

(技術資料)

人工ニューラルネットワークを用いたリチウムイオン電池電極の最適メソスケール構造探索

山中拓己^{*1}・高岸洋一^{*1} (博士(理学))・山上達也^{*1} (博士(工学))

Optimal Design of Mesoscale Structure for Li-ion Battery Electrode Using Artificial Neural Networks

Takumi YAMANAKA・Dr. Yoichi TAKAGISHI・Dr. Tatsuya YAMAUE

要旨

機械学習と数値解析手法を組み合わせ、リチウムイオン電池電極のメソスケール構造を最適化するスキームを提案した。(i) 構造のみの最適化を目指す場合、(ii) 構造や材料選択、セル設計などの最適化をめざす場合の二通りの最適化用途を想定し、それぞれに適した物理モデルを提案スキームに適用した。数百～数千種類のメソスケール構造を生成し、それぞれの物理モデルにて内部抵抗を評価し、データセットを構築した。これを人工ニューラルネットワーク(ANN)に学習(回帰)させた。(i)(ii)いずれの場合においても構造パラメータの中では空げき率の感度が最も高かった。また、空げき率を最適化した構造は典型的な構造に比べて、内部抵抗が小さいことが分かった。提案スキームを適用することにより、2通りの最適化問題に対して有用な結果が得られることを確認した。

Abstract

A scheme has been proposed for optimizing the mesoscale structure of lithium-ion battery electrodes using machine learning approaches and numerical simulations. Two types of optimization applications have been assumed: (i) optimization of the structure only, and (ii) optimization including the structure, material selection, and cell design. Appropriate physical models for each have been applied to the proposed scheme. Hundreds to thousands of mesoscale structures have been generated and their internal resistances have been evaluated using the respective physical models to build a data set. This has been injected into (and regressed by) an artificial neural network (ANN) to build a model that instantly forecasts the internal resistance for a given input. In the cases of both (i) and (ii), the porosity has been found to be the most sensitive among the structural parameters, and the porosity-optimized structure shows lower internal resistance than the typical structure. It has been confirmed that the proposed scheme is applicable to two types of optimization problems, with useful results.

検索用キーワード

リチウムイオン電池, メソスケール構造, 最適化, ハイスループットモデル, 3次元モデル, 機械学習, 人工ニューラルネットワーク

ま え が き = リチウムイオン電池には、(i) 高エネルギー密度、(ii) 高出力密度、(iii) 長寿命、(iv) 高い安全性に対する要求を満たす必要がある。このためには、電極や電解質の新材料の開発に加えて、多孔質である電極のメソスケール構造(数 μm ～数百 μm オーダー)を設計することが重要である^{1), 2)}。この設計において数値シミュレーションによる検討を行うことは、電池の内部現象を理解しつつ電池電極構造の最適化を進める上で非常に有効である。

電池性能や耐久性、安全性を予測するために、これまでは1次元の電気化学モデルが広く利用されてきた。これらのモデルにおいて計算負荷は低いものの、一般に電極は均質な構造として近似される。この際、メソスケールにおける電極の3次元的多孔質構造や分布は反映されない。いっぽう、3D-SEM トモグラフィデータ^{3), 4)}や人工構造^{5), 6)}を用いた電気化学モデルに基づく3次元拡張シミュレーションモデル(以下、3次元モデルという)が最近開発されている。3次元モデルでは、多孔質電極のメソスケール構造を考慮して、電気化学反応やLi濃度の3次元分布を推定する。これにより、より正確

な電池性能予測が期待できる。

また、機械学習手法の一つである人工ニューラルネットワーク(Artificial Neural Network以下、ANNという)と電気化学モデルを組み合わせたパラメータの感度解析が報告されている^{7), 8)}。これらの報告では、ANNが電池性能の回帰予測や特徴量の感度分析に有用なツールであることが示されている。しかし、計算負荷の面からほとんどは1次元モデルが採用されており、3次元モデルに適用された事例は少ない。

近年、当社では3次元モデルをベースとした新たなモデル「ハイスループットモデル」を開発し、ANNと組み合わせた設計最適化手法を提案している⁹⁾。これらのモデルの特徴を比較した(表1)。ハイスループットモデルは、一部の3次元的现象を考慮しないことによって計算効率を向上させている。しかしながら、このモデルは空げきなどの構造の影響を考慮しているため、電池の製造条件(プロセス条件)を検討するうえで有効である。

電極設計へのフィードバックを考える場合には、構造だけでなく材料特性を含めた最適化が必要である。このため、計算効率が低下しても3次元モデルの活用が望ま

*1 (株)コベルコ科研 技術本部 計算科学センター

表1 従来の1Dモデル, ハイスループットモデル, 3Dモデルの特徴比較

Table 1 Comparative table for features of conventional 1D models, high-throughput models, and 3D models

Item	Convectional 1D model	High-throughput model	3D model
Structure of active material	Sphere only (Uniformity within electrode)	No restriction	No restriction
Spatial distribution of Li concentration in active material	1D distribution (Radial direction of sphere)	1D distribution (Radial direction of equivalent sphere)	3D distribution
Spatial distribution of electrical potential in active material	1D distribution (Electrode thickness direction)	Not taken into account	3D distribution
Spatial distribution of electrical potential in electrolyte	1D distribution (Electrode thickness direction)	3D distribution	3D distribution
Spatial distribution of electrochemical reactions on interfaces	1D distribution (Electrode thickness direction)	3D distribution	3D distribution
Computation costs	A few seconds	Dozens of minutes	A few hours
Suitable applications	Focus on comprehensive phenomena of the entire battery	Focus only on 3D structure	Focus on multiple factors such as 3D structure and material properties

しい。

リチウムイオン電池電極のメソスケール構造を対象とし、(i) ハイスループットモデルによる構造のみの最適化、ならびに (ii) 3Dモデルによる材料特性も含めた最適化を検討した。本稿では、実際の電池を想定した最適化事例を紹介する。

1. ハイスループットモデルとANNの組み合わせによる最適構造探索⁹⁾

提案する最適化スキームを図1に示す。ステップ1では、まず数多くの電極構造を生成し、ハイスループットモデル等を用いて物理現象を再現する。つぎにこの結果から、入力パラメータ(説明変数)と最適化したいパラメータ(目的変数)との関係をデータセット化する。ステップ2では、データセットをANNに学習(回帰)させる。これにより、あらゆる説明変数の組み合わせに対して目的変数を返す回帰モデルが構築される。ステップ3では、回帰モデルと最適化アルゴリズムを組み合わせ、目的変数を最適化(最大化・最小化・ある値に近づける等)する説明変数の組み合わせを探索する。

従来の最適化手法では、何らかの物理モデルと最適化アルゴリズムを組み合わせることによって、直接的な目的変数の最適化が行われてきた。本最適化手法のメリットは二つある。一つは、データセット化や回帰モデル構築の工程において、説明変数と目的変数との相関や感度が得られ、設計の指針が得られることである。もう一つは、回帰モデルの計算コストが物理モデルに比べて極めて小さいことから、多数の回帰モデルでの学習により、最適解の信頼性向上が期待できることである。

1.1 電極のメソスケール構造生成

電極内の活物質は粉末体から作成されることから、活物質のメソスケール構造は球の凝集構造とした。ランダムパック法¹⁰⁾に基づき、数百個の球からなる合計2,100種類のメソスケール構造を生成した。これらの構造を図2に示す。50×50×50(μm³)の立方体の中に、半径が2.5~12.5(μm)の活物質(球)をランダムに生成した。ここでは、ランダムに生成された球同士のオーバーラップを許容しており、その領域幅は生成時の圧力により決

定している。

1.2 ハイスループット電気化学モデル

構築した球凝集の人工構造に対して、単純化した電気化学モデルを用いて内部抵抗を評価する。電解質の有効イオン電導度は3次元ポアソン方程式(1)に従う。

$$\nabla \cdot [\sigma_l \nabla \phi] = 0 \dots\dots\dots (1)$$

ここで、 σ_l と ϕ_l はそれぞれバルク電解質のイオン伝導度と電解質電位である。上式を解き、算出された電解質の有効イオン電導度 $\sigma_{l,eff}$ から電解質のイオン抵抗(電解質抵抗) R_l を推定する。

$$R_l = [\sigma_{l,eff}(1 - \theta_b)^{15}]^{-1} \dots\dots\dots (2)$$

ここで、 θ_b は活物質の体積分率である。

活物質と電解質との間の反応抵抗 R_{react} は、線形化されたButler-Volmer方程式(式(3))により式(4)で与えられる。

$$i = i_0 \left[\exp\left(\frac{\alpha F}{RT} \eta\right) - \exp\left(-\frac{\alpha F}{RT} \eta\right) \right] \approx i_0 \frac{2\alpha F}{RT} \eta \dots\dots\dots (3)$$

$$R_{react} = \frac{\eta}{(I \cdot L)} \dots\dots\dots (4)$$

ここで、 i_0 は交換電流密度、 i は活物質と電解質との間に生じる電流密度、 η は過電圧、 α は電荷移動係数、 F はファラデー定数、 R はガス定数、 T は温度を表す。 I は系の断面に対する電流、 L は電流方向の系の長さである。

活物質中のLi拡散 c_s は拡散係数 D_s を用いて定常の拡散方程式(式(5))に従う。

$$\nabla \cdot [-D_s \nabla c_s] = 0 \dots\dots\dots (5)$$

濃度分極 Δc_s は式(6)に従う。

$$\Delta c_s = \frac{i_s r^2}{2D_s} \dots\dots\dots (6)$$

ここで、 i_s は活物質表面のLi濃度フラックス、 r は半径である。したがって、Li拡散抵抗 R_{diff} は次式で与えられる。

$$R_{diff} = \frac{[\phi_{OCR}(c_0) - \phi_{OCR}(c_0 + \Delta c_s)]}{I \cdot L} \dots\dots\dots (7)$$

ここで、 c_0 は活物質中の平均Li濃度である。開回路電

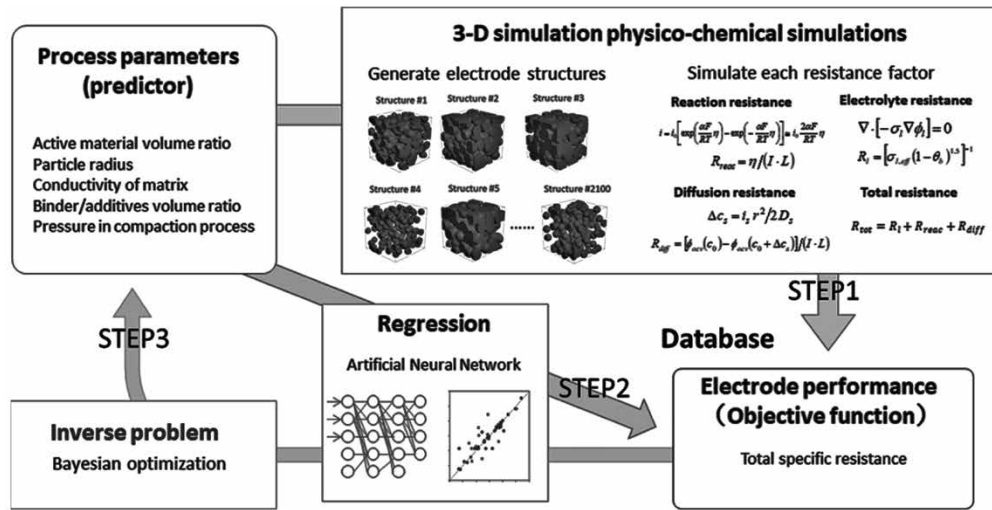


図1 電極メソスケール構造予測・最適化スキーム
Fig.1 Prediction and optimization scheme for a Li-ion battery porous electrode




図2 生成された電極メソスケール構造 (50 × 50 × 50 μm³)
Fig.2 Generated mesoporous structures of electrode (50 × 50 × 50 μm³)

圧 ϕ_{OCV} は次式で示す6次関数を用いて算出する。

$$\phi_{OCV}(c_0) = \sum_i p_i \left(\frac{c_0}{c_{max}} \right)^i \dots\dots\dots (8)$$

ここで、 c_{max} は活物質の最大Li濃度、 p_i は係数である(表2)。これらの簡略化により、活物質のLi濃度の3次元分布を無視する(等価的な球の分布を採用)ことになるものの、3次元の複雑な構造を有する場合に計算負荷を軽減できる。

電極の全内部抵抗 R_{tot} は、電解質抵抗 R_l 、活物質と電解質間の反応抵抗 R_{rec} 、Li拡散抵抗 R_{diff} の和で与えられる。

$$R_{tot} = R_l + R_{rec} + R_{diff} \dots\dots\dots (9)$$

NMC (リチウムニッケルマンガンコバルト酸化物, Li(Ni_{1/3}Mn_{1/3}Co_{1/3})O₂)の代表的な電気化学パラメータ(式(1)~(9)で用いる各係数)を各内部抵抗の評価に採用する。

1.3 データセット

前節の計算結果からデータセットを構築する。説明変数を①活物質体積分率、②活物質粒径、③バインダ・導電助剤の体積分率、④電解質のイオン伝導度、⑤圧力とした。また、目的変数を①反応抵抗、②電解質イオン抵抗、③拡散抵抗とした。目的変数と説明変数を含む学習・検証用のデータセットを表3に示す。学習セットのために全データセットのうち70%のデータをランダ

表2 開回路電圧関数の多項式係数

Table 2 Polynomial coefficients of open circuit voltage (OCV) function

Coefficient	Value
p_6	-43.8299
p_5	109.273
p_4	-99.9523
p_3	39.8270
p_2	-5.52739
p_1	-1.00539
p_0	4.19987

ムに取って使用し、残りのデータをANNモデルの検証に使用した。

1.4 ANNと感度分析

ネットワークの構成を決定するために、ニューロン数や隠れ層を含むハイパーパラメータが異なるさまざまなANNを評価した。検証データに対する決定係数 R^2 を表4に示す。隠れ層が2層で構成されたANNの R^2 値は、単層で構成されたANNの R^2 よりも高くなっている。

ハイスループットモデルによって計算された全内部抵抗と、さまざまなANNによって予測された全内部抵抗値に対する教師データと検証データの両方の散布図を図3に示す。ここで、図中の括弧内は、隠れ層のニューロン数を示している。例えば、(2, 2)の場合は第1隠れ層のニューロン数が2であり、第2隠れ層のニューロン数が2である。図3からわかるように、ニューロン数や隠れ層の数が多くなるほど予測精度が向上している。本稿では、試行した中で最も精度が高いANN(10, 10)を採用した。

構築したANNを用いて各説明変数の全内部抵抗に対する感度(寄与度)を分析した。最も単純なアプローチとして、ここではANNの第一層目の隠れ層上のニューロンの重み係数を評価する¹¹⁾。各説明変数に対する第1層のニューロンの重み係数の大きさ $|w|$ (総和)を図4に示す。図中の“AP”は活物質を表しており、“Kmatrix”は電解液中のLiイオン伝導度を表している。この図か

表3 説明変数と目的変数を含む学習・検証用データセット
Table 3 Dataset for learning and testing, including predictors and descriptors

#	Descriptors					Predictors		
	Active material		Binder/additives	Electrolyte	Compaction process	Reaction resistance ($\Omega \cdot m$)	Electrolyte resistance ($\Omega \cdot m$)	Diffusion resistance ($\Omega \cdot m$)
	Volume fraction (%)	Radius (μm)	Volume ratio (%)	Conductivity (S/m)	Pressure (MPa)			
1	77.8	10.5	28.5	0.77	3.12	1.03	291	9.68
2	85.4	11.5	0.254	0.35	23.2	1.71	20.4	4.02
...
2100	85.4	11.5	0.852	0.35	14.6	1.75	80.7	2.49

表4 検証データに対する決定係数 R^2
Table 4 Determination coefficients, R^2 , for validation data

Number of Hidden Layers	Number of Neurons				
	2	4	6	8	10
1	0.326	0.788	0.834	0.810	0.790
2	0.330	0.795	0.822	0.863	0.827




図3 ハイスループットモデルによって計算された全内部抵抗と、さまざまなANNによって予測された値との、教師データと検証データの両方の散布図

Fig.3 Scatter plots between specific resistances calculated by simplified physico-chemical models and predicted by various artificial neural network (ANN) models with training data and test data

ら、全内部抵抗に対して、圧力や粒子径の影響は比較的小さく、活物質粒子の体積分率が最も大きく影響を及ぼすことがわかる。

1.5 最適メソスケール構造

最適化アルゴリズムの一つであるベイズ最適化とANNを組み合わせ、全内部抵抗を最小化する説明変数を探索する。最適化を検証するために、初期条件を変えて5回の計算を行った。この結果、各計算はいずれの場合においても試行回数100回にて約 $47 \Omega \cdot m$ に収束した。

全内部抵抗に対する最適構造パラメータを表5に示す。バインダ/導電助剤の数が少なく、活物質粒子の粒径が小さい条件で、活物質体積分率が約50%で充填されるべきであることをこの結果は示している。また、電解質のイオン伝導度が高いほど電極の全内部抵抗が低下するため、本計算条件の範囲内で最も高いイオン伝導度




図4 各説明変数に対する第1層の重み係数の大きさ $|w|$ (総和)
Fig.4 Summations of weight coefficient magnitudes of the first layer neurons for various design parameters

表5 全内部抵抗に対する最適構造パラメータ
Table 5 Optimized process parameters for total specific resistance

Active Material		Binder/Additives	Electrolyte	Compaction
Volume fraction (%)	Radius (μm)	Volume ratio (%)	Conductivity (S/m)	Pressure (MPa)
50.4	6.00	0.0820	1.00	590




図5 (a) 最適化された活物質粒子の充填構造 ($50 \times 50 \times 50 \mu\text{m}^3$) および (b) 最適条件における各抵抗のレーダーチャート
 Fig.5 (a) Packing structure of active material particles ($50 \times 50 \times 50 \mu\text{m}^3$) and (b) radar chart of each specific resistance factor in condition of optimized process parameters

が示されている。最適解として得られた590 MPaの圧縮圧力は、実際のプロセスにおける典型的な範囲内にある¹²⁾。

図5 (a) は、最適化された構造パラメータにおける活物質のメソスケール構造を示している。図5 (b) は、各条件における各内部抵抗のレーダーチャートを示している。図5 (b) の最も濃く太い線の三角形は全内部抵抗が最小の場合であり、濃淡は条件の組み合わせを示している。この図より、拡散抵抗および電解質抵抗は最小ではないが、反応抵抗は最小であるものが存在していることが確認できる。

2. 3次元モデルを用いた最適構造探索

前章では、構造の最適化を目的として、ハイスループットモデルを用いた最適化について述べた。前述したように、構造および材料選択の最適化を目指す場合には、ハイスループットモデルではなく通常の3次元モデルを用いる必要がある。本章では、提案した最適化スキーム(図1)のステップ1において、3次元モデルを用いた事例を紹介する。

2.1 3次元モデル

Newmanらが提唱するモデル¹³⁾を基に、電解質のLiイオン濃度を質量保存則(式(10))、電解質の電位をNernst-Planckの式(式(11))、活物質Li濃度を拡散方程式(式(12))、活物質の電位をPoisson方程式(式(13))、電気化学反応速度をButler-Volmer式(式(14))で表現する。これら全体を連成して、各時刻における電解質内の電位場 ϕ_l 、活性物質内の電位場 ϕ_s 、電解質内のLiイオン濃度場 c_l 、活物質内のLiイオン濃度場 c_s を求める。

$$\frac{\partial c_l}{\partial t} = \nabla \cdot (-D_{l,eff} \nabla c_l) = 0 \quad \dots\dots\dots (10)$$

$$\nabla \cdot \left(-\sigma_l \nabla \phi_l + \left(\frac{2\sigma_{l,eff} RT}{F} \right) (1-t_+) \nabla \ln(c_l) \right) = 0 \quad \dots\dots\dots (11)$$

$$\frac{\partial c_s}{\partial t} + \nabla \cdot (-D_s \nabla c_s) = 0 \quad \dots\dots\dots (12)$$

$$\nabla \cdot (-\sigma_s \nabla \phi_s) = 0 \quad \dots\dots\dots (13)$$

$$i = i_0 \left\{ \exp\left(\frac{F\eta}{2RT}\right) - \exp\left(\frac{-F\eta}{2RT}\right) \right\} \quad \dots\dots\dots (14)$$

ここで、 t は時刻、 σ_s は電気伝導度である。次式により内部抵抗 R_{tot} を算出できる。




図6 3次元モデルの概要
 Fig.6 Schematic view of 3D-model

$$R_{tot} = \frac{\phi_{OCV} - \Delta\phi_s}{I} \quad \dots\dots\dots (15)$$

ここで、 $\Delta\phi_s$ は集電箔間の電位差である。

3次元モデルの概要を図6に示す。図のように、集電箔・電極・セパレータ領域はトータル厚さ81(μm)、断面 50×50 (μm)としてモデル化し、負極材はLi金属を想定したハーフセルとしている。これらのモデリングには研究開発向け材料開発シミュレーションソフトウェアのGeoDict¹⁴⁾を用いている。

典型的な条件における活物質内および電解質内のLiイオン濃度分布の時間変化を図7に示す。図のように、充電が進行するに伴って活物質内のLi濃度が減少し、電解質内のLiイオン濃度が増加する様子が確認できる。

2.2 データセット

各種電池パラメータに対する310通りの計算結果からデータセットを構築する。説明変数は構造パラメータである①平均粒径、②粒度分布標準偏差、③空げき率と材料特性である④活物質導電率、⑤活物質Li拡散係数、⑥界面反応速度定数、⑦電解液イオン伝導度、⑧電解液イオン拡散係数、ならびに電池の使用条件である⑨印加電流、⑩温度とした。また、目的変数は全内部抵抗とした。このように、多種にわたる入力条件を説明変数に指定できることが3次元モデルの強みである。1.2節と同様に、学習セットのために、全データセットのうち70%のデータをランダムに取って使用し、残りのデータをANNモデルの検証に使用した。

2.3 ANNと感度分析

前節により得られたデータセットをANNに学習させる。ここでは1層の隠れ層(40個ニューロン)を持つANNとした。決定係数 $R^2=0.824$ であり、十分な精度で予測できることが確認された。ANNによる各説明変数の感度分析の結果を図8に示す。最も感度が高い説明変数は界面反応速度定数である。このパラメータは反応抵抗との相関が高いことから、反応抵抗が全内部抵抗に占める割合が大きいことが示唆される。つぎに、電解質のイオン伝導度と空げき率が同程度に高い。空げき率は構造パラメータの中では最も感度が高く、1章の結果を支持している。なお、空げき率やイオン伝導度の相関が高いことから、反応抵抗のつぎにイオン抵抗が全内部抵抗に占める割合が大きいと考えられる。

学習したANNを用いて計算した空げき率と内部抵抗

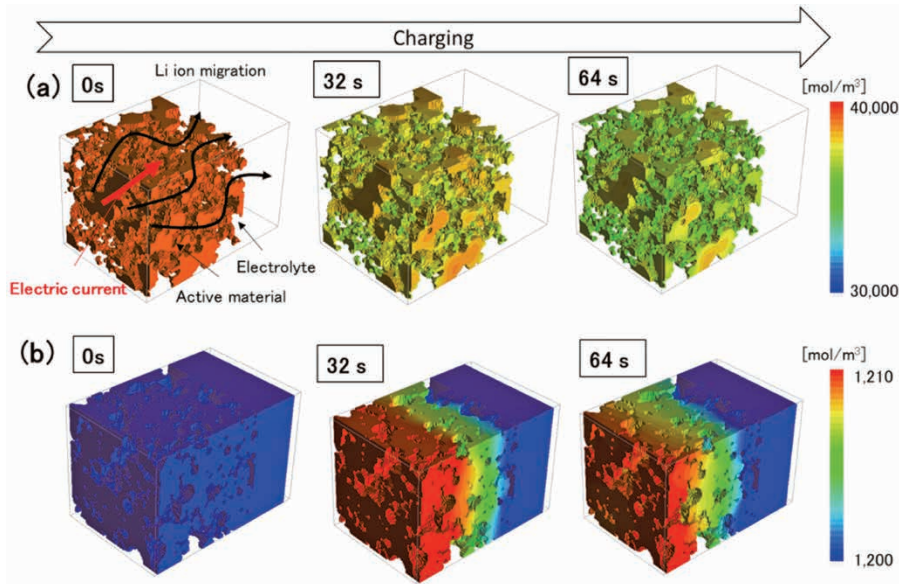


図7 活物質内 (a) および電解質内 (b) のLiイオン濃度分布の時間変化
Fig.7 Time histories of Li-ion concentration distribution in (a) active materials and (b) electrolyte




図8 ANNによる各説明変数の感度分析結果
Fig.8 Results of sensitivity analysis for various design parameters




図9 空げき率と内部抵抗の関係
Fig.9 Relationship between porosity and specific resistances

の関係を図9に示す。35.3(%)で極小値となることが分かる。これは、空げき率が増加すると電解質のイオン抵抗が低下して空げき率が低下(活物質体積分率が增加)することにより活物質の電気抵抗・拡散抵抗が低下し、これらが35.3(%)でバランスすることを示唆している。

2.4 最適メソスケール構造

前述したように、最適構造の探索という視点から、感度分析により構造パラメータとして空げき率が最も効いており、空げき率35.3(%)の構造が最適構造であることが示された。構造パラメータとして、標準構造である空げき率44.2(%)、平均粒径4.8(μm)の場合と、最適値とされた空げき率35.3(%)および今回の条件で最も小さい平均粒径3(μm)の場合を比較した(図10)。

全内部抵抗はそれぞれ0.966(m Ω)と0.706(m Ω)であり、構造パラメータの変更により内部抵抗は27%減少する。なお、空げき率の最適値が1章と異なるのは、ハイスループットモデルでは説明変数に材料物性を含んでいないことが主たる要因と考えられる。しかしながら、構造の最適化については、両モデルで空げき率が主要な因子

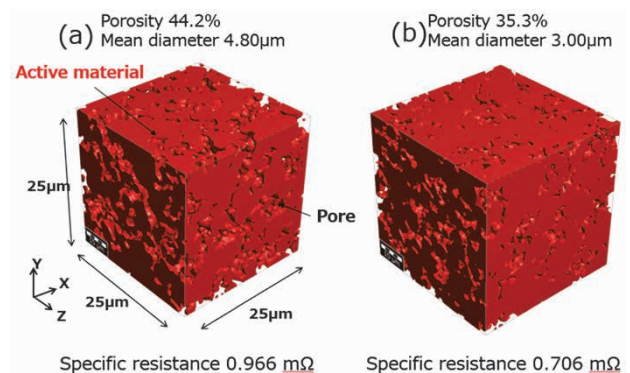


図10 標準構造および最適化された構造の比較
Fig.10 Comparison between (a) Standard and (b) optimized structures of active material particles

であるは一貫しており、用途、コスト面などから使い分けること肝要と考える。

むすび = 本研究では、リチウムイオン電池の電極メソスケール構造を最適化する手法を提案した。最適化スキームを2通りの電極メソスケール構造の最適化に適用し、電極設計の指針に資する有用な結果が得られることが確認できた。とくに、空げき率が内部抵抗最小化のカギとなる構造パラメータであることが示された。

本稿では内部抵抗の最小化に着目したが、リチウムイオン電池には容量の最大化、寿命の最大化、安全性の最

大化など、取り組むべき最適化問題はいくつもある。提案した手法はこれらの最適化、あるいは複数の目的変数の最適化（多目的最適化）に応用することも可能であり、リチウムイオン電池の電極や電解質の開発に貢献していきたい。

参 考 文 献

- 1) W. J. Long et al. Chem. Rev. 2004, Vol.104, Issue10, p.4463-4492.
- 2) S. T. Arthur et. al. MRS Bull. 2011, Vol.36, Issue7, p.523-531.
- 3) G. B. Less et al. J. Electrochem. Soc. 2012, Vol.159, No.6, p.A697-A704.
- 4) J. Gelb et al., J. Power Sources. 2017, Vol.357, p.77-86.
- 5) L. B. Trembacki et al. J. Electrochem. Soc. 2018, Vol.165, No.13, p.E725-E736.
- 6) T. Danner et al. J. Power Sources. 2016, Vol. 334, p.191-201.
- 7) E. Hosseinzadeh et al. Energies. 2017, Vol.10, Issue9, 1278.
- 8) N. Dawson-Elli et al. J. Electrochem. Soc. 2018, Vol.165, No.2, p.A1-A15.
- 9) Y. Takagishi et al. Batteries 2019, Vol.5, Issue3, 54.
- 10) A. Bertei et al. Chem. Eng. Trans. 2013, Vol.32, p.1531-1536.
- 11) B. Wu et al. J. Power Sources. 2018, Vol.395, p.128-136.
- 12) Y. H. Trana et. al. J. Power Sources. 2012, Vol. 210, p.276-285.
- 13) T. F. Fuller et. al. J. Electrochem. Soc. 1994, Vol.141, No.1, p.1-10.
- 14) Math2Market GmbH. GeoDict Software.
<https://www.math2market.com/Solutions/aboutGD.php>
(参照2020-11-24).