



Title	圧縮センシングにおける信号類似性の活用：省電力無線脳波計測回路システム実現に向けた取り組み
Author(s)	兼本, 大輔; 瀧本, 英智; 廣瀬, 哲也
Citation	電子情報通信学会技術研究報告. 信学技報. 2024, 124(247), p. 89-94
Version Type	VoR
URL	https://hdl.handle.net/11094/102211
rights	Copyright©2024 IEICE
Note	This document is a technical report published in the IEICE Technical Report issued by the Institute of Electronics, Information and Communication Engineers in November 2024. Please refer to the paper published in IEEE ISCAS 2025 for the latest results demonstrating lower power dissipation (CR = 6, 72 μ W/ch, NMSE = 0.116). DOI: 10.1109/ISCAS56072.2025.11043415, or the open-access version (OUKA): https://hdl.handle.net/11094/102085

The University of Osaka Institutional Knowledge Archive : OUKA

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

The University of Osaka

圧縮センシングにおける信号類似性の活用 ～省電力無線脳波計測回路システム実現に向けた取り組み～

兼本大輔[†] 瀧本英智[†] 廣瀬哲也[†]

† 大阪大学工学研究科 〒565-0871 大阪府吹田市山田丘 2-1

E-mail: †dkanemoto@eei.eng.osaka-u.ac.jp

あらまし センシング集積回路の省電力化を目指し、回路が処理する情報量を大幅に削減できる圧縮センシングが注目されている。しかし、信号のスパース性が低い場合、再構成精度が低下し、圧縮比を上げるのが難しくなるという課題が存在する。そこで我々は、信号の類似性に着目することでスパース性の改善を行い、高精度な再構成と高圧縮による省電力の両立を可能にする圧縮センシングの新手法を提案している。本研究では、この手法を無線脳波伝送システムに応用し、高い再構成精度を保つつつ、送信デバイスに搭載したマイクロコントローラ (Nordic Semiconductor nRF52840) の消費電力削減効果を実機で確認した。検証の結果、対象信号に対して等価的 40Hz サンプリングで圧縮 (5 倍圧縮) を行った場合でも、高い再構成精度を実現しつつ、消費電力を $83.2\mu\text{W}/\text{ch}$ に抑えられることが確認できた。本成果は、従来の省電力記録に対して 14% の改善を達成したことを意味する。

キーワード 圧縮センシング、低消費電力、信号類似性、脳波、ランダムアンダーサンプリング

Utilization of Signal Similarity in Compressed Sensing

–Realizing Low-power Dissipation Wireless EEG Monitoring Circuit System–

Daisuke KANEMOTO[†], Eichi TAKIMOTO[†], and Tetsuya HIROSE[†]

† Graduate School of Engineering, Osaka University 2-1 Yamadaoka, Suita, Osaka, 565-0871 Japan

E-mail: †dkanemoto@eei.eng.osaka-u.ac.jp

Abstract In order to achieve power-saving in sensing integrated circuits, there is a lot of interest in compressed sensing, which can greatly reduce the amount of information handled by the circuit. However, when the signal is not sparse, the accuracy of reconstruction deteriorates, making it difficult to increase the compression ratio. Therefore, we have proposed a new method of compressed sensing that improves the sparsity of the signal by focusing on the similarity of the signal, and enables both high-precision reconstruction and power saving through high compression. In this study, we applied this method to a wireless EEG transmission system and confirmed the effect of reducing the power consumption of the microcontroller (Nordic Semiconductor nRF52840) mounted on the transmission device while maintaining high reconstruction accuracy. As a result of the verification, it was confirmed that even when the signal was compressed (5x compression) at an equivalent 40Hz sampling rate, the power consumption could be kept to $83.2\mu\text{W}/\text{ch}$ while maintaining high reconstruction accuracy. This result means that a 14% improvement has been achieved over conventional power-saving recording.

Key words Compressed sensing, low-power dissipation, signal similarity, EEG, random undersampling

1. まえがき

デジタルトランスフォーメーション (DX: Digital Transformation) は、産業、社会、個人生活など様々な分野を革新する情報通信分野の中心技術になりつつある [1]。DX を実現するには、自然界の情報を大量かつ高精度にセンシングする必要があ

り、今後、センサーの開発がますます重要になることが予測される。センサーデバイスの運用において、省電力化は極めて重要な課題であり、センサーデバイスに搭載する集積回路の低消費電力化に関する研究が進められている (例えば [2])。しかし、近年の微細加工技術の進展によるセンシング回路の性能向上が限界に近づいており、さらなる電力削減を実現するために他の

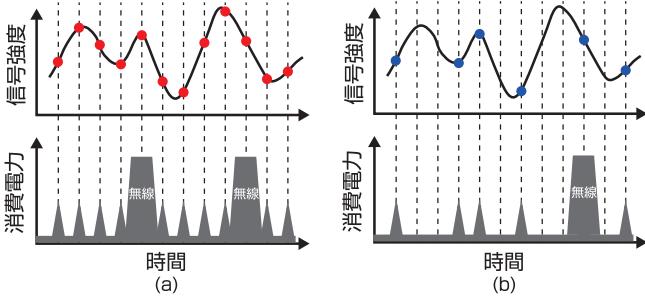


図 1 等間隔サンプリングに比べ、ランダムアンダーサンプリングを行った場合、サンプリング回数の削減と無線送信回数を削減できるため、省電力化が可能

Fig. 1 Compared to equally spaced sampling, random undersampling reduces the number of sampling cycles and the number of radio transmissions, thus saving power.

手法を模索する必要性がますます高まっている。つまり、今後の省電力化には、集積回路の進化に依存せず、ソフトウェアとハードウェアの協調による新たな設計アプローチなど、革新的な取り組みが重要となる。

そこで我々は、新しい試みの一つとして、ランダムアンダーサンプリングを用いた圧縮センシング [3] に注目している。図 1(a) は従来の等間隔サンプリングを行うシステムの動作と消費電力を、図 1(b) は圧縮センシングシステムを想定したランダムアンダーサンプリングの動作と消費電力を示している。一般的に、サンプリングのタイミングで消費電力が発生し、無線でデータを送る度に多くの消費電力が発生する。つまり、等間隔サンプリングに比べ、ランダムアンダーサンプリングを行うことで扱うデータを削減でき、サンプリング時や無線送信時の電力消費を抑えることができる。本手法は消費電力を削減する点で非常に有効な手段であり、例えば、無線脳波計の実現にランダムアンダーサンプリングを積極的に活用し、A/D 変換器 [4] や増幅器 [5], [6]、またシステム全体 [7] の省電力化が可能であることが示されている。また、脳波などの一次元信号に対するセンシングのみならず、画像への応用実績(例えば [8], [9])もあり、幅広い信号への応用に期待が集まっている。

一方、圧縮センシングにおける再構成では、センシング対象信号が有するスパース性を活用するため、信号のスパース性が十分でない場合、再構成精度が劣化する課題がある。そこで我々は、信号類似性に着目し、過去信号を活用した基底を生成することで高精度な再構成が可能な手法を提案している [10]。本研究では、圧縮センシングにおける信号類似性を活用することで、無線脳波伝送における省電力並びに高精度再構成を実現できることを実機を通して確認することを目的として行った。

本論文では 2 章に圧縮センシングの基本的な説明を説明する。3 章では信号類似性を活用した手法の紹介を行う。4 章にて本手法を無線脳波伝送システムに応用した場合の検証結果を述べる。そして 5 章にて本論文をまとめる。

2. 圧縮センシングに関する数理の基礎

本章では、圧縮センシングを用いた計測システムを説明する

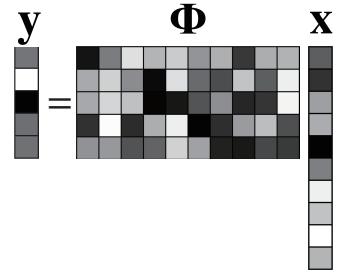


図 2 観測行列 Φ を用いてセンシング対象信号 x を圧縮し、圧縮信号 y を得る。

Fig. 2 Compresses the signal to be sensed x using the observation matrix Φ to obtain the compressed signal y .

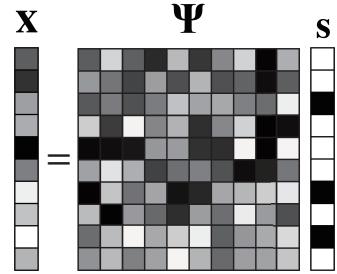


図 3 適切な基底行列 Ψ が存在すれば、 x は基底行列とスパースベクトル s に分解可能。

Fig. 3 Given a suitable basis matrix Ψ , x can be decomposed into a basis matrix and a sparse vector s .

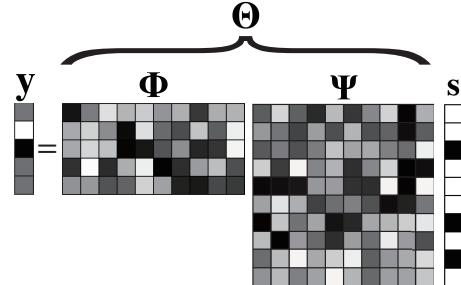


図 4 センシング行列 Θ を用いると、圧縮信号 y とスパースベクトル s は線形写像により結び付けられる。

Fig. 4 Using the sensing matrix Θ , the compressed signal y and the sparse vector s are related by a linear mapping.

上で必要となる数理について説明する。あるセンシング対象信号に対し、一定時間 Δt 秒ごとにおける信号強度を要素として持つベクトルを $\mathbf{x} \in \mathbb{R}^N$ と定義する。ベクトルの各要素の濃淡は信号強度を示しており、濃いほど強度が強く、白はゼロを示す。

始めに \mathbf{x} の圧縮について説明する。圧縮信号 $\mathbf{y} \in \mathbb{R}^M$ は、観測行列 $\Phi \in \mathbb{R}^{M \times N}$ と \mathbf{y} の行列ベクトル積

$$\mathbf{y} = \Phi \mathbf{x}, \quad (1)$$

で表現できる。ここで、 $M < N$ の場合、 \mathbf{y} は \mathbf{x} に比べて要素数が減少しており、信号圧縮が行われていることがわかる。図 2 は $M = 5$ の例を示している。ここで、圧縮比 (Compressed Ratio:CR) を $CR = N/M$ と定義した場合、図 2 は $CR = 2$ となり、 \mathbf{x} に対して \mathbf{y} はデータ量を半分に圧縮できていると解釈できる。圧縮センシングにおいて、圧縮は行列ベクトル積で実現

可能であるが、一般的には直接 \mathbf{y} から \mathbf{x} を再構成することは難しい。それは、 $M < N$ を満たす Φ は横長行列であり、原理上逆行列が求まらず、 \mathbf{y} と Φ から \mathbf{x} が一意に決まらない（劣決定系）ためである。そこで圧縮センシングでは、センシング対象の信号 \mathbf{x} が有するスパース性に着目し、問題解決を行う。

ここで \mathbf{x} は、ある基底行列 $\Psi \in \mathbb{R}^{N \times P}$ と、ほとんどの要素が 0 のスパースベクトル $\mathbf{s} \in \mathbb{R}^P$ を用い

$$\mathbf{x} = \Psi \mathbf{s}, \quad (2)$$

が成り立つと仮定する。図 3 は非ゼロ要素数が 3 の例であり、スパース性が高い例を示している。たしかに、どのような \mathbf{x} に對しても式 (2) の表現、つまり \mathbf{x} が特定の基底行列とスパースベクトルとの積で表現できることは保証されていない。しかし、例えば脳波は α 波や β 波など、周期的な信号波の合成で表現できる傾向があり、 Ψ を逆フーリエ変換や逆離散コサイン変換に代表される逆変換行列を用いると、 \mathbf{x} を Ψ とスパースベクトルとの行列ベクトル積で表現できる可能性が高く、式 (2) を満たす場合はある。さらに、3. 章で解説するが、信号の類似性に着目し、すでに過去得られた多くの既知信号を活用することで、対象信号をスパースベクトルとの積に表現可能な Ψ を生成できれば、式 (2) が成り立つ状況は多い。

そこで、ここでは \mathbf{x} をスパースベクトルに表現できる基底が存在すると仮定して議論を進める。圧縮センシングでは式 (1) と式 (2) を用い、

$$\mathbf{y} = \Phi \mathbf{x} = \Phi \Psi \mathbf{s} = \Theta \mathbf{s}, \quad (3)$$

の関係を活用する（図 4）。式 (3) は、観測で得られた \mathbf{y} は、未知のスパースベクトル \mathbf{s} に対して既知の行列であるセンシング行列 Θ の写像で表現できることを示している。そこで、圧縮センシングを用いた対象信号の再構成では、既知のベクトルと行列である \mathbf{y} と Θ を使用して、まずはよりスパースなベクトル $\hat{\mathbf{s}}$ を求める以下の最適化問題から考えることに相当する。

$$\hat{\mathbf{s}} = \arg \min_{\mathbf{s}} \|\mathbf{s}\|_0 \quad \text{subject to} \quad \mathbf{y} = \Theta \mathbf{s}, \quad (4)$$

ここで、 $\|\cdot\|_0$ は ℓ_0 ノルムを意味し、ベクトル内の非ゼロ要素の数を示している。式 (4) は $\mathbf{y} = \Theta \mathbf{s}$ の制約を満たしつつ、最も非ゼロ数が少ない最適なスパース表現 $\hat{\mathbf{s}}$ を見つけ出す ℓ_0 最適化問題を意味する。ただし、 ℓ_0 最適化問題は計算上の困難さから直接解く事は難しい（NP 困難）[11]。そこで、現実的な方法で $\hat{\mathbf{s}}$ を見つけ出すための様々な手法が提案されている。例えば、式 (4) の ℓ_0 ノルムの代わりに ℓ_1 ノルムに置き換えた後、 ℓ_1 ノルムを最小化することでスパースな解を再構成する手法として基底追跡 (basis pursuit : BP) などのアルゴリズムが利用される[12]。また、式 (4) をいくつかの局所的な部分問題に分割し、局所的に最も良いものを逐次的に取り込んでいく貪欲法のアルゴリズムもスパースベクトルの再構成アルゴリズムとして利用されている。例えば、直行マッチング追跡 (Orthogonal Matching Pursuit : OMP) は有名な貪欲法の一種であり、多くの圧縮センシングシステムにおけるスパースベクトルの再構成に利用されている[13]。一方で、計算負荷が高いが、信号のブロック構造

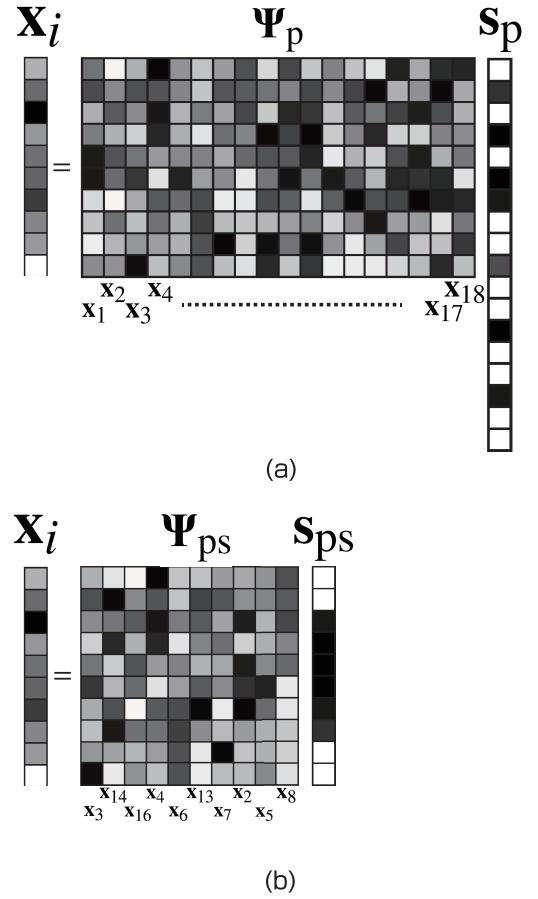


図 5 (a) 過去信号 \mathbf{x}_1 から \mathbf{x}_{18} を並べて基底を生成。過去信号とセンシング対象信号 \mathbf{x}_i との間には相関があるため、スパースベクトル \mathbf{s}_p が得られる可能性が高い。(b) 利用される可能性が高い過去信号のみを集めてコンパクトな基底 Ψ_{ps} を生成。

Fig. 5 (a) Generate a basis by arranging the past signals from past signal \mathbf{x}_1 to \mathbf{x}_{18} . Because there is a correlation between the past signals and the sensing target signals, it is highly likely that a sparse vector, \mathbf{s}_p , will be obtained. (b) A compact basis, Ψ_{ps} , is generated by collecting only the past signals that are likely to be used.

に着目したベイズ推定を行うことで、高精度にスパースベクトルを再構成することができるブロックスパースベイジアン学習 (block sparse Bayesian learning : BSBL) を活用したアルゴリズムも広く利用されている[14]。そして様々なアルゴリズムを活用し $\hat{\mathbf{s}}$ を導出することで、最終的に

$$\hat{\mathbf{x}} = \Psi \hat{\mathbf{s}}, \quad (5)$$

の関係式から、再構成した信号 $\hat{\mathbf{x}}$ が得られる。

3. 信号類似性に着目した基底生成技術

2. 章で説明した通り、信号をスパース表現できる基底を開発することは、圧縮センシングの再構成精度向上の観点や、圧縮比を高めるために重要になる。そこで、我々は様々な観点から基底の研究を進め（例えば[15]など）、最近は以下の 2 つの観点から新しい基底生成技術に関する研究を行っている。それは、自然界の信号は取得するセンシング対象の信号と過去取得した信

号には高い相関があること(例えば[16]), また一般的に生物学的信号として用いられる \mathbf{x} はブロック/グループ構造を持つこと(例えば[17])である。つまり, 適切な Ψ を用いることで, \mathbf{s} は g 個のブロックで表現できると仮定でき

$$\mathbf{s} = [\underbrace{s_1, \dots, s_{d_1}}_{\mathbf{s}_1^T}, \dots, \underbrace{s_{d_{g-1}+1}, \dots, s_{d_g}}_{\mathbf{s}_g^T}]^T \quad (6)$$

この式が得られることが予測できる。式(6)の例では, g 個のブロックのうち, j 個 ($j > g$) のブロックのみが非ゼロである。BSBL は, ブロック内の相関を考慮することで, 高い再構成精度が期待できるため, 圧縮センシングの数理を活用したシステムにおいて注目を集めている[18]。そこで我々は上記 2 つの観点は BSBL と互換性があることに注目し, 信号類似性を活用した基底生成技術を研究している。

ここでは例として, 本手法の概要を図 5 を用いて紹介する。図 5(a) は, 測定対象の脳波信号 \mathbf{x}_i , スペースベクトル \mathbf{s}_p , および Ψ_p の関係を示しており, 例えば, 過去に取得した脳波信号 $\mathbf{x}_1 - \mathbf{x}_{18}$ を単純に 18 個並べた基底行列 Ψ_p を次式で定義する

$$\Psi_p \stackrel{\text{def}}{=} [\mathbf{x}_1 \mathbf{x}_2 \cdots \mathbf{x}_{18}]. \quad (7)$$

本例では, \mathbf{x}_i が信号 \mathbf{x}_2 および \mathbf{x}_4 と高い相関を持つ場合, \mathbf{s}_p における \mathbf{x}_2 および \mathbf{x}_4 に対応する要素は大きな値で表示される。また使用する脳波信号の数が多いほど, スペースベクトルに高い相関を持つ要素が存在する可能性が高くなることが考えられる。しかし, 複数の脳波信号を用いる手法では基底行列のサイズが大きくなり, 再構成に時間がかかる。また, $\mathbf{x}_1 - \mathbf{x}_{18}$ が互いに無関係に並べられた場合, \mathbf{x}_i と相関の高い信号が近傍に配置されない可能性は高く, \mathbf{s}_p の非ゼロ要素の位置がブロック構造になりにくい。したがって、図 5(b) に示すように使用する EEG 信号を選択して並べ替えることで, 疎なベクトル内の任意の位置に非ゼロ要素の位置を配置し, ブロック構造を人工的に実現できる。この行列を用いて得られる \mathbf{s}_{ps} は, 非ゼロ要素のブロックを生成できるため, BSBL アルゴリズムによる再構成に適している。本研究では, EEG 信号の $\mathbf{x}_1 - \mathbf{x}_{18}$ の平均周波数を算出し, 平均周波数の値でソートし, 平均周波数の分布に基づいた出現率の高い周波数を過去信号として用いることで, 基底行列の列数を効率よく削減する手法を採用した。

4. 信号類似性に着目した省電力脳波無線伝送システムの検証

本研究では, 信号類似性に着目した圧縮センシングを応用した省電力脳波無線伝送システムを構築し, 有効性を検証した。脳波信号のテストデータとして, CHB-MIT 頭皮脳波データベース[19]に基づく発作症状期を避けた FP1-F7 チャンネルデータを用いた。この評価では, 1 フレーム長を 2.5 秒とし, 256Hz サンプリングを 200Hz サンプリングにリサンプリングして検証に用いた。全フレームに対して直流成分カットを行った後, 絶

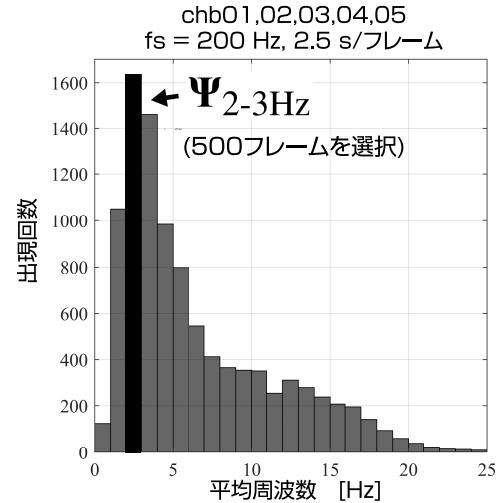


図 6 DC カットを行い, $150\mu\text{V}$ 以上の信号を含むフレームを除いた chb01 から chb05 までの EEG データ(各 2000 フレーム)に対して平均周波数を計算し, その結果をヒストグラム化した。最も頻度が高い 2-3Hz を 500 フレーム用いて基底行列 $\Psi_{2-3\text{Hz}}$ を生成し本検証の再構成処理に用いた。

Fig. 6 The mean frequency was calculated for the EEG data from chb01 to chb05 (2000 frames each) excluding the frames containing signals above $150\mu\text{V}$ by DC cut, and the results were histogrammed. The basis matrix $\Psi_{2-3\text{Hz}}$ was generated using the 500 frames with the highest frequency of 2-3 Hz.

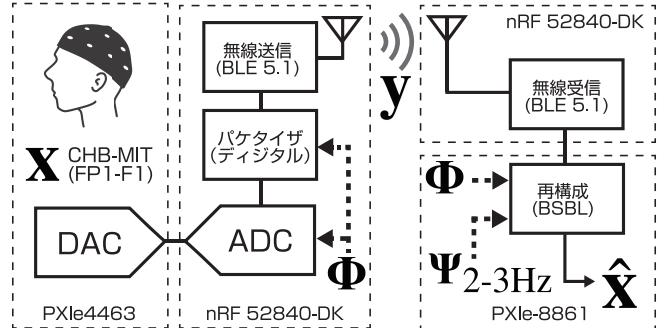


図 7 検証に用いたシステムブロック図。送信側のマイコンと受信側の再構成を実施する PC はランダムアンダーサンプリングを実現するための Φ を用いた。また受信側は作成した基底行列 $\Psi_{2-3\text{Hz}}$ を利用し再構成を行う。

Fig. 7 System block diagram used for verification. The microcontroller of transmitter and the PC of receiver that performs reconstruction use Φ to realize random undersampling. The receiver uses a basis matrix $\Psi_{2-3\text{Hz}}$ for reconstruction.

対振幅が $150\mu\text{V}$ を超えるフレームは単純にアーチファクトと判断して除外処理を行った。信号類似性を活用した基底は, テストデータを生成した被験者である chb14 と異なる chb01, 02, 03, 04, 05 (各 2,000 フレーム) を活用し, テストデータと同じく DC カットとアーチファクトフレームの除外処理を行っている。先に得られた信号(10,000 フレーム)の平均頻度分布を図 5 に示す。今回の評価では, 2 から 3Hz に分布が集中していることが分かるため, そのデータを 500 フレーム使い, 基底 $\Psi_{2-3\text{Hz}}$ を生成した。図 7 は今回の検証に用いた実験系のブロック図を, 図 8 は検証に用いたシステムの全体写真を示している。送

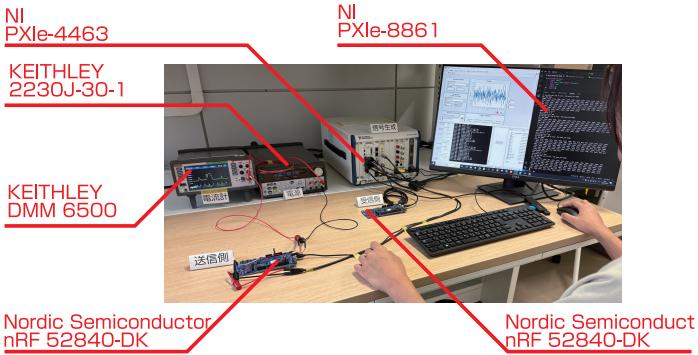


図 8 検証に用いたシステムの写真。通信を行なながら再構成処理と電力計測を行った。

Fig. 8 Photograph of the system used for verification. The system is capable of performing reconstruction and power measurement while communicating.

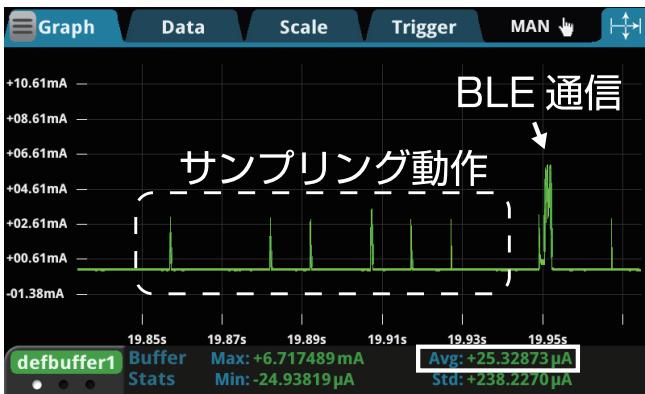


図 9 計測器を用いて通信時の電流を計測した結果。ランダムアンダーサンプリングによる疎らなサンプリング動作後に、BLE の通信に係る電力消費が確認できる。本フレームの平均消費電流は $25.3\mu\text{A}$ である。

Fig. 9 Results of measuring the current during communication using an instrument. The power consumption for BLE communication can be confirmed after sparse sampling operation by random undersampling. The average current consumption during this frame is $25.3\mu\text{A}$.

信・受信両側に 3.3V 電源で動作する nRF 52840 のマイクロコントローラチップが搭載された評価ボード (nRF 52840-DK) を用い、通信には BLE5.1 を採用した。送信側は電源とマイクロコントローラの間にデジタル電流計 DMM 6500 (KEITHLEY) を用いた。受信信号は PXIe-8861 において、BSBL アルゴリズム (Python3 で実装) を用い、再構成処理を行った。本検証には chb14 の 12 フレーム分のデータを使用し、10 パターンの Φ をあらかじめ生成・利用することで、再構成精度の 120 フレーム平均値が算出できるようにした。今回のシステムでは $CR=5$ を採用したため、等価的なサンプリングレートは 40Hz である。

本検証で得られた電流波形を図 9 に示す。ランダムアンダーサンプリングによる疎らなサンプリング動作後に、BLE の通信に係る電力消費が発生している事が確認できる。本フレーム内における消費電流は $25.3\mu\text{A}$ であり、120 フレーム分の平均消費電流は $25.2\mu\text{A}$ となったため、実装したシステムでは消費電力を $83.2\mu\text{W}/\text{ch}$ に抑えられることが分かった。

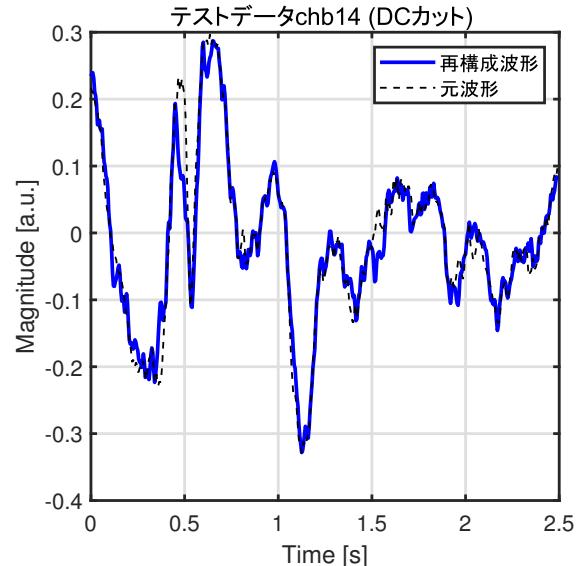


図 10 $CR=5$ における信号類似性を活用した再構成信号波形は元信号と非常に近いことが分かる。

Fig. 10 The reconstructed signal waveform utilizing signal similarity at $CR=5$ is close to the original signal.

図 10 は再構成結果をしており、この結果からも再構成信号は元信号と非常に近い値で復元できていることが分かる。

表 1 にて、今回得られた検証結果と他の無線脳波伝送システムとの比較を行った。文献 [7] は圧縮センシングを採用しており、基底は DCT で再構成アルゴリズムとして OMP を採用している。文献 [20], [21] は等間隔サンプリングをベースとしたシステムである。圧縮センシングを活用したシステムは省電力動作が可能であることが分かるが、本検証結果は省電力だけでなく再構成精度の改善も大幅に実現できただけでなく、従来の省電力記録に対して 14% の改善を達成したことを意味する。

5. まとめ

本研究では、信号の類似性に着目した新しい基底生成技術を応用し、高精度な再構成と省電力効果を両立する圧縮センシングシステムの動作検証を行った。無線脳波伝送システムに応用し、再構成精度の向上と送信デバイスに搭載した nRF52840 の消費電力削減効果を実機で確認した。検証の結果、対象信号に対して等価的 40Hz サンプリングで圧縮 (5 倍圧縮) を行った場合でも非常に高い再構成精度を達成し、同時に nRF52840 の消費電力を $83.2\mu\text{W}/\text{ch}$ に抑えることができた。本成果は、従来の省電力記録に対して 14% の改善を達成したことを意味する。

謝 辞

本研究は JSPS 科研費 JP24K02914 の助成を受けたものです。本研究は JKA 財団の支援を受けて実施したものである。

文 献

- [1] U. Ahrend, M. Aleksy, M. Berning, J. Gebhardt, F. Mendoza, and D. Schulz, "Sensors as the basis for digitalization: New approaches in instrumentation, IoT-concepts, and 5G," *Internet Things*, vol. 15, pp. 1–16, Sep. 2021.
- [2] H.-S. Ku, S. Choi, and J.-Y. Sim, "A $12\mu\text{s}$ -conversion, 20mK -

表1 無線脳波伝送デバイスの実証における諸特性比較。

Table 1 Comparison of various characteristics in demonstration of wireless EEG transmission devices.

	本検証結果	T. Miyata et al. [7]	A.Dementyev et al. [20]	T.Torfs et al. [21]
消費電力 [μ W]	83.2 ⁽¹⁾	97 ⁽¹⁾	432 ⁽²⁾	495
チャネル数	1	1	1+DRL	2
圧縮比	5倍	4倍	N/A	N/A
再構成アルゴリズム, 基底	BSBL, 類似性を活用した基底	OMP, DCT	N/A	N/A

⁽¹⁾ nRF52840 (ADC, パケタイザ, 無線送信 (BLE 5.1))⁽²⁾ EEGWISP パート

resolution temperature sensor based on SAR ADC,” *IEEE J. Solid-State Circuits Syst. II, Exp. Briefs*, vol. 69, no. 3, pp. 789–793, Mar. 2021.

- [3] D. L. Donoho, “Compressed sensing,” *IEEE Trans. Inf. Theory*, vol. 52, no. 4, pp. 1289–1306, Apr. 2006.
- [4] Y. Okabe, D. Kanemoto, O. Maida, and T. Hirose, “Compressed sensing EEG measurement technique with normally distributed sampling series,” *IEICE Trans. Fundamentals*, vol. E105-A, no. 10, pp. 1429–1433, Oct. 2022.
- [5] K. Mii, D. Kanemoto, and T. Hirose, “0.36 μ w/channel capacitively-coupled chopper instrumentation amplifier in EEG recording wearable devices for compressed sensing framework,” *Jpn. J. Appl. Phys.*, vol. 63, 03SP54, 2024.
- [6] R. Matsubara, D. Kanemoto, and T. Hirose, “Reducing power consumption in LNA by utilizing EEG signals as basis matrix in compressed sensing,” in *Proc. IEEE Int. Symp. Circuits Syst. (ISCAS)*, May 2024, pp. 1–5.
- [7] T. Miyata, D. Kanemoto, and T. Hirose, “Random undersampling wireless EEG measurement device using a small TEG,” in *Proc. IEEE Int. Symp. Circuits Syst. (ISCAS)*, May 2023, pp. 1–5.
- [8] Y. Harada, D. Kanemoto, T. Inoue, O. Maida, and T. Hirose, “Image quality improvement for capsule endoscopy based on compressed sensing with K-SVD dictionary learning,” *IEICE Trans. Fundamentals*, vol. E105-A, no. 4, pp. 743–747, Apr. 2022.
- [9] D. Kanemoto, J. Spaulding, and B. Murmann, “Single-chip mixer-based subarray beamformer for sub-nyquist sampling in ultrasound imaging,” *Jpn. J. Appl. Phys.*, vol. 60, SBBL08, 2021.
- [10] D. Kanemoto and T. Hirose, “EEG measurements with compressed sensing utilizing EEG signals as the basis matrix,” in *Proc. IEEE Int. Symp. Circuits Syst. (ISCAS)*, May 2023, pp. 1–5.
- [11] B. K. Natarajan, “Sparse approximate solutions to linear systems,” *SIAM J. Comput.*, vol. 24, no. 2, pp. 227–234, Apr. 1995.
- [12] S. S. Chen, D. L. Donoho, and M. A. Saunders, “Atomic decomposition by basis pursuit,” *SIAM J. on Sci. Comp.*, vol. 20, no. 1, pp. 33–61, Jan. 1998.
- [13] J. A. Tropp and A. C. Gilbert, “Signal recovery from random measurements via orthogonal matching pursuit,” *IEEE Trans. Inf. Theory*, vol. 53, no. 12, pp. 4655–4666, Dec. 2007.
- [14] Z. Zhang and B. D. Rao, “Extension of SBL algorithms for the recovery of block sparse signals with intra-block correlation,” *IEEE Trans. Signal Process*, vol. 61, no. 8, pp. 2009–2015, Apr. 2013.
- [15] K. Nagai, D. Kanemoto, and M. Ohki, “Applying K-SVD dictionary learning for EEG compressed sensing framework with outlier detection and independent component analysis,” *IEICE Trans. Fundamentals*, vol. E104-A, no. 9, pp. 1375–1378, Sep. 2021.
- [16] M. Fira and L. Goras, “Comparison of inter-and intra-subject variability of P300 spelling dictionary in EEG compressed sensing,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 7, no. 10, pp. 366–371, Apr. 2016.
- [17] Y. C. Eldar, P. Kuppinger, and H. Bolcskei, “Block-sparse signals : uncertainty relations and efficient recovery,” *IEEE Trans. Signal Process*, vol. 58, no. 6, pp. 3042–3054, Jun. 2010.
- [18] T. Miyata, D. Kanemoto, and T. Hirose, “Utilizing previously acquired BSBL algorithm parameters in the compressed sensing framework for eeg measurements,” in *Proc. IEEE Int. Conf. Consum. Electron. (ICCE)*, Jan. 2024, pp. 1–5.
- [19] A. Shoeb, *Application of Machine Learning to Epileptic Seizure Onset* *Detection and Treatment*, Sep. 2009.

[20] A. Dementyev and J. R. Smith, “A wearable uhf rfid-based EEG system,” in *Proc. IEEE Int. Conf. RFID*, Apr. 2013, pp. 1–7.[21] T. Torfs, V. Leonov, R. F. Yazicioglu, P. Merken, C. V. Hoof, R. J. Vullers, and B. Gyselinckx, “Wearable autonomous wireless electroencephalography system fully powered by human body heat,” *SENSORS*, pp. 1269–1272, Dec. 2008.