測定データを含む入力データが学習済みの前記分類器に入力されたときに前記分類器から得られる出力データを、用いる、
- 射出成形機システム。
- [請求項3] 請求項2に記載の射出成形機システムにおいて、
- 前記分類器は、
- 実物の前記成形品についての前記測定データと前記不良タイプと前記不良状態とを含む複数組の実物データセットと、複数組の疑似データセットと、によって学習され、
- 前記疑似データセットは、前記実物データセットを加工して得られ

た前記測定データと前記不良タイプと前記不良状態とを含む、
射出成形機システム。


[図1]




[図2]



[図3]



[図4]



INTERNATIONAL SEARCH REPORT

International application No.

PCT/JP2019/012230

A. CLASSIFICATION OF SUBJECT MATTER

Int.Cl. B29C45/76 (2006.01) i

According to International Patent Classification (IPC) or to both national classification and IPC

B. FIELDS SEARCHED

Minimum documentation searched (classification system followed by classification symbols)

Int.Cl. B29C45/76

Documentation searched other than minimum documentation to the extent that such documents are included in the fields searched

Published examined utility model applications of Japan	1922-1996
Published unexamined utility model applications of Japan	1971-2019
Registered utility model specifications of Japan	1996-2019
Published registered utility model applications of Japan	1994-2019

Electronic data base consulted during the international search (name of data base and, where practicable, search terms used)

C. DOCUMENTS CONSIDERED TO BE RELEVANT

Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
Y	JP 2017-30152 A (FANUC CORPORATION) 09 February 2017, claims, paragraphs [0028]-[0063], fig. 1-3 & US 2017/0031330 A1, paragraphs [0032]-[0082], pp. 7-8, fig. 1-3 & DE 102016009203 A1 & CN 106393618 A	1-3
Y	JP 63-209917 A (TOSHIBA CORP.) 31 August 1988, claims, examples (Family: none)	1-3
Y	JP 8-309814 A (MITSUBISHI HEAVY INDUSTRIES, LTD.) 26 November 1996, claims, examples (Family: none)	1-3
Y	JP 2006-48370 A (KAGAWA UNIVERSITY) 16 February 2006, claims, paragraphs [0002]-[0009] (Family: none)	3

☐ Further documents are listed in the continuation of Box C.

☐ See patent family annex.

* Special categories of cited documents:

"A" document defining the general state of the art which is not considered to be of particular relevance

"E" earlier application or patent but published on or after the international filing date

"L" document which may throw doubts on priority claim(s) or which is cited to establish the publication date of another citation or other special reason (as specified)

"O" document referring to an oral disclosure, use, exhibition or other means

"P" document published prior to the international filing date but later than the priority date claimed

"T" later document published after the international filing date or priority date and not in conflict with the application but cited to understand the principle or theory underlying the invention

"X" document of particular relevance; the claimed invention cannot be considered novel or cannot be considered to involve an inventive step when the document is taken alone

"Y" document of particular relevance; the claimed invention cannot be considered to involve an inventive step when the document is combined with one or more other such documents, such combination being obvious to a person skilled in the art

"&" document member of the same patent family

Date of the actual completion of the international search
03 June 2019 (03.06.2019)

Date of mailing of the international search report
18 June 2019 (18.06.2019)

Name and mailing address of the ISA/
Japan Patent Office
3-4-3, Kasumigaseki, Chiyoda-ku,
Tokyo 100-8915, Japan

Authorized officer

Telephone No.

A. 発明の属する分野の分類 (国際特許分類 (IPC))

Int.Cl. B29C45/76 (2006.01) i

B. 調査を行った分野

調査を行った最小限資料 (国際特許分類 (IPC))

Int.Cl. B29C45/76

最小限資料以外の資料で調査を行った分野に含まれるもの

日本国実用新案公報	1922-1996年
日本国公開実用新案公報	1971-2019年
日本国実用新案登録公報	1996-2019年
日本国登録実用新案公報	1994-2019年

国際調査で使用した電子データベース (データベースの名称、調査に使用した用語)

C. 関連すると認められる文献

引用文献の カテゴリー*	引用文献名 及び一部の箇所が関連するときは、その関連する箇所の表示	関連する 請求項の番号
Y	JP 2017-30152 A (ファナック株式会社) 2017.02.09, 特許請求の範囲、段落0028-0063、図1-3 & US 2017/0031330 A1, [0032]-[0082], 第7-8頁, FIG. 1-3 & DE 102016009203 A1 & CN 106393618 A	1-3
Y	JP 63-209917 A (株式会社東芝) 1988.08.31, 特許請求の範囲、実施例 (ファミリーなし)	1-3

☒ C欄の続きにも文献が列挙されている。

☐ パテントファミリーに関する別紙を参照。

* 引用文献のカテゴリー

「A」 特に関連のある文献ではなく、一般的技術水準を示すもの
「E」 国際出願日前の出願または特許であるが、国際出願日以後に公表されたもの
「L」 優先権主張に疑義を提起する文献又は他の文献の発行日若しくは他の特別な理由を確立するために引用する文献 (理由を付す)
「O」 口頭による開示、使用、展示等に言及する文献
「P」 国際出願日前で、かつ優先権の主張の基礎となる出願

の日の後に公表された文献

「T」 国際出願日又は優先日後に公表された文献であって出願と矛盾するものではなく、発明の原理又は理論の理解のために引用するもの
「X」 特に関連のある文献であって、当該文献のみで発明の新規性又は進歩性がないと考えられるもの
「Y」 特に関連のある文献であって、当該文献と他の1以上の文献との、当業者にとって自明である組合せによって進歩性がないと考えられるもの
「&」 同一パテントファミリー文献

国際調査を完了した日

03.06.2019

国際調査報告の発送日

18.06.2019

国際調査機関の名称及びあて先

日本国特許庁 (ISA/J P)

郵便番号 100-8915

東京都千代田区霞が関三丁目4番3号

特許庁審査官 (権限のある職員)

神田 和輝

4 R

3439

電話番号 03-3581-1101 内線 3471

C (続き) . 関連すると認められる文献		
引用文献の カテゴリー*	引用文献名 及び一部の箇所が関連するときは、その関連する箇所の表示	関連する 請求項の番号
Y	JP 8-309814 A (三菱重工業株式会社) 1996. 11. 26, 特許請求の範囲、 実施例 (ファミリーなし)	1-3
Y	JP 2006-48370 A (国立大学法人 香川大学) 2006. 02. 16, 特許請求 の範囲、段落 0 0 0 2 - 0 0 0 9 (ファミリーなし)	3