

固溶強化型銅合金の元素選択： 実験データ，第一原理計算と機械学習を用いたモデル化

山口 健志 井上 雄基 有澤 周平 松野下 裕貴
伊藤 優樹 末廣 健一郎 森 広行 牧 一誠

Element Selection for Solid Solution Copper Alloys:
Modeling Using Experimental Data, First-Principles Calculations, and Machine Learning

Kenji YAMAGUCHI Yuki INOUE Shuhei ARISAWA Hirotaka MATSUNOSHITA
Yuki ITO Ken'ichiro SUEHIRO Hiroyuki MORI Kazunari MAKI

Abstract

In this study, a comprehensive elemental screening framework is proposed to predict the solid solution strengthening and electrical resistivity of copper alloys. Electrical resistivities are predicted by first-principles calculations, and a high degree of accuracy is obtained. Two models are considered to predict the solid-solution strengthening. One of them uses the generalized critical resolved shear stress formula and provides a reasonable accuracy for a testing set of our experimental data. The other model using machine learning has a high prediction performance for the testing set. Combining the predicted electrical resistivity and solid-solution strengthening, we establish a figure-of-merit formula for the comprehensive elemental screening. All solute elements, H to Rn, including hypothetical copper alloys are ranked, and the less studied Cu-Au, -Hg, and -Tl are predicted to be high-performance structures. From economic, environmental, and healthcare perspectives, Cu-Mg is an appropriate choice according to the results.

キーワード：銅固溶合金，材料設計，MI，第一原理計算，MSP[®]

1. はじめに

さまざまな銅合金は，電氣的，機械的，物理的特性のユニークな組み合わせにより広く使用されており，近年のモビリティの電化・電動化，AIの発展などによって，その需要は高まっている。固溶強化型の銅合金は，製造プロセスが簡単でコストが低く，機械的強度と電気伝導性のバランスが良いことが知られている。当社は独自の合金設計技術^{1,2)}を元にCu-Mg系固溶強化型合金「MSP[®]シリーズ」を開発し，幅広く市場に受け入れられている。文献2に示した通り，固溶強化の尺度としてKingの文献³⁾の有効原子半径，元素ごとの抵抗率の増加の尺度としてLindeの文献⁴⁾のデータを用いる合金設計指針を確立し，それ以前に知られていた銅固溶合金の限界に対してさらに高いレベルでの高強度と高導電性の両立を示し上市に至ったわけであるが，文献3，4の一方または両方から漏れた元素とCuの組み合わせに対して網羅的に調査できていないという懸念は残った。そこで，NIMS-MMC-CoEの発足に際し，改めて蓄積した実験データとシミュレーションや機械学習を用いてこの問題に立ち返

ることとした。機械学習などデータ科学を援用した材料開発，いわゆるマテリアルズインフォマティクス (MI) をNIMSとの協力の下で遂行するにあたって，その拠って立つ実験データに関しては，NIMS-MMC-CoEの発足以前に当社で蓄積したデータを用いてモデル化を遂行し，その検証用に新たに実験データを取得する方針とした。また，実験データに含まれていない元素に対する予測性を得るために第一原理計算による計算量を活用する方針とした。われわれ以前にも銅合金を対象としたMIによるモデル化の試みは存在したが^{5,6)}，周期表上のさまざまな元素に対する網羅的な取り組みはわれわれが初めてであった⁷⁾。

2. 方 法

2.1 モデル化の方針

本研究で構築したモデルの全体像の概略を図1に示す。本研究においては，Cuと原子番号の1から86 (HからRn)の元素からなる2元固溶合金のすべてに対して，第一原理計算を用いて弾性定数と電気伝導率を計算し，データベースを作成した。機械特性のモデル化に関して

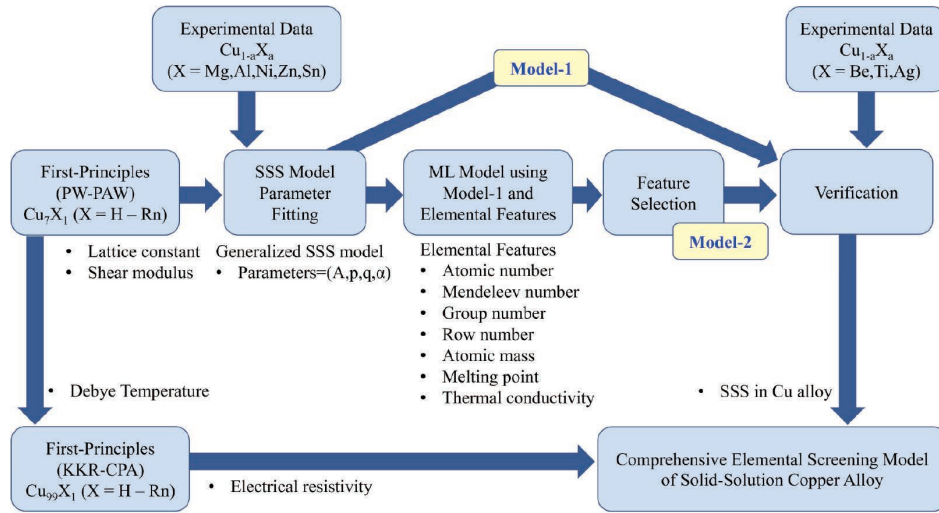


図1 本研究で開発した銅固溶合金モデルの概念図

Framework of the comprehensive elemental screening of solid solution copper alloys

は文献^{8,9)}に示されたモデル式へのフィッティングに計算結果と実験データを用い、予測モデルの改善と検証を機械学習モデルに基づいて実施した。

2.2 実験データ

サンプル作製と特性評価手法は、文献1に示されており、ここではその詳細には触れない。ただし、MIという言葉や概念が一般化する以前に、目的に合致したデータセットの整備の観点で、結晶組織の大きさと圧延率を揃えた上で、元素組成に依存したデータの取得を行った点は改めて強調しておきたい。本研究で用いたデータに対して、仕上冷間圧延において再結晶粒の粒径を40 μm 、圧延率を75%に統一して試料を作製している。固溶強化の実験値は0.2%耐力を用い、電気伝導特性は四探針法による電気抵抗率の常温での測定値を用いた。

学習用には以下の19データを用いた。Cu, Cu100-xMgx ($x = 0.7, 2, 3, 4, 5$, and 6 atom%), Cu100-xAlx ($x = 4, 8$, and 12 atom%), Cu100-xZnx ($x = 8, 13$, and 20 atom%), Cu100-xSnx ($x = 0.4, 1, 2$, and 3 atom%), Cu100-xNix ($x = 3$ and 6 atom%)。これらの添加元素は、銅固溶合金の添加元素として一般的に良く用いられる元素¹⁰⁾である。検証用には以下の6データを用いた。Cu100-xBex ($x = 12$ atom%), Cu100-xTix ($x = 0.5$ and 5 atom%), Cu100-xAgx ($x = 2, 3$, and 4 atom%)。3つの検証用データの元素は以下のような観点で選定した。Beは実験的に用意した元素の中で最も軽く、かつ高特性を示すことが知られている¹⁰⁾。Tiは遷移元素の中では高い固溶率を示しかつ高強度である¹⁰⁾。AgはCuと同族でありながら、銅固溶合金を形成することで高強度－高導電性を示すことが知られており¹⁰⁾、その特性を予測可能であることを確認するため、検証用として取り分けて (Hold-out)、学習に用いないこととした。

2.3 固溶強化のモデル化

0.2%耐力に対して、文献^{11,12)}で示された“generalized critical resolved shear stress formula”を固溶強化モデルとして用いた (以下、Model-1 とする)。Model-1 は

$$\sigma - \sigma_0 = A \cdot G \cdot \varepsilon^p \cdot x^q \quad (1)$$

と示され、ここで $\sigma - \sigma_0$ は純銅を基準とした0.2%耐力の増加量、 G はせん断弾性率、 x は添加元素のモル分率、 ε は以下に示すミスマッチパラメータ、 A, p, q は定数である。 ε は、弾性定数のミスマッチパラメータ ε_G 、格子定数のミスマッチパラメータ ε_l を用いて

$$\varepsilon = \sqrt{(\varepsilon_G)^2 + (\alpha \cdot \varepsilon_l)^2} \quad (2)$$

と表され、パラメータ α は添加元素と相互作用して固溶強化をもたらす転位の種類を示しており、 $3 < \alpha < 16$ はらせん転位、 $\alpha > 16$ は刃状転位である。また、 $\varepsilon_G, \varepsilon_l$ は

$$\varepsilon_G = \frac{\delta_G}{1 + 0.5|\delta_G|}; \quad \delta_G = \frac{1}{G} \cdot \frac{dG}{dx}; \quad \varepsilon_l = \frac{1}{l} \cdot \frac{dl}{dx} \quad (3)$$

と示される。ここで l は立方晶である銅合金の格子定数である。本研究において A, p, q, α は、第一原理計算に基づく G, l の結果を用い、0.2%耐力の実験値が式(1)に従うとしてフィッティングを行い決定した。さらに固溶強化のモデルの予言性を高めるため、特徴量として添加元素の特徴量と Model-1 を用いた機械学習モデル (以下、Model-2 とする) を検討した。フィッティングあるいは学習に用いていない検証用のデータで Model-1, Model-2 のモデル検証を行った。

2.4 第一原理計算による計算量

第一原理計算による銅固溶合金の格子定数と弾性率を評価するため、密度汎関数法に基づき、平面波基底法に




図2 銅固溶合金の添加元素による格子定数の変化量。PW-PAW は本研究での計算結果を表し、Exp. は King による実験結果を表す³⁾

Deviations of the lattice constants of solid solution copper alloys by each element




図3 銅固溶合金の添加元素による電気抵抗率上昇の計算値および実験値。(a) H から Rn までの電気抵抗率上昇。KKR-CPA は本研究による計算結果。実験値は Linde⁴⁾, Komatsu¹³⁾, Davis, et al.¹⁰⁾, と本研究によるものである。(b) 実験結果と計算結果の比較。Davis 等¹⁰⁾ の Cu-Pd 以外は、極めて良い一致を示す

Calculated and experimental electrical resistivities of solid solution copper alloys

よって電子状態を記述し、PAW 法でポテンシャルを記述する VASP ver.5.4 を用いた。交換相関相互作用の汎関数は一般化勾配近似の PBE 型を用いた。VASP による構造最適化は、FCC の Cu_7X_1 ($\text{X} = \text{H} - \text{Rn}$) の $2 \times 2 \times 2$ モデルに対して実行した。Vegard's 則に基づいて Cu との变量を

$$\begin{aligned} \varepsilon_G \equiv \varepsilon_G(X) &\equiv \frac{\delta_{G0}}{1 + 0.5|\delta_{G0}|}; & \delta_{G0} &\equiv \frac{1}{G_{\text{Cu}}} \cdot \frac{G_{\text{CuX}} - G_{\text{Cu}}}{0.125}; \\ \varepsilon_l \equiv \varepsilon_l(X) &\equiv \frac{1}{l_{\text{Cu}}} \cdot \frac{l_{\text{CuX}} - l_{\text{Cu}}}{0.125} \end{aligned} \quad (4)$$

と示す。ここで G_{Cu} と G_{CuX} はおのの Cu と Cu_7X_1 のせん断弾性定数であり、 l_{Cu} と l_{CuX} はおのの純銅と Cu_7X_1 の格子定数である。また、 $\varepsilon_G(X)$ と $\varepsilon_l(X)$ は固溶元素 X ($\text{X} = \text{H} - \text{Rn}$) の組成に依存しないせん断弾性定数のミスマッチパラメータおよび格子定数のミスマッチパラメータを表す。格子定数のミスマッチパラメータは King の報告で実験値がいくつか示されており³⁾、図2に示す通り $\varepsilon_l(X)$ の計算結果は Hg を除いて良い一致を見た。本研究においては、計算で得られた $\varepsilon_l(X)$ を用いてモデルを構築する方針とした。

電気抵抗率の評価には、完全固溶系の電子状態の計算

に適した KKR-CPA 法である SPR-KKR Ver.7.7.3 を用いた。電気抵抗率の計算は Vertex 補正有の Kubo-Greenwood 公式に従う線形応答理論で求めた。 Cu_{99}X_1 ($\text{X} = \text{H} - \text{Rn}$) の電気抵抗率の評価においては 300 K の熱揺らぎの効果を含み、磁性を有する可能性がある添加元素 ($\text{X} = \text{V} - \text{Ni}, \text{Ce} - \text{Lu}$) に対しては up スピンと down スピンの分布も完全にランダムに配置していると仮定した。これは、これらの元素を添加した Cu_{99}X_1 のキュリー温度が 300 K よりも十分に低いと仮定したことに相当する。純 Cu に対する抵抗率の変化は

$$\rho - \rho_0 = \delta\rho(X) \cdot x \quad (5)$$

と示す。この計算結果を図3(a)に示す。実験値は文献値^{4,10,13)} および本研究の測定結果を示した。文献値の実験結果も式(5)に従うとして添加元素のモル分率当たりの抵抗率の変化量として示した。図3(b)に示す通り、文献¹⁰⁾ の Cu-Pd の値以外は極めて良い一致を示した。Cu-Pd の別文献⁴⁾ の結果と本研究の計算値は良い一致を示しており、本研究のモデル化において、電気抵抗率は計算結果を用いることとした。

2.5 固溶強化のモデル

固溶強化のモデルは第一原理計算の計算量と、2.2 で説明した学習用の実験データを用いてフィッティングによりモデルを構築した。固溶強化に対する Model-1 を、

$$\text{Model-1} \equiv A \cdot G_{\text{Cu}} \cdot \varepsilon(X)^p \cdot x^q \equiv B_X \cdot x^q \quad (6)$$

と定義する。ここで $\varepsilon(X) \equiv \sqrt{\{\varepsilon_G(X)\}^2 + \{\alpha \cdot \varepsilon_i(X)\}^2}$, $B_X \equiv A \cdot G_{\text{Cu}} \cdot \varepsilon(X)^p$ を固溶元素 X (X = H - Rn) のミスマッチパラメータ因子および固溶強化因子と定義する。前述 (2.2 節) の学習用データ 19 個を用いてパラメータ A, p, q, α を数値最適化により求め、その結果を表 1 に示した。 α の巨大な値は、固溶強化に有効なのは原子サイズのミスマッチパラメータだけであり、添加元素と相互作用するのは刃状転位であることを示している。図 4 に示す通り、学習データだけでなく、学習に用いていない検証用の 6 点の実験データも決定係数 0.8 以上の良い一致を示しており、一定の予測性能を示す Model-1 が得られた。

2.6 機械学習による固溶強化のモデル化

図 4 に示した Model-1 の予測性能に対し、機械学習モデルとしてガウス過程回帰 (GPR) を採用して改善を試みた。GPR は 2 点のデータ間の類似性をそのデータ間の

表 1 Model-1 に対するパラメータの最適値
Optimal parameters of Model-1

A	p	q	α
0.03790	0.7301	0.9169	$9.533 \cdot 10^3$




図 4 学習用データ CuX (X = Mg, Al, Ni, Zn, and Sn) と検証用データ CuX (X = Be, Ti, and Ag) に対する Model-1 での固溶強化の予測と実験結果の比較
Experimental vs. calculated (Model-1) solid solution strengthening for the training and testing sets of CuX (X = Mg, Al, Ni, Zn, and Sn) and CuX (X = Be, Ti, and Ag), respectively

共分散行列で示す「カーネル」で表現し、予測値だけでなくその不確定さを分散として示す。GPR モデルのパラメータは学習データを用いて決定した。特徴量として、pymatgen¹⁴⁾ の元素に由来する 7 つのパラメータ、すなわち group number, row number, block number, atomic mass, Mendeleev number, thermal conductivity, melting point の組成比での相加平均を用いた。さらに各組成に対する Model-1 の値も特徴量として用いることで最大 8 つの特徴量を用いた GPR モデルを検討対象とした。検証データを用いた検証において、常に Model-1 は特徴量として採用することとし、残りの元素の特徴量 7 つから 0~7 つを選択し、すべての組合せに対して平均二乗誤差平方根 (RMSE) が最小となる特徴量のセットを採用する方針とした。このように構築した GPR モデルを Model-2 とし、




図 5 Model-2 の特徴量の数と、検証データに対する RMSE の関係

Number of selected features of Model-2 and RMSE for the testing set




図 6 学習用データ CuX (X = Mg, Al, Ni, Zn, and Sn) と検証用データ CuX (X = Be, Ti, and Ag) に対する Model-2 での固溶強化の予測と実験結果の比較。エラーバーは GPR で得られた標準偏差を表す
Experimental vs. predicted (Model-2) solid solution strengthening for the training and testing sets




図7 Model-1 および Model-2 にもとづく FOM による H から Rn にいたる添加元素の 2 元系銅合金の特性比較

FOM vs. atomic number as a comprehensive elemental screening

その特徴量の数と、検証データに対する RMSE の関係を図 5 に示した。図 5 中の横軸において “No. of features” = 1 は、 $\log_{10}(\text{Model-1})$ を特徴量とすることを表し、“No. of features” = N は $\log_{10}(\text{Model-1})$ と元素起因の特徴量から N-1 個の特徴量を選択した場合を表している。検証データに対する最小の RMSE は、特徴量として $\log_{10}(\text{Model-1})$ と atomic mass (平均原子質量) の 2 変数によるものであった。原子質量は周期表中で単純増加する変数であり、Model-1 で表現しきれなかった周期表中での補正を表現したものと考えられる。図 6 に示す通り、6 つの検証データに対する予言性は大変良く、決定係数 R^2 は 0.9 以上となった。

2.7 結果と考察

以上で導出したモデルに基づき 2 元系の銅固溶合金の H から Rn の間のすべての添加元素の特性評価を行った。その評価を行うにあたり、次のような figure of merit (FOM) を定義した。

$$\text{FOM} \equiv \log_{10} \left[\frac{\sigma - \sigma_0}{(\rho - \rho_0)^q} \right] \quad (7)$$

ここで Model-1 を用いた FOM は、式 (5) (6) を用いることにより

$$\text{FOM}_{\text{Model-1}} = \log_{10} \left[\frac{B_X}{\{\delta\rho(X)\}^q} \right] \quad (8)$$

と表され、添加量に対して独立であることが分かる。式 (7) (8) のように FOM を定義することにより、FOM が大きいほど、電気抵抗率の上昇を抑制しながら固溶強化を高めることが出来ることが分かる。すなわち、さまざまな添加元素に対する銅固溶合金のスクリーニングは、この FOM を用いることにより実行可能である。Model-2 の FOM は組成に依存した量となるが、ここでは、1.0 atom% の値を採用してスクリーニングを行った。得られた FOM は図 7 に示した。FOM の変化には周期的な特徴があり、価電子数 = 1 または 2 である X = Be, Mg, K, Rb, Ag, Hg で極大値をもつことが分かった。Cu の価電子数は 1 であることから、電子状態が Cu と比べて大きく




図8 Model-1 に基づき、式 (6) の電気抵抗率増加 $\delta\rho(X)$ と、式 (8) の SSS factor B_i の平面で表した 2 元系銅固溶合金の特性図。FOM= の点線は、おのの FOM の値が一定となる線を示し、右下ほど優れた特性を示すことを表す

Predicted results using Model-1 plotted in the electrical resistivity increase vs. solid solution strengthening factor plane

変化することが無いために抵抗率の上昇が抑制され、なおかつ図 2 に示した原子半径の違いにより固溶強化する元素の FOM が高いことが分かる。また、Model-1 による FOM の結果を、図 8 のように、式 (5) の抵抗率上昇 $\delta\rho(X)$ と、式 (6) の固溶強化因子 B_i の平面で描画し直した。図 8 に示したように広く用いられる固溶元素 Zn, Sn, Al, Be, Ni⁽¹⁰⁾ などは FOM が 2 未満であり、FOM が 2 を超える優れた特性を示す添加元素はあまり無いことが分かる。

FOM の上位 10 位の元素を表 2 にまとめた。Model-1, Model-2 おのおので算出したところ、Ag, Cd, In, Hg, Au, Tl, Mg, Pb の 8 元素は共通した。とくに Ag はいずれのモデルにおいても最大の FOM を示した。Cu-Ag は実用的にも強度-導電性バランスの優れた銅合金であることが知られており⁽¹⁰⁾、コスト面が見合えば最良の選択となる。続いて高い FOM を示す Cu-Cd も、Cd の毒性が知られて

表2 Model-1 および Model-2 に基づいた FOM の上位 10 元素
Top 10 elements of FOM by Model-1 and Model-2

Element	FOM _{Model-1}	Element	FOM _{Model-2}
Ag	3.140	Ag	3.085
Cd	2.601	Cd	2.552
In	2.331	In	2.280
Hg	2.331	Hg	2.225
Au	2.249	Au	2.135
Tl	2.158	Mg	2.058
Mg	2.064	Tl	2.047
Pb	1.943	K	1.837
Pd	1.887	Pb	1.824
Rb	1.878	Na	1.818

いるが、優れた強度－導電性バランスを示すことも知られている¹⁰⁾。Cu-Mg が優れた特性を示すことは既に当社の示した通りである^{1,2)}。最近の機械学習による銅合金のモデル化により Cu-In が優れた特性を示すことが予言され実証されているが⁶⁾、実用的には In の発がん性を考慮する必要がある¹⁵⁾。Cu-Au と Cu-Tl は、従来高性能であるとは報告されていない¹⁰⁾。Au の高コストや Tl の毒性、Tl の場合は固溶限の低さ¹⁶⁾が要因であると考えられる。Hg が毒性をもつ Cu-Hg は文献¹⁰⁾でも取り上げられていないが、図2に示した格子ミスマッチパラメータの従来報告されている King の実験値とのずれから、本研究での固溶強化が過大に評価されている恐れはある。Cu-Pb は快削性元素として実用的に用いられているが¹⁰⁾、固溶限が 0.09 atom% と低いこともあり¹⁶⁾、従来高性能合金とは認識されていない。Cu-Pd は、文献¹⁰⁾の抵抗率が正しければ、われわれの結果は過大評価となるが、上記で議論したようにわれわれの計算結果は Linde⁴⁾の抵抗率を再現しており、良い強度－導電性バランスを示す可能性はある。表2の他の元素 Na, K, Rb は、いずれもアルカリ金属であるが、極めて低い固溶限が知られており¹⁶⁾、現実の固溶合金として用いることは困難である。以上のように FOM で選別した元素は、従来知られている高性能合金を再現することが出来ており、未知の添加元素としては Cu-Au, Hg, Tl に可能性があることが分かった。また、強度－導電性バランスと経済性、安全性を考慮すると表2の元素の中では Cu-Mg が最良の選択と言っても過言では無い、と考えられる。

3. 結 論

包括的な元素スクリーニングのフレームワークを用いて、銅固溶合金の固溶強化と抵抗率上昇を予測した。開発したモデルにより Cu-Ag, Cu-Cd, Cu-In などの高性能

銅合金が予測された。本取組により Cu-Mg は強度－導電性バランスと経済性、安全性から最適な選択肢であると改めて確認できた。

謝 辞

NIMS-MMC-CoE での共同研究の取り組みを通じ、NIMS の出村雅彦先生、永田賢二先生、大沼郁雄先生には、本研究を進めるにあたり、多大なるご指導とご助言を賜りました。ここに感謝の意を申し上げます。本取組の初期のモデル化に貢献した三菱マテリアル筑波製作所の石垣卓也氏に感謝します。

文 献

- 1) K. Maki, Y. Ito, H. Matsunaga and H. Mori, *Scr. Mater.*, **68**, 777 (2013).
- 2) 松永裕隆, 牧 一誠, 有澤周平, 秋坂佳輝, 西村透, 森 広行, まてりあ, **56**, 88-90 (2017).
- 3) H. W. King, *J. Mater. Sci.*, **1**, 79-90 (1966).
- 4) J. O. Linde, *Helv. Phys. Acta*, **41**, 1007-1015 (1968).
- 5) C. Wang, H. Fu, L. Jiang, D. Xue and J. Xie, *NPJ Comput. Mater.*, **5**, 57-64 (2019).
- 6) H. Zhang, H. Fu, X. He, C. Wang, L. Jiang, L. Chen and J. Xie, *Acta Mater.*, **200**, 803-810 (2020).
- 7) K. Yamaguchi, T. Ishigaki, Y. Inoue, S. Arisawa, H. Matsunoshita, Y. Ito, H. Mori, K. Suehiro, K. Maki, K. Nagata and M. Demura, *Sci. Technol. Adv. Mater.: Methods*, **3**, 2250704 (2023).
- 8) R. L. Fleischer, *Acta Metall.*, **11**, 203-209 (1963).
- 9) R. Labusch, *Phys. Status Solidi B*, **41**, 659-669 (1970).
- 10) J. R. Davis (Ed.), *ASM Specialty Handbook: Copper and Copper Alloys* (ASM International, Materials Park, OH, US, 2001).
- 11) I. Wesemann, A. Hoffmann, T. Mroczek and U. Martin, *Int. J. Refract. Met. Hard Mater.*, **28**, 709-715 (2010).
- 12) M. Walbrühl, D. Linder, J. Ågren and A. Borgenstam, *Mater. Sci. Eng., A*, **700**, 301-311 (2017).
- 13) S. Komatsu, *J. Jpn. Res. Inst. Adv. Copper-base Mater. Tech.*, **41**, 1-9 (2002).
- 14) S. P. Ong, W. D. Richards, A. Jainx, G. Hautier, M. Kocher, S. Cholia, D. Gunter, V. L. Chevrier, K. Persson and G. Ceder, *Comput. Mater. Sci.*, **68**, 314-319 (2013).
- 15) M. Nakano, K. Omae, A. Tanaka and M. Hirata, *J. Occup. Health*, **61**, 251-256 (2019).
- 16) T. B. Massalski (Ed.), *Binary Alloy Phase Diagrams, II Ed.* (ASM International, Materials Park, OH, US, 1990).



山口 健志 Kenji YAMAGUCHI
開発 TMO 解析領域
主席研究員 博士 (理学)



伊藤 優樹 Yuki ITO
高機能製品カンパニー銅加工事業部技術開発部
圧延製品開発室 (三宝駐在)
室長補佐



井上 雄基 Yuki INOUE
企画部
部長補佐



末廣 健一郎 Ken'ichiro SUEHIRO
高機能製品カンパニー銅加工事業部技術開発部
銅加工開発センター
センター長



有澤 周平 Shuhei ARISAWA
三宝製作所技術部加工品課
課長



森 広行 Hiroyuki MORI
高機能製品カンパニー銅加工事業部技術開発部
開発推進室
室長 博士 (工学)



松野下 裕貴 Hirotaka MATSUNOSHITA
高機能製品カンパニー銅加工事業部技術開発部
銅加工開発センター
センター長補佐 博士 (工学)



牧 一誠 Kazunari MAKI
高機能製品カンパニー銅加工事業部技術開発部
部長 博士 (工学)