



Title	タイヤモデル同定における遺伝的アルゴリズムの適応手法の開発
Author(s)	
Citation	令和2（2020）年度学部学生による自主研究奨励事業研究成果報告書．2021
Version Type	VoR
URL	https://hdl.handle.net/11094/80651
rights	
Note	

The University of Osaka Institutional Knowledge Archive : OUKA

<https://ir.library.osaka-u.ac.jp/>

The University of Osaka

令和2年度大阪大学未来基金「学部学生による自主研究奨励事業」研究成果報告書

ふりがな 氏 名	しんぐう よしき 新宮 義規	学部 学科	工学部 応用理工学科	学年	3 年					
ふりがな 共同 研究者氏名	いかがわ ひろゆき 五十川 弘行	学部 学科	基礎工学部 電子物理科学科	学年	3 年					
	たかた ゆたか 高田 裕佳		工学部 電子情報工学科		3 年					
	やまね しゅん 山根 駿		基礎工学部 システム科学科		3 年					
アドバイザー教員 氏名	いしはら ひさし 石原 尚	所属	工学研究科							
研究課題名	タイヤモデル同定における遺伝的アルゴリズムの適応手法の開発									
研究成果の概要	研究目的、研究計画、研究方法、研究経過、研究成果等について記述すること。必要に応じて用紙を追加してもよい。(先行する研究を引用する場合は、「阪大生のためのアカデミックライティング入門」に従い、盗作剽窃にならないように引用部分を明示し文末に参考文献リストをつけること。)									
1. 緒言										
1.1 研究背景										
自動車はタイヤが発生させる力によって運動を行う。タイヤが発生させる力の内、車両の推進方向の力を縦力、旋回時の遠心力方向にかかる力を横力と呼ぶ。また横力の着力点は、タイヤの変形によりタイヤ中心とずれるため、鉛直軸まわりのトルクとなる。これはセルフアライニングトルクと呼ばれる。現在、こういったタイヤの力学的特性に輪荷重などを考慮した数理モデルが複数提案されている。その一つに Magic Formula と呼ばれる実験同定モデルが存在している。このモデルは実用性の検証と改良が良く進んでいるが、非常に多くのパラメータが存在しておりそれらの数値の同定手法は未だ確立されていない。										
1.2 研究目的										
Magic Formula のパラメータを同定するため、タイヤの特性を測る実験を行うには専用の装置が必要であり、容易ではない。そこで本研究では、同定対象のタイヤを履いた車両の走行データからパラメータを同定する方法を提案する。走行データと、タイヤモデルを含む車両モデルでシミュレーションした結果を比較し、遺伝的アルゴリズム(以下 GA)という最適化の計算手法の一つを用いてタイヤモデルを同定する。本研究では、走行データ Magic Formula タイヤモデルの同定手法及び、タイヤモデル同定に適した GA の設定を確立することを目的とする。										
1.3 研究概要										
車両運動をシミュレーションするための4輪車両モデルを Mathworks 社の Matlab Simulink で構築する。車両モデルには、Magic Formula によるタイヤモデルを組み込む。一方、同定対象のタイヤを履いた車両を実際に走行させ、その時のエンジン回転数やヨーレートといった車両挙動情報をロギングする。実際の車両で走行した際の舵角やアクセル操作などを、構築した車両モデルに入力してシミュレーションを行う。										

ュレーションさせ、シミュレーションでの車両挙動情報をロギングする。ロギングした実車両挙動情報と、シミュレーション車両挙動情報の誤差を評価関数として、誤差が小さくなるようにタイヤモデルパラメータを推定する。誤差が小さいほど、推定したパラメータによるタイヤモデルが、実際のタイヤの力学的特性を正しく表現していると言える。また本研究では、全日本学生フォーミュラ大会に出場するために開発した小型フォーミュラレーシングカーOF-19を使用する。車両モデルには、OF-19の車両緒元が適用されている。

誤差を評価しパラメータを推定する部分に GA を導入する。GA は、Mathworks 社の Matlab で実装する。GA はタイヤモデルパラメータをランダムに幾つか生成し、生成したパラメータを車両モデルに渡してシミュレーションを行う。その後 GA はシミュレーションを行った結果を受け取り、実車両との誤差が小さかったパラメータをベースに、また新たなパラメータを生成する。これを繰り返すことで、誤差が小さくなるタイヤモデルパラメータを探索する。誤差の評価方法や、新たなパラメータを生成する際の設定や手法を吟味し、タイヤモデルパラメータの同定に適した GA を試行錯誤し確立させる。

2. 本研究で使用するモデル・アルゴリズム

2.1 Magic Formula

Magic Formula は、タイヤの力学的特性グラフを三角関数ベースの数式でフィッティングしたタイヤモデルである。タイヤの縦力は、タイヤのスリップ率 k が高くなると増大し、ある地点でピークを迎えた後緩やかに減少することが知られている。また横力も同様に、タイヤのスリップ角 α が大きくなると増大し、ある地点でピークを迎えた後減少する。ニューマチックトレール(セルフアライニングトルクのモーメント長)は、スリップ角 α が 0 の時にピークを持ち、 α が大きくなると減少する。例として、横力のグラフ形状をエラー! 参照元が見つかりません。に示す。これら形状を、三角関数を用いてフィッティングする。




図 1 横力の特性例[1]

さらに、タイヤの力学的特性は、輪荷重やキャンパー角、タイヤ温度などによっても変化する。それらの影響を考慮した Magic Formula が幾つか存在しているが、本研究では輪荷重 F_z 及びキャンパー角 γ の変化に対応したモデルを使用する。このモデルでは、パラメータが 73 個存在し、それらを GA で同定する。Magic Formula の式及び同定するパラメータ $a_0 \sim a_{17}$, $b_0 \sim b_{13}$, $c_0 \sim c_{21}$, $q_0 \sim q_{14}$, $s_0 \sim s_3$ は、参考文献[1]を参考にされたい。以降、純スリップ時(スリップ角またはスリップ率のどちらかのみがついている状態)の縦力、横力、セルフアライニングトルクはそれぞれ F_{x0} , F_{y0} , M_{z0} と表し、複合スリップ時(タイヤにスリップ率とスリップ角が同時に与えられている状態)の縦力、横力、セルフアライニングトルクはそれぞれ F_x , F_y , M_z と表す。

2.2 遺伝的アルゴリズム

遺伝的アルゴリズム(GA)とは生物の進化を模倣し解を探索するアルゴリズムである。GA の基本原理及び用語は参考文献[2]を参考にされたい。本研究では、染色体は同定する Magic Formula のパラメータ群に対応し、遺伝子は各パラメータの各桁に対応する。また遺伝子型として 2 進数での実装を行っており、各パラメータは 14bit の遺伝子で構成される。そのうち 1bit が符号、10bit が実数部、

3bit が指数部を示し、パラメータの値は $\pm(\text{実数部}) \times 10^{-(\text{指数部})}$ の形で表現される。よって表現できるパラメータの値は、実数部が1023まで、指数部が0から-7までとなる。

GA には、選択方法や交叉方法の他、設定できる手法や数値が多数存在する。本研究で吟味する主な項目は、選択方法、交叉方法、交叉率、突然変異率である。これらを変更し、タイヤモデル同定に適した GA の設定を確立する。なお、車両シミュレーションの計算には時間がかかるため、計算時間の都合上、本研究では100世代までの結果を目安として議論する。

3. 車両モデルの開発

車両モデルとは、タイヤモデルが出力した力から運動方程式を解き、車両運動のシミュレーションを行う計算モデルである。本研究で用いるタイヤモデルは輪荷重 R_z 、キャンバー角 γ 、スリップ角 α およびスリップ率 k に依存して F_x 、 F_y 、 M_z が出力されるため、これらの入力を正確に再現する必要がある。

輪荷重については車両の縦加速度、横加速度による荷重移動から計算を行った。メインスプリングおよびショックアブソーバー、さらにタイヤの縦ばねを含んだ2自由度バネマスダンパー系の運動方程式を解くことで、前後および横加速度による過渡的な輪荷重変動を再現した。また車体の前後ロール剛性配分、空力特性などを考慮し、さらにフレームの縦曲げ振動およびねじれ振動による輪荷重変動も考慮した。キャンバー角については、サスペンションジオメトリーによるキャンバー角変化を関数として入力し、さらにフレームのねじれ変形によるキャンバー角変化を考慮することで再現性を高めた。タイヤのスリップ角については、ドライバーの舵角入力、車体スリップ角、サスペンションジオメトリーによるスリップ角変化、フレームの横曲げ変形によるスリップ角変化に加え、ヨーレートおよびフレームの横曲げ変形によるタイヤの横移動速度から地面との相対的な移動速度によるスリップ角を算出することで再現性を高めた。またスリップ率については、エンジンだけでなく LSD によるトルクを考慮した。

これらのモデリングを実装し、 F_x 、 F_y 、 M_z から車両の前後方向および横方向の剛体移動の運動方程式、回転運動方程式を解くことで車両の姿勢を計算し、ヨーレートや縦速度、車両の旋回軌跡などを出力できるようにした。

4. 遺伝的アルゴリズムの開発

4.1 ベースとなる遺伝的アルゴリズムの開発

Magic Formula のパラメータを推定するための GA を作成した。Magic Formula のパラメータ推定では解の探索範囲が広大で、局所解に陥る可能性が高いため、分散遺伝的アルゴリズムを実装した。分散 GA については参考文献[3]を参考にされたい。分散 GA における島数は10とし、計算時間の観点から各島の個体は14と設定した。また交叉方法として一様交叉と2点交叉を、選択方法としてルーレット選択とトーナメント選択を採用し、島によってその組み合わせを変更した。また2個体のエリート選択を実装し、最大適応度が最も高かった各島の2個体は、エリートとして次の世代に残される。島ごとに交叉率、突然変異率、移住間隔は変更可能としている。本研究では表1に示す設定とした。なお、トーナメント選択の括弧付き番号はトーナメントサイズを表す。またここでの突然変異率は、その個体に突然変異を起こすかどうかの確率であり、各遺伝子をそれぞれ突然変異させるかどうかの確率は0.5%としている。

表 1 GA の設定

	選択方法	交叉方法	交叉率 [%]	突然変異率 [%]
島 1	ルーレット選択	一様交叉	90	1
島 2	ルーレット選択	一様交叉	90	0.5
島 3	ルーレット選択	二点交叉	90	1
島 4	ルーレット選択	二点交叉	90	0.5
島 5	ルーレット選択	二点交叉	80	2
島 6	トーナメント選択(2)	一様交叉	90	1
島 7	トーナメント選択(2)	一様交叉	90	0.5
島 8	トーナメント選択(2)	二点交叉	80	1
島 9	トーナメント選択(4)	一様交叉	90	1
島 10	トーナメント選択(4)	二点交叉	90	0.5

実際の車両で定常円旋回を行い、その際に取得した舵角及びエンジン回転数を車両モデルに入力として与えた。使用した実データを図 2～4 に示す。シミュレーション時間は 10 秒で、時間ステップは車両モデルが十分な精度で回るよう 0.001 秒とした。また実際の車両データは、ロギング周波数は 10Hz であるため 1000Hz となるよう線形補間して使用した。シミュレーションのヨーレート出力結果を実際の車両データと比較し、誤差の逆数を適応度とする。また、パラメータの探索範囲が広いと、タイヤモデルが大きく外れた個体は 10 秒間のシミュレーションが終了する前にスピン挙動を示し、出力結果が発散するため計算がその時点で終了してしまう。若い世代では、ほとんどの個体の計算が途中で終了してしまうため、計算が進んだステップ数を適応度に加え、少しでも長く計算が進んだ個体をよりよい個体と評価した。




図 2 舵角実データ




図 3 エンジン回転数実データ




図 4 ヨーレート実データ

4.2 制約条件の導入

4.1 節に示した GA で 100 世代進めた結果、10 秒間計算が回る個体は現れなかった。これはパラメータの探索範囲が広大すぎたため、まともなタイヤモデルを持つ個体が現れなかったからであると考察する。そこでパラメータに制約条件を設け、探索範囲を狭めた。制約条件は、生成したパラメータに適当な輪荷重、キャンバー角などを与えた際の縦力、横力、セルフアライニングトルクの値が妥当な範囲内に入っているかとして定めた。設定した制約条件数は 111 個となった。しかしながら、111 個の制約条件を満たす個体は、初期世代のランダム生成で現れる可能性は限りなく低い。そこで、満たした制約条件数のみを適応度として遺伝的アルゴリズムを回し、ある程度制約条件を満たした個体

が現れ始めてからシミュレーションを実施することとした。全個体の平均の適応度が、事前に定めた値を上回ったところで、満たした制約条件数による遺伝をやめ、シミュレーションに切り替える。切替後は、満たした制約条件数に加え、以前と同様にシミュレーションのヨーレート誤差と、進んだステップ数を適応度とした。その際、交叉後の子個体が親個体よりも制約条件数が下がる場合は交叉をやり直す操作を追加した。ただし、10 万回交叉をやりなおしても制約条件数が下がった子個体しか生成されない場合は、親個体をそのまま次の世代に残した。

進化を進めた結果、シミュレーションがある程度進む個体が現れた。しかしながら、その子個体は、親個体よりも発散までの時間が短くなる場合がほとんどであった。パラメータの取り得る本来の範囲が小さく、交叉により大きく外れたパラメータが現れることが原因と考えられるが、この場合、発散までの時間が長い良個体の進化が進まない。そこで、シミュレーションでそもそも計算結果が発散しない、つまりスピンしないような方法を考案した。

4.3 マンモデルの導入

シミュレーション中の旋回半径を算出し、実走行のデータで得た旋回半径との誤差をもとに舵角及びエンジン回転数を調整するマンモデルを導入する。つまり、目標の旋回ルートを通るように、修正舵、アクセルペダル操作の修正を行うドライバーの役割を担うブロックをシミュレーションに追加する。マンモデルは目標旋回半径との誤差を入力とした PI 制御で実装した。PI パラメータは、ある程度まとめたタイヤモデルを設定した車両モデルでシミュレーションを回し、収束するように手動で定めた。舵角とエンジン回転数のログと、実走行データの誤差の逆数を、遺伝的アルゴリズムの適応度とした。目標旋回ルートに従って運転した結果、実走行と同じ操舵及びアクセル操作が行われていれば、タイヤモデルが正しいとみなすことができる。

100 世代進めた結果、10 秒間シミュレーションが回り切れる個体が多く見られた。しかしながら、実走行の定常円旋回に近い挙動を示した個体は 100 世代時点では 4 割程度であった。今回の遺伝的アルゴリズムモデルでは、全個体の満たした制約条件数平均が 70 を超えたところでシミュレーションに移行するようにしていた。70 という数字は、計算時間の都合上設定した。定常円旋回に近い挙動の個体のパラメータでも、満たした制約条件数は 74 程度で、全成約数の 111 には到底及ばなかった。原因は、制約条件を複数のパラメータを統合して計算される縦力や横力などの範囲で定めたために、交叉でその値を構成するパラメータが複数変化すると制約条件から外れる確率が高まるからであると考えた。つまり、パラメータを組み合わせた制約条件を定めることは、各パラメータ一つに対する制約条件は未だ緩いため GA による解の探索では膨大な時間がかかり不向きであった。

4.4 パラメータ別制約条件の導入

4.3 節の結果では、パラメータ毎の制約条件が有効であることが考えられた。そこで、Magic Formula でのタイヤ特性グラフが、図 1 のような典型的なグラフ形状がある程度保つ範囲でパラメータにそれぞれ範囲条件を与える。グラフ形状の正解値としては、FSAE TTC(Tire Test Consortium)[4]のタイヤデータを参考とした。グラフの形状を表すパラメータが、複数のパラメータから構成されているため、一意に各パラメータの範囲を決定することは困難である場合が多い。そこで本研究においては、輪荷重およびキャンバー角の変化の 2 乗で効く項の係数は 0 とし、実質的に同定するパラメータの数を減らすことで、各パラメータの範囲を有意に定めた。

パラメータ毎の制約条件を導入した結果、ほぼ全ての個体が 10 秒間発散せずシミュレーションを回せるようになった。タイヤ特性がある程度妥当になり、過剰に計算が発散することが無くなった。

め、スピンを抑えるマンモデルは必要なくなった。またマンモデルには手動で設定した PI 制御パラメータが存在し、進化結果がこれらに影響される。人為的要素を極力減らすためマンモデルは廃止し、車両モデルの入力として、実走行の舵角、エンジン回転数のログデータを与える方法に戻した。

4.5 適応度の重み選定

ここまでは、GA の評価指標としてヨーレートを使用してきた。ここで、ヨーレートないし車両の自転は横力によって生み出されることを考えると、ヨーレートの評価のみでは縦力に直接的に効く指標での評価ができていない。そこで、評価指標に車両の縦速度、旋回曲率(旋回半径の逆数)を加えた。ここで旋回曲率はヨーレートを縦速度で割ったものであるから、ヨーレートと縦速度の比率であると言える。縦速度の実走行データには、車両の速度 GPS データを使用した。使用した実データを図 5、図 56 に示す。その他のデータは図 2～図 4 と同様である。




図 5 縦速度実データ




図 6 旋回曲率実データ

ヨーレート、縦速度、旋回曲率のシミュレーション結果と実走行データの誤差を評価するが、図 4、図 5、図 6 を参照すれば分かるように、これらの値はレンジが異なる。そのため、これらの誤差をそのまま評価関数として使用すると、それぞれのグラフのずれが同様でも、ヨーレートや縦速度に比べて旋回曲率は値としては非常に小さくなる。そこで、それぞれのグラフの誤差が評価関数に同様の影響を与えるよう誤差を正規化した。正規化の方法は、ある程度まとめたタイヤモデルを設定した車両モデルでシミュレーションした際のヨーレート、縦速度、旋回曲率それぞれの誤差を算出しておき、シミュレーション毎にその値でそれぞれの誤差を割ることで実現した。

次に、それぞれの誤差の重みを選定する。ヨーレート、縦速度、旋回曲率のどの指標を重視して評価し、GA を進めることがパラメータ同定に有効かを調査する。正規化した誤差の和をそのまま評価に使用する条件(条件 same)と、正規化した誤差にある指標のみ 3 倍の重みを与えて使用する条件(条件 speed, 条件 yawrate, 条件 curvature)で GA の進化結果を比較した。各条件において 100 世代進化させた際の結果を図 7～9 に示す。なお示した結果は荷重 800[N]、キャンバー角 0 時の複合スリップのものである。




図 7 縦力特性進化結果




図 8 横力特性進化結果




図 9 セルフアライニングトルク進化結果

縦力の結果については、カーブ形状は speed 条件が最もよい結果を示した。縦力は車両進行方向の加減速を生み出す力であり、縦速度は進行方向の加減速で決定される。そのため、縦速度の結果が最も合うよう設定された speed 条件が、縦力の力学特性グラフをよくフィッティングさせたものと考えられる。speed 条件以外の結果はピークを持たないカーブ形状となり、期待された結果とならなかった。

横力の結果については、カーブ形状は same 条件及び curvature 条件がよい結果を示した。横力は定常旋回時に遠心力と釣り合う力となるが、遠心力は縦速度と角速度(ヨーレート)の比で決定される。そのため、縦速度の結果のみ、ヨーレートの結果のみに重みを置いた speed 条件、yawrate 条件では期待された結果とならず、縦速度とヨーレートの比に重みを置いた curvature 条件や全てバランスよく評価する same 条件で、横力の力学特性グラフをよくフィッティングさせたものと考えられる。

セルフアライニングトルクの結果については、カーブ形状は speed 条件と yawrate 条件がよい結果を示した。この結果の理由について、理論的に結果を裏付ける考察を行うことができなかった。セルフアライニングトルクは転舵を抑える、もしくは促進する方向に働き、ドライバーの操作性を大きく左右するが、車両運動自体には大きな影響を与えない。ニューマチックトレールの変化は車両を自転させようとする力(横力)のモーメント長を変化させ、車両のオーバー・アンダーステア傾向に影響を与えるが、ニューマチックトレールは高々数 cm であり、車両運動全体で見るとその感度は小さいからである。今回のように、舵角入力が決まっているシミュレーションでは、速度やヨーレートといった車両運動の結果からはニューマチックトレールないしセルフアライニングトルクは十分に推定できないと考えられる。よって図 9 セルフアライニングトルク進化結果図 9 の結果は、speed 条件、yawrate 条件で残った個体が、偶然良いセルフアライニングトルクを示すパラメータを持っていたと

考察する。

結果をまとめると、縦力を表す Magic Formula パラメータを推定したい場合には、縦速度の評価に重みをつけ、横力を表すパラメータを推定したい場合には、旋回曲率の評価に重みを付けるか、まったく評価することが有効であることが示された。また、本システムではセルフアライニングトルクを表す Magic Formula パラメータ $q_0 \sim q_{14}$, $s_0 \sim s_3$ は、十分に推定できないことがほのめかされた。

4.6 評価に使用する走行コースの考察

4.5 節の結果を見ると、左右対称なグラフではないことが読み取れる。これは、評価に使用した実データとした左方向のみの定常円旋回を使用したためにスリップ角が正の領域のみしか使われていなかったからであると考えられる。そこで、評価の走行コースを左右一周ずつ定常円旋回を行うスキッドパッドのデータとした。なお時間は同じく 10 秒間で、評価の重みは縦速度、ヨーレート、旋回半径曲率に全て同じ重みで置いたものとした。この条件で 100 世代進化を進めた際の結果を図 10 に示す。なお same 条件で行ったためグラフ形状がよく一致する横力の結果のみを示している。




図 10 左右旋回コースによる横力結果

結果を見ると、左旋回のみの際と比較して違う傾向のグラフ形状となった。グラフ形状は大きく変わらないが、原点のシフトが以前と比べて大きく異なった。しかしながら左右対称とはならなかった。結果から、評価に用いるコースレイアウトによって、結果が変化することが分かった。従って、本システムでタイヤパラメータの推定を行う際は、加減速、定常旋回、過渡応答など様々な挙動が含まれた走行データを使用することでよい結果が得られる可能性が示唆された。

4.7 GA の設定の考察

本システムで用いた GA は、分散 GA を用い、表 1 に示すように様々なパラメータを持たせた。図 11 に same 条件で進化を進めた際の島別の適応度の結果を示す。これは各島の中で最も適応度が高かった個体の適応度の推移を示している。世代が進むごとに適応度が上昇している様子が分かる。ここで、10 世代おきに適応度が上昇している様子がよく見られる。これは分散 GA における個体の移住に起因していると考えられる。また他の条件でもそうあったが、ある特定の島がいつも最も良い適応度を残すことなく、毎回異なる島の個体が最も高い適応度として残った。このことから、ある特定の設定が有意により結果を生むとは考えにくい。さらに 10 世代ごとに平均適応度がよく上昇していることを考えると、本システムのように様々な設定の個体を分散 GA で処理を進めることは、比較的有效であると考察する。




図 11 各島別における適応度の変化

5. 結論

本研究では、Magic Formula のタイヤパラメータを GA により推定する手法を確立した。GA の設定には、様々な設定を持つ個体を分散 GA で進化させるようにすることが有効であった。また、適応度の評価として、縦力のタイヤパラメータをよく推定するには、縦速度を重視した方がよく、横力のタイヤパラメータをよく推定するには、旋回曲率を重視するか、縦速度とヨーレートを同じように重視することが有効であった。しかしながら、セルフアライニングトルクをよく推定するには、縦速度やヨーレート、旋回曲率の他の評価指標が必要であることが分かった。また、評価に用いる走行データによって結果の傾向が変わるため、様々なコースで吟味する必要がある。

6. 謝辞

本研究においては、アドバイザー教員の石原尚先生、また事務職員の山田佳美さんには本件へのアドバイス、予算執行にとどまらず、本研究グループが参加している学生フォーミュラプロジェクト全般にわたってご協力いただきました。本当にありがとうございます。また、本学工学研究科機械工学専攻修士2年生の岡田健太郎さん、基礎工学研究科システム創生専攻修士1年生の義田遼太郎さんには、車両運動モデルやタイヤモデルの制約条件、計算や評価手法の提案など、多岐にわたってご助力いただきました。ありがとうございます。

このような研究の機会を得ることができたのは、本自主研究奨励事業を支えてくださる皆様のおかげであると深く実感致しております。大阪大学未来基金の皆様、本事業にかかわる教職員の皆様に厚く御礼申し上げます。

7. 参考文献

- [1] “タイヤ特性のモデル化と車両運動に与える影響に関する研究”，高橋俊道，2018.3
- [2] “遺伝的アルゴリズム”，北野宏明，人工知能学会誌 Vol.7, No.1, 1991.10.23
- [3] “遺伝的アルゴリズムにおける世代交代モデルの提案と評価”，佐藤浩，小野功，小林重信，人工知能学会誌 Vol.12, No.5, 1996.8.26
- [4] Formula SAE Tire Testing Consortium, <https://www.fsaettc.org/>, 2021.1.5.Access