

(19)日本国特許庁(JP)

(12)特許公報(B2)

(11)特許番号  
特許第7359850号  
(P7359850)

(45)発行日 令和5年10月11日(2023.10.11)

(24)登録日 令和5年10月2日(2023.10.2)

(51)国際特許分類 F I  
A 6 1 B 8/14 (2006.01) A 6 1 B 8/14

請求項の数 15 (全23頁)

(21)出願番号	特願2021-521781(P2021-521781)	(73)特許権者	590000248
(86)(22)出願日	令和1年10月22日(2019.10.22)		コーニンクレッカ フィリップス エヌ
(65)公表番号	特表2022-505511(P2022-505511 A)		ヴェ
(43)公表日	令和4年1月14日(2022.1.14)		Koninklijke Philips N.V.
(86)国際出願番号	PCT/EP2019/078739		オランダ国 5 6 5 6 アーヘー アイン
(87)国際公開番号	WO2020/083918		ドーフエン ハイテック キャンパス 5 2
(87)国際公開日	令和2年4月30日(2020.4.30)		High Tech Campus 5 2 ,
審査請求日	令和4年8月16日(2022.8.16)		5 6 5 6 AG Eindhoven , N
(31)優先権主張番号	18202469.5		etherlands
(32)優先日	平成30年10月25日(2018.10.25)	(74)代理人	100122769
(33)優先権主張国・地域又は機関	欧州特許庁(EP)		弁理士 笛田 秀仙
(31)優先権主張番号	19164249.5	(74)代理人	100163809
(32)優先日	平成31年3月21日(2019.3.21)		弁理士 五十嵐 貴裕
	最終頁に続く	(72)発明者	ライテン ウォウター マリヌス ベンジ
			最終頁に続く

(54)【発明の名称】 超音波信号の適応ビームフォーミングの方法及びシステム

(57)【特許請求の範囲】

【請求項 1】

超音波信号の適応ビームフォーミングのための方法であって、

a) 超音波送信にตอบสนองして複数の超音波トランスデューサ素子によって取得されたRF信号を受信するステップと、

b) 訓練済み人工ニューラルネットワークを前記RF信号に適用することによって、前記RF信号をビームフォーミングするためのコンテンツ適応アポダイゼーション重みを決定するステップと、  
を有する方法。

【請求項 2】

前記訓練済み人工ニューラルネットワークの入力ノードの数及び出力ノードの数は、寄与するRF信号の数に対応する、請求項1に記載の方法。

【請求項 3】

c) 前記コンテンツ適応アポダイゼーション重みを前記RF信号に適用して、ビームフォーミングされた出力信号を計算するステップ、を更に有する、請求項1又は2に記載の方法。

【請求項 4】

前記訓練済み人工ニューラルネットワークは、正及び負の入力値の両方を無境界の出力値で伝播させる活性化関数を含む少なくとも一つの活性化層を有する、請求項1乃至3のいずれか1項に記載の方法。

## 【請求項 5】

前記訓練済み人工ニューラルネットワークは、入力値の前記正の部分と前記負の部分とを連結する活性化関数を含む少なくとも1つの活性化層を含む、請求項4に記載の方法。

## 【請求項 6】

前記人工ニューラルネットワークが、最大で4つの完全結合層を有する、請求項1乃至5のいずれか1項に記載の方法。

## 【請求項 7】

前記人工ニューラルネットワークは、最大で3つの活性化層を有する、請求項1乃至6のいずれか1項に記載の方法。

## 【請求項 8】

前記ビームフォーミングされた出力信号は、視野の超音波画像を再構成するために使用され、前記超音波画像の1つ又は多くとも数ピクセルに関するRFデータが前記訓練済み人工ニューラルネットワークによって1つ又は複数のバッチで処理されるように、前記RF信号が、前記訓練済み人工ニューラルネットワークを適用する前に再配置される、請求項1乃至7のいずれか1項に記載の方法。

10

## 【請求項 9】

前記訓練済み人工ニューラルネットワークが、1つ又は複数の完全結合層及びノ又は少なくとも1つの畳み込み層を有する、請求項1乃至8のいずれか1項に記載の方法。

## 【請求項 10】

前記訓練済み人工ニューラルネットワークは、反復ニューラルネットワークの一部である、請求項1乃至9のいずれか1項に記載の方法。

20

## 【請求項 11】

前記訓練済み人工ニューラルネットワークの重みの一部又は全部が量子化され又は1～4ビットに量子化される、請求項1乃至10のいずれか1項に記載の方法。

## 【請求項 12】

前記訓練済み人工ニューラルネットワークは、前記訓練済み人工ニューラルネットワークの入力層及びノ又は出力層よりも少ない数のノードを有する少なくとも1つの隠れ層を有する、請求項1乃至11のいずれか1項に記載の方法。

## 【請求項 13】

超音波信号のコンテンツ適応ビームフォーミングに有用な訓練済み人工ニューラルネットワークを提供する方法であって、

30

(a) 入力トレーニングデータ又は超音波送信にตอบสนองして複数の超音波トランスデューサ素子によって取得されたRF信号を受信するステップと、

(b) 出力トレーニングデータを受信するステップであって、前記出力トレーニングデータは、コンテンツ適応アポダイゼーション重みであり、前記コンテンツ適応アポダイゼーション重みが、コンテンツ適応ビームフォーミングアルゴリズムによってRF信号から計算されるか、又は前記出力トレーニングデータが前記コンテンツ適応ビームフォーミングアルゴリズムによって前記RF信号から計算されるビームフォーミングされた出力信号である、ステップと、

(c) 前記入力トレーニングデータ及び前記出力トレーニングデータを使用することによって人工ニューラルネットワークを訓練するステップと、

40

(d) 訓練済み人工ニューラルネットワークを提供するステップと、  
を有する方法。

## 【請求項 14】

コンピュータユニットによってコンピュータプログラムが実行される場合に、前記コンピュータユニットに請求項1乃至13のいずれか1項に記載の方法を実行させる命令を有するコンピュータプログラム。

## 【請求項 15】

超音波信号の適応ビームフォーミングのためのシステムであって、

a) 超音波送信にตอบสนองして複数の超音波トランスデューサ素子によって取得されるRF

50

信号を受信する第 1 のインターフェースと、

b) 前記 R F 信号に訓練済み人工ニューラルネットワークを適用し、それによって前記 R F 信号をビームフォーミングするためのコンテンツ適応アポダイゼーション重みが生成され、前記 R F 信号に前記コンテンツ適応アポダイゼーション重みを適用してビームフォーミングされた出力信号を計算するように構成された計算ユニットと、

c) 前記ビームフォーミングされた出力信号を出力する第 2 のインターフェースと、を有するシステム。

【発明の詳細な説明】

【技術分野】

【0001】

本発明は、超音波信号の適応ビームフォーミングのための方法、超音波信号の適応ビームフォーミングに有用な人工ニューラルネットワークを訓練する方法、並びに関連するコンピュータプログラム及びシステムに関する。

【背景技術】

【0002】

K. E. Thomenius, "Evolution of ultrasound beamformers," 1996 IEEE Ultrason. Symp. Proc., vol. 2, pp. 1615-1622, 1996に記載されているように、伝統的な超音波画像方法は通常、遅延和(DAS)ビームフォーミングを使用するが、その理由はその複雑さが低く、再構成時間が速いからである。この方法は、受信チャンネルに対して固定されたコンテンツ不変のアポダイゼーション重みを使用する。その再構成速度はリアルタイム撮像を可能にするが、DASビームフォーミングは、コンテンツ適応アレイアポダイゼーションがないため、最適な画像コントラストと解像度を提供しない。例えば、軸外成分からの後方散乱は、十分に補償されない。この比較的劣った品質を改善するために、改善された画像は、多くの場合、取得時間の増加を犠牲にして、複数の取得を合成すること、及び/又は集束ビームを使用することによって得られる。

【発明の概要】

【発明が解決しようとする課題】

【0003】

適応ビームフォーミングアルゴリズムは、取得されたR F信号に基づいて、最適なコンテンツ適応アポダイゼーション重みを決定し、それらを受信チャンネルに適用することによって、これを改善する。しかしながら、これらの方法は、計算的により要求が厳しく、従って、かなり長い再構成時間をもたらす。従って、現在知られている適応ビームフォーミングアルゴリズムは、リアルタイム超音波画像には適していない。

【0004】

既知の適応ビームフォーミングアルゴリズムは、アポダイゼーション後の受信信号の分散を最小にする一方で、所望の方向におけるユニティゲインを維持するようにアポダイゼーション重みを連続的に最適化する最小分散(MV)ビームフォーマである。このプロセスは、典型的にはクラッタ画像につながる望ましくない方向からの干渉信号の電力を効果的に抑制する。MVビームフォーミングは、DASに比べて解像度とコントラストを大幅に向上させることができるが、 $n \times n$ の空間共分散行列を反転する必要があり、その計算量は $n^3$ ( $n$ はチャンネル数)と非常に重いことが知られている。それゆえ、MVビームフォーミングは、リアルタイム画像には使用されない。

【0005】

MVビームフォーミング方法は、例えばI. K. Holfort, Adaptive Beamforming for Medical Ultrasound Imaging, PhD Thesis, Technical University of Denmark, Lyngby, November, 2009及びJ. F. Synnevag, A. Austeng, and S. Holm, "Benefits of minimum-variance beamforming in medical ultrasound imaging," IEEE Trans. Ultrason. Ferroelectr. Freq. Control, vol. 56, no. 9, pp. 1868-1879, 2009に記載されている。ビームフォーミングの一般的な原理は例えば、Chapter Two of the PhD Thesis by I.K. Holfort, Adaptive Beamforming for Medical Ultrasound Imag

10

20

30

40

50

ingに記載されており、これは参照により本明細書に組み込まれる。MVビームフォーミングでは、アポダイゼーション重みは、 $w^H a = 1$ として、 $\min w^H R w$ を解くことによって決定される。ここで、 $a$ は、ステアリングベクトルであり、 $R$ は、入力アレイの共分散行列である。この最小化問題の解は、

$$w_{mv} = \frac{R^{-1}a}{a^H R^{-1}a}.$$

である。共分散行列  $R$  の反転は、特に大きな行列の場合、計算的に非常に高価であるため、リアルタイムの実行には適していない。

【0006】

人工ニューラルネットワークは、画像形成及び特徴付けのための超音波イメージングのコンテキストにおいて提案されている（例えば、国際公開第2018/127498A1号公報を参照のこと）。本文献によれば、超音波イメージングシステムは、エコー信号を取得するように構成された超音波トランスデューサ、及び取得されたエコー信号を記憶するように構成されたチャンネルメモリを有することができる。システムはまた、チャンネルメモリに結合され、取得されたエコー信号又はビームフォーミングされた信号のうちの1つ又は複数のサンプルを受信し、取得されたエコー信号のうちの1つ又は複数のサンプルに基づいて撮像データを提供するように構成されたニューラルネットワークを有する。ニューラルネットワークは、イメージングデータを生成するか、又は組織情報を抽出するように訓練される。

【0007】

Adam Luchies and Brett Byram, "Suppressing off-axis scattering using deep neural networks", Proceedings of SPIE 10580, Medical Imaging 2018: Ultrasonic Imaging and Tomography, 105800G, March 6, 2018によれば、超音波トランスデューサ素子から取得されたRF信号（チャンネルデータとも呼ばれる）は、短時間フーリエ変換され、深層ニューラルネットワークへの入力として使用され、従って、深層ニューラルネットワークは、周波数ドメインで演算を行う。出力は入力と同じ構造を有し、逆短時間フーリエ変換が、処理されたデータを時間ドメインに戻すように変換し、処理されたチャンネルデータを生成するためにするために使用され、処理されたデータは、チャンネルにわたって合計される。

【0008】

本発明の目的は、既知のコンテンツ適応ビームフォーミング方法と比較して、高い画質を提供すると同時に、計算コストを低減した適応ビームフォーミング方法を提供することである。特に、本発明の目的は、リアルタイム超音波画像に使用できる程度に計算時間を短縮しつつ、MVビームフォーミングなどの従来の適応ビームフォーミングアルゴリズムと同等の高い画像品質を提供することができる解決策を提供することである。

【課題を解決するための手段】

【0009】

これらの目的は、請求項1に記載の超音波信号の適応ビームフォーミングのための方法、請求項13に記載の訓練済み人工ニューラルネットワークを提供する方法、請求項14に記載のコンピュータプログラム、及び請求項15に記載のシステムによって満たされるか、又は超えられる。請求項に記載の方法に関連して本明細書で説明される任意の特徴、利点、又は代替の実施形態は、他の請求項のカテゴリ、特に請求項に記載のシステム、コンピュータプログラム、及び超音波画像デバイスにも適用可能である。特に、訓練済みニューラルネットワークは、請求項に記載された訓練方法によって適応されることができる。更に、人工ニューラルネットワークへの入力データは、入力トレーニングデータの有利な特徴及び実施形態を含むことができ、逆もまた同様である。更に、訓練済みニューラル

10

20

30

40

50

ネットワークの出力（コンテンツ適応アポダイゼーション重み）は、出力訓練データの有利な特徴及び実施形態を含むことができ、その逆も同様である。

【0010】

第1の態様によれば、本発明は超音波信号の適応ビームフォーミングのための方法を提供し、この方法は、(a)超音波送信に応答して複数の超音波トランスデューサ素子によって取得されたRF信号を受信するステップと、(b)訓練済み人工ニューラルネットワークをRF信号に適用することによってRF信号をビームフォーミングするためのコンテンツ適応アポダイゼーション重みを決定するステップとを含む。

【0011】

従って、本発明の方法は、MVビームフォーミングのような今日の計算的に高価な方法の代替として人工ニューラルネットワーク(NN)を適用することによって、コンテンツ適応形式で最適な、又は最適に近いアポダイゼーション重みを得ることができる。この文脈における「コンテンツ適応(Content-adaptive)」は、アポダイゼーション重みが、取得されたRF信号に依存すること、すなわち、それらが信号のコンテンツに適応されることを意味する。超音波画像の場合、それらは、イメージングされた視野に適応される。先行技術とは対照的に、NNの出力は、RF信号(チャンネルデータ)又はビームフォーミングされた画像の形ではなく、出力は、各チャンネルごとのアポダイゼーション重みであり、よって、例えば乗算及び加算によって、通常の方法でビームフォーミングされた出力信号を生成するためにRF信号に適用されることができる。従って、NNへの入力RF信号であり、次いで、これらの同じ信号が、NNの出力、すなわちアポダイゼーション重みと乗算され、続いて、加算されて、ビームフォーミングされた出力信号を生成することができる。

【0012】

完全なコンテンツ適応ビームフォーミング又は画像再構成プロセスは、1)飛行時間補正、2)アポダイゼーション重みの適応(及び適用)、3)エンベロープ検出の3ステップに分けられる。本発明の方法は、適応アポダイゼーション重みの計算に焦点を当てており、これは、上述の3つのステップのうち計算的に最も高価なものである。

【0013】

NNへの入力は、人間又は動物の身体の部分などの媒体への超音波送信に応答して複数の超音波トランスデューサ素子によって取得される無線周波数(RF)信号である。取得されたRF信号は、振幅と位相の両方を持つ。従って、NNへの入力として使用されるRF信号は、実数であっても複素表現であってもよい。超音波イメージングでは、超音波送信によって撮像される領域は、視野と呼ばれる。複数の超音波トランスデューサ素子は、アレイトランスデューサ、例えば、線形トランスデューサ、又は、フェーズドアレイの複数又はすべての素子でありうる。いくつかの実施形態では、アポダイゼーション重みは、アレイ内のトランスデューサ素子から取得されたすべてのRF信号について計算されるが、アレイ内のトランスデューサ素子のサブセットのみが、任意の所与の時点にRF信号を受信するイメージング方法もある。

【0014】

有用な実施形態では、NNへの入力が時間アラインされたRF信号、すなわち、飛行時間補正後の時間シフトRF信号又はRF信号であり、ここで、飛行時間補正において適用される遅延は、トランスデューサの幾何学的形状に対して相対的である。このような時間補正は、DASビームフォーミングと同様に行うことができる。好適には、この方法は、時間ドメインにおいて動作し、すなわち時間ドメインの信号に対して動作する。有用な実施形態に従って、NNのための入力を形成することができる時間アラインされたRF信号を生成するために、ピクセルごとの飛行時間補正が、受信されたRF信号(生のRF信号)に適用される。これにより、サイズNのデータアレイが得られ、ここで、Nは、寄与するトランスデューサ素子の数に対応する。従って、本方法は時間アラインされた信号を生成するために、信号に対して飛行時間補正を実行するステップを更に有することができる。

【0015】

10

20

30

40

50

チャンネルデータとも呼ばれるRF信号は、「ニューラルネットワーク(neural network)」又はNNとも呼ばれる訓練済み人工ニューラルネットワークに供給される。人工ニューラルネットワーク(NN)は、ノードとも呼ばれる接続された人工ニューロンの集合に基づいており、各接続(エッジとも呼ばれる)は、1つのノードから別のノードに信号を送信することができる。信号を受信する各人工ニューロンは、信号を処理し、それに接続された更なる人工ニューロンに処理した信号を転送することができる。有用な実施形態では、本発明のNNの人工ニューロンが層状に配置される。入力信号(タイムラインRF信号など)は、入力層とも呼ばれる最初のレイヤから最後のレイヤである出力層まで伝わる。有用な実施形態では、NNは、フィードフォワードネットワークであるが、それはまた、その内部状態を記憶し、それを一連の関連する入力の処理に使用することができるように、反復ニューラルネットワークの一部であってもよく、又は反復ニューラルネットワークであってもよい。有用な実施形態では、NNが機械学習技術、特に深層学習に基づいて、例えばバックプロパゲーションによって訓練される。使用されるトレーニングデータは、トレーニングターゲットとしてのMVビームフォーマのような高品質適応ビームフォーミングアルゴリズムの出力、及び入力トレーニングデータとしての関連する時間ラインされたRF信号でありうる。有用な実施形態では、本発明が、ニューラルネットワークを用いて計算要求の厳しい計算を行いながら、適応型ビームフォーマの構造を取り入れて設計されたNNアーキテクチャに対するモデルベースのアプローチを使用する。

10

**【0016】**

本発明による訓練済み人工ニューラルネットワークは、ソフトウェアプログラムの形態で提供されてもよいが、ハードウェアとして実現されてもよい。更に、訓練済みのNNは、訓練済みニューラルネットワークと全く同じように必ずしも構造化されていない訓練された関数の形成で提供されることができ、例えば、特定の接続/エッジが重み0を有する場合、訓練後、訓練済み人工NNに基づく訓練済み関数を提供する際、そのような接続は省略されることができる。

20

**【0017】**

訓練後、本発明のNNを使用すると、MVビームフォーミングの結果を上回るとまではいかないまでも、近似する高品質の画像が、わずかな計算時間で得られることがわかった。今日の実験では、その時間ゲインはおよそ500分の1になる。従って、本発明は、MVビームフォーマなどの既知の適応型ビームフォーミングアルゴリズムと同等の品質を、数分の1の計算コストで実現する、極めて高品質な適応型ビームフォーミング手法を提供する。そのため、本発明の方法では、超音波画像の品質をリアルタイムに向上させることができる。従って、本発明は、従来のハードウェアやGPUアクセラレーションを用いて、適応型ビームフォーミング技術に匹敵する画質を、高速に提供する。

30

**【0018】**

有用な実施形態によれば、人工ニューラルネットワークの入力ノードの数及び人工ニューラルネットワークの出力ノードの数は、寄与するRF信号の数に対応し、ここで、「寄与する」とは、寄与するRF信号が例えば、特定のビームフォーミングされた出力信号、例えば、特定のビームフォーミングされたピクセルにそれぞれ寄与することを意味する。従って、入力ノードの数Nは受信超音波トランスデューサ素子の数に対応し、受信超音波トランスデューサ素子は、トランスデューサレイ内のトランスデューサ素子のすべて、又はそのサブセットとすることができる。好適には、各出力ノードが、1つの特定の入力ノードに供給される1つのRF信号に対するコンテンツ適応アポダイゼーション重みを供給する。従って、ほとんどの実施形態では、入力ノードの数がNNの出力ノードの数と同一又はほぼ同一である。

40

**【0019】**

有利な実施形態では、次のステップにおいて、NNによって決定されるコンテンツ適応アポダイゼーション重みが、RF信号、すなわち、NNに供給される同じRF信号に適用されて、ビームフォーミングされた出力信号を計算する。これは、入力(例えば時間ラインされたRF信号)から乗算及び加算要素に加算される第2の接続によって行われても

50

よく、この場合、乗算は、時間アラインされた前記RF信号の各々と、NNの出力に現れるアポダイゼーション重みの各々との間で行われる。ビームフォーミングされた出力信号は、視野の超音波画像内のピクセルに対応するRF信号であることが好ましい。従って、有用な実施では、次々に1つのピクセルに対応する時間アラインされたRF信号がニューラルネットワークを通して伝搬され、コンテンツ適応アポダイゼーション重みで重み付けされた同じRF信号が、ビームフォーミングされた出力信号をピクセルごとに与えるように合計される。ビームフォーミングされた出力信号は、当技術分野で知られている更なる方法ステップ、特に包絡線検出によって、それぞれのピクセル値を生成するために更に処理されることができる。

#### 【0020】

有用な実施形態では、本方法は、超音波送信にตอบสนองして視野から複数の超音波トランスデューサ素子によって取得された生のRF信号を受信し、その後飛行時間補正を行って時間アラインされたRF信号を生成するステップを含む。このような飛行時間補正は例えば、I. K. Holfort, Adaptive Beamforming for Medical Ultrasound Imaging, PhD Thesis, Technical University of Denmark, Lyngby, November, 2009による論文に記載されているように、当技術分野で知られている方法に従って行われることができる。時間アラインされたRF信号は、典型的には1~50MHzの範囲の周波数を有することができる。トランスデューサ素子によって取得される信号のサンプリングレートは典型的には50MHzより高くなり、例えば、100~400MHz、典型的には、200MHzである。

#### 【0021】

有用な実施形態によれば、本発明の方法は、超音波信号の適応ビームフォーミングのためのコンピュータ実現方法であり、該方法は、a) 超音波送信にตอบสนองして、視野から超音波トランスデューサのレイによって取得された生のRF信号を受信するステップと、b) 生のRF信号に対して飛行時間補正を実行し、時間アラインされたRF信号を生成するステップと、c) 時間アラインされたRF信号に訓練済み人工ニューラルネットワークを適用することによって、時間アラインされたRF信号をビームフォーミングするためのコンテンツ適応アポダイゼーション重みを決定するステップと、d) 時間アラインされたRF信号にコンテンツ適応アポダイゼーション重みを適用して、ビームフォーミングされた出力信号を計算するステップと、を有する。

#### 【0022】

ニューラルネットワークは、好適には、隠れ層を含むいくつかの層を有し、従って、好適には、深層ネットワークである。(N+1)番目の層のノードの値は、N番目の層のノードの値に基づいて計算される。これは、それぞれの接続/エッジの関連する重み(アポダイゼーションの重みと混同しないように)にN番目の層の各ノードの数値を乗算し、(N+1)番目の層の1つ又は複数のノードに追加することで行うことができる。この演算は、行列乗算と等価である。完全結合層は、完全結合層のノードと後続の層又は先行する層のノードとの間の大部分、特にすべてのエッジが存在するという事実によって定義されることができ、エッジのそれぞれの重みは個別に調整されることができる。更に、層の各ノードの値にバイアスを加えることができ、このバイアスもトレーニング可能なパラメータである。

#### 【0023】

好適な実施形態では、人工ニューラルネットワークが最大で4つの完全結合層を含む。いくつかの実施形態では、2つ又は3つの完全結合層で十分であり得る。本発明者らは、比較的小さいニューラルネットワーク(従って、わずかな計算労力しか必要としない)が優れた結果を達成するのに十分であることを発見した。例えば、完全結合された入力層と、完全結合された出力層を有する1つ又は2つの完全結合された隠れ層とが存在し得る。あるいは、完全結合された入力層と、最後の完全結合された隠れ層が出力層に直接接続する2つ又は3つの完全結合された隠れ層とがありうる。有用な実施形態では、NNは、最大で2つ又は3つの完全結合された隠れ層を含む。有用な実施形態では、NNが活性化層

10

20

30

40

50

も含み、これは好適には完全結合層の間に配置される。活性化層とは、各ノードの値に非線形関数（「活性化関数」又は「伝達関数」）を適用し、その出力を次の層の対応するノードに伝搬させるものである。名称によっては、活性化関数を層と呼ばず、一部を別の層（完全連結層）と考えられるが、本書では「活性化層」と呼ぶことにする。

#### 【0024】

有用な実施形態では、前記人工ニューラルネットワークは、正と負の両方の入力値を無境界出力値で伝搬する活性化関数を含む少なくとも1つの活性化層を含む。「無境界」とは、活性化関数の出力値が特定の値（+1や-1など）に限定されないことを意味する。好適には、原理的に任意の値を得ることができ、それによってRF信号のダイナミックレンジを維持することができる。このような関数の例は、Shang et al., "Understanding and Improving Convolutional Neural Networks via Concatenated Rectifier Linear Unit", Proceedings of the 33rd International Conference on Machine Learning, New York, USA, 2016に記載されているように、反正規化（Antirectifier）関数又は連結正規化線形ユニット（Concatenated Rectifier Linear Unit, CReLU）であってもよい。

10

#### 【0025】

NNに供給されるRF信号のダイナミックレンジは大きく、それに加えて正及び負の成分の両方を有するので、双曲線正接及び正規化線形ユニット（ReLU）のような従来の活性化関数は、本発明の適用には十分に適していない。ReLUは、その正の無境界出力による勾配の消失を回避する。しかしながら、このような非線形性は、本質的に多くの不活性（dying）のノードにつながり、トレーニングプロセスを損なうので、RF入力データを扱うときには適切でないことがある。対照的に、双曲線正接活性化は、負の値を保存することができる。しかしながら、-1と1の間に有界であり、従って、大きなダイナミックレンジを有する信号に対して迅速に飽和する傾向があり、その結果、バックプロパゲーション中に消失勾配が生じる。代わりに、有用な実施形態では、本発明が負の信号成分及び信号のダイナミックレンジを維持しながら、非線形性を導入する活性化関数を使用する。このような活性化関数を用いることで、ビームフォーミングされた出力画像の品質が向上する。更に、ニューラルネットワークは、最小のネットワークサイズを有しながら、適応的にビームフォーミングされたターゲット画像を正確に再現するように設計されることができ。

20

30

#### 【0026】

更なる有用な実施形態では、ニューラルネットワークが、入力値の正及び負の部分連結する活性化関数を含む少なくとも1つの活性化層を含み、「入力値」は、活性化層に供給される値、すなわち活性化層のノードの値を意味する。従って、負及び正の値は、次の層の異なるノードに伝搬され、これら2つのノードのうちの少なくとも1つの値はゼロである。その結果、次の層のノード数は、活性化層のノード数の2倍になる。言い換えれば、活性化層の出力は、入力の2倍のサイズを有する。有用な実施形態では、出力は常に正であり、これは活性化がエネルギー情報を保存する、すなわち、信号のモジュールを維持するが、正及び負の信号情報の両方を保存するという利点を有する。有用な実施形態では、活性化関数は、F. Chollet, "Antirectifier," GitHub, 2018. [Online]に記載されるように、サンプル単位のL2正規化と2つのReLU活性化を組み合わせた反正規化関数であってもよく、それによって入力の正の部分と負の部分連結する。以下が入手可能である：<https://github.com/keras-team/keras/blob/4f2e65c385d60fa87bb143c6c506cbe428895f44/examples/antirectifier.py>。この反正規化の演算は次のように記述されうる：

40

50

$$f(x) = \begin{bmatrix} \max\left(0, \frac{x - \mu_x}{\|x - \mu_x\|}\right) \\ \max\left(0, -\frac{x - \mu_x}{\|x - \mu_x\|}\right) \end{bmatrix}.$$

ここで、 $\mu_x$ は任意の時間に活性化層を通して伝播される入力値のベクトル又はバッチの平均であり、 $\|x - \mu_x\|$ は、L2ノルム又は分散である。従って、活性化関数は、活性化前にL2正規化を適用することが好ましい。この正規化は、活性化が信号に対してより対称的に働くことを可能にする。更に、L2正規化は、トレーニングがより迅速に収束するという利点を有する。

#### 【0027】

有用な実施形態によれば、人工ニューラルネットワークは、最大3つの活性化層を有する。有用な実施形態では、活性化層が2つの完全結合層の間に配置され、好適には活性化層が完全結合層の各対の間に、すなわち、最後の層（好適には出力層に直接接続する）を除く完全結合層の各々の後に配置される。

#### 【0028】

有用な実施形態では、ビームフォーミングされた出力信号が視野の超音波画像を再構成するために使用され、信号、好適には時間アラインされたRF信号は、訓練済み人工ニューラルネットワークを適用する前に再構成され、その結果、超音波画像の1つ又は多くとも数個のピクセルに関連するRF信号（RFデータ）が、NNによって1つ又は複数のバッチで処理される。ベクトルが、NNの入力層に同時に供給される値の組である場合、バッチは、ビームフォーミングされた超音波画像内の1つ（又は数個）のピクセルを再構成するのに必要なデータのすべてを一緒に含む、そのようなベクトルのシーケンスである。換言すれば、NNは、ピクセルごとにアポディゼーション重みを出力するように構成されることができる。これを行うために、幾つかの実現形態では、各ピクセルに寄与するRF信号が互いに遅延されるように、時間アラインされたRF信号を再配置することが有用であり、その結果、各ピクセルは独立に処理されることができる。NNに供給されるデータの各バッチは、1つ（又は多くても数個）の特定のピクセルに関係し、ここで、RF信号の幾つかの部分は、幾つかのピクセルに寄与するため、再配置において複製されることができる。

#### 【0029】

好適な実施形態では、超音波画像の1つの単一ピクセルに関するRF信号が、NNによって1バッチで処理され、それによって、入力ノードの数は、前記1つのピクセルに寄与するRF信号の数に対応する。

#### 【0030】

別の実施形態では、NNは、ビームフォーミングプロセスにおいて隣接するピクセルも組み込むことによって、その視野を広げるために拡張される。これにより、いくつかの隣接するピクセル、例えば最大9個のピクセルに関するRFデータは、ニューラルネットワークによって1つのバッチで処理される。従って、NNの入力ノード数が増加する。この実施形態は、クラッタ抑制を改善し、従って、ネットワークサイズが増加するという理由で、より高いハードウェア要件を犠牲にして、画質を更に向上させる。いくつかの隣接するピクセルは任意の方向、すなわち、超音波画像の平面内、又は撮像深度にわたって、互いに隣接していてもよい。

#### 【0031】

別の実施形態では、人工ニューラルネットワークNNが1つ又はいくつかの完全結合層に加えて、又はその代わりに、少なくとも1つの畳み込み層を含む。このような畳み込み層は、時間アラインされたRF信号にわたって適用されてもよく、又は入力空間にわたっ

10

20

30

40

50

て適用されてもよい。畳み込みニューラルネットワークは通常、少なくとも畳み込み層及びプーリング層を含み、カーネルが畳み込み層に適用される。カーネル演算は、畳み込み層のノードのサブセット上で実行され、出力はプーリングレイヤ内の1つのノードに伝播される。通常、畳み込みニューラルネットワーク内では、畳み込み層のノードがd次元画像のようなd次元行列として配置されると考えることができる。畳み込み層を使用する利点は、入力値の特に局所的な相関が、ノード又はレイヤ間の局所的な接続性パターンを実施することによって、特に各ノードが先行するレイヤのノードの小さい領域のみに接続されることによって、活用され得ることである。

#### 【0032】

従って、畳み込み層の使用は訓練可能なパラメータの量を減らし、訓練と予測の両方を高速化する。有用な実施形態では、完全結合層のうちの1つが、畳み込み層（及び場合によっては後続のプーリング層）によって置き換えられる。別の有用な実施形態では、すべての隠れ層は、畳み込み層（場合によってはプーリング層が続く）である。

10

#### 【0033】

他の有用な実施形態では、NNが反復ニューラルネットワーク（RNN）であるか、又はその一部である。反復ネットワークでは、フィードバックはメモリ機能を生成し、それによってネットワークにメモリ特性を与える。このようなメモリ機能は、超音波画像の視野が1つの画像から次の画像に完全に変化しないように、トランスデューサが撮像された身体部分の上をゆっくりと動かされるリアルタイム超音波画像のような関連データのシーケンスを処理する際に有用であり得る。有用な実施形態では、RNNはいくつかのレイヤを有し、隠れ層のうちの少なくとも1つは、1の固定重みを使用して1組のコンテキストノードに接続される。各時間ステップにおいて、入力は、複数の層を介してフィードフォワードされる。固定バック接続は、コンテキストノード内の非表示ノードの以前の値のコピーを保存する。従って、ネットワークは、一種の状態を維持することができ、標準的なフィードフォワードNNの能力を超えるシーケンス予測などのタスクを実行することを可能にする。有用な実施形態によれば、人工ニューラルネットワークの重みの一部又は全部は、量子化され、特に1~4ビットに量子化される。従って、重みは、限られた数の可能な値のうちの1つ、例えば、2つの値（0及び1）のうちの1つ、又は4つ又は8つの値のうちの1つに丸められる。これにより、NNのメモリ及び処理要件が低減される。有用な例では、重みは2進値のみを採用することができるように、1ビットに量子化される。この実施形態は、フィールドプログラマブルゲートアレイ（FPGA）上などのメモリ制約の実装にとって非常に有利である。驚くべきことに、このように重みのメモリサイズが制限されたとしても、良好な結果が得られることが示された。

20

30

#### 【0034】

有用な実施形態では、本発明の訓練済みニューラルネットワークは、超音波トランスデューサから取得されたRF信号を完全に処理して、例えば、最終的に再構成された画像を生成するか、又は画像上に分析データを提供する、より大きなニューラルネットワークの部分でありうる。好適には、本発明の訓練済みニューラルネットワークがコンテンツ適応ビームフォーミングにおいて有用なアポダイゼーション重みを提供する、より大きなニューラルネットワークの部分である。

40

#### 【0035】

有益な実施形態によれば、訓練済みニューラルネットワークは、人工ニューラルネットワークの入力層及び/又はアウトプット層よりも少ないノード、例えば2-32、好適にはより少ない $2^2 - 2^4$ 少ないノードを有する少なくとも1つの隠れ層を含む。有用な実施形態では、完全結合された隠れ層のすべてが、入力層及び出力層よりも少ないノードを有する。この次元削減により、ネットワークはデータのよりコンパクトな表現を見つけ出し、ノイズを抑制することができます。例えば、第1の完全結合された隠れ層は、入力層よりも2~16倍、好適には4~8倍少ないノードを有することができる。更なる態様によれば、本発明は超音波信号のコンテンツ適応ビームフォーミングにおいて有用なトレーニングされた人工ニューラルネットワークを提供するための方法を提供し、この方法は（

50

a) 超音波送信に応答して複数の超音波トランスデューサ素子によって取得された入力トレーニングデータ、すなわち、時間アラインされたRF信号を受信するステップと、(b) 出力トレーニングデータを受信するステップであって、この出力トレーニングデータはコンテンツ適応アポディゼーション重みであり、この場合、このようなコンテンツ適応アポディゼーション重みが、コンテンツ適応ビームフォーミングアルゴリズム、特に最小分散アルゴリズムによってRF信号から計算されるか、又は出力トレーニングデータが、コンテンツ適応ビームフォーミングアルゴリズムによってRF信号から計算されるビームフォーミングされた出力信号である、ステップと、(c) 入力トレーニングデータ及び出力トレーニングデータを使用して人工ニューラルネットワークを訓練するステップと、(d) 訓練済み人工ニューラルネットワークを提供するステップと、を有する。

10

**【0036】**

従って、第1の実施形態では、NNは、トレーニングターゲットとしてビームフォーミングされたRF信号を使用してトレーニングされる。これらのターゲット信号は、訓練済みのNN(例えば、高い空間分解能、最小クラッタ又は最大コントラストを有する)を使用するとき生成される信号の所望の品質及び特性を表すべきである。これらのターゲット信号は、入力信号及び関連するビームフォーミングされた出力信号を提供する数値シミュレーションに由来することができる。代替的に又は付加的に、これらの入力信号は、所望の品質を有し、所望の特性を有するビームフォーミングされた出力信号を提供することが知られているビームフォーミングアルゴリズムで処理された、捕捉されたRF信号に由来することができる。このビームフォーミングアルゴリズムは、特に最小分散ビームフォーミングアルゴリズムでコンテンツ適応ビームフォーミングアルゴリズムとすることができる。次いで、NNは、コンテンツ適応の形式でアポディゼーション重みを計算するように構成される。この実施形態では、好適にはアポディゼーション重みが合計で1になるという制約がトレーニング中に使用され、その結果、1からのあらゆる偏差がコスト関数に加算することによってペナルティを課される。

20

**【0037】**

第2の実施形態では、NNは、トレーニングターゲットとしてコンテンツ適応アポディゼーション重みを提供することによって訓練され、トレーニングターゲットは、最小分散アルゴリズムのような既知のコンテンツ適応ビームフォーミングアルゴリズムを使用して計算される。これらの既知の技術は、典型的には軸外クラッタを抑制するために利用可能なチャンネルデータを適応的に処理し、及び/又は、回折限界を超えて横方向分解能をもたらすために、利用可能なチャンネルデータを適応的に処理することを求めるデータ依存ビームフォーミング方法である。他の公知の適応ビームフォーミング技術は、(圧縮センシングで使用されるような)指定されたドメインにスパース性を強制する非線形反転方式、振幅及び位相推定(APESS)、並びに開口ドメインモデル画像再構成(ADMIRE)を含む。しかしながら、これらのアルゴリズムは計算的に非常に高価であり、従って、実際のリアルタイム画像データではなく、トレーニングデータに対してのみ使用されることができる。例えば、最小分散ビームフォーミングのためには、画像の中のすべてのピクセルに対して行列反転を行わなければならない。

30

**【0038】**

人工ニューラルネットワークは上述のように構成されてもよく、すなわち、それはいくつかの層、好適には最大4つの完全結合層と、最大3つの活性化層とを有する深層ネットワークであってもよい。トレーニングは、バックプロパゲーションによって行うことができる。この方法では、時間アラインされたRF信号がエッジの所定の重みを用いてNNを通して伝搬される。出力は誤差又はコスト関数を使用して出力トレーニングデータと比較され、その出力はNNを通過してバックプロパゲートされ、それによって、最小誤差をもたらすネットワーク重み(及び場合によってはバイアスなどの他のパラメータ)を見つけるために勾配を計算する。これは、エッジの重みを調整し、コスト関数の負の勾配に従うことによって行われることができる。ニューラルネットワークの重みは本発明によれば、非常に迅速に最小値に収束し、その結果、NNは1つ又は少数の超音波画像のみに関連する

40

50

非常に限られた数のデータに対して訓練され得ることが見出された。

【0039】

有用な実施形態では、ニューラルネットワークは、トレーニング中にドロップアウト層を使用する。これにより、ドロップアウト層内のあるノード/接続がランダムに選択され、値/重みが0に設定される。例えば、ドロップアウト層は、30～80%などの所定の割合のドロップアウトノードを有することができ、例えば、すべてのノードの50%がドロップアウトされ、それらの値/重みが0に設定される。トレーニングデータの次のバックプロパゲーションでは、ドロップアウト層の異なるノードセットが0に設定される。これはトレーニング中にノイズを生成するが、トレーニングが有用な最小値に収束するという利点を有する。従って、NNはドロップアウト層を使用する場合、はるかに良好に訓練可能である。有用な実施形態では、トレーニング中、1つ、2つ、又は3つの完全結合層の後にドロップアウト層が続く。ドロップアウト層を使用することによって、接続の数が低減され、バックプロパゲーションの各反復中に、サブネットワークのみがトレーニングされる。ただし、実際に使用されているネットワークは、完全なNN(ドロップアウトレイヤなし)である。トレーニング中に、人工ニューラルネットワークが、L2正規化を用いた活性化関数を含む少なくとも1つの活性化層を含む場合、更に有用である。これは、訓練をより迅速に収束させる。

10

【0040】

更なる実施形態によれば、NNによって生成されるアポダイゼーション重みは、ユニティゲインからの偏差にペナルティを課すコスト関数(損失関数とも呼ばれる)を実現することによって制約される。従って、ニューラルネットワークはアポダイゼーション重みを生成し、その合計は1に近い。有用な実施形態において、これは、ニューラルネットワークのトレーニング中に厳密には実現されないが、1の合計からのいかなる偏差も、コスト関数に加算することによってペナルティを課される。従って、本発明は、入力に比例するままの出力信号を生成するロバストなビームフォーマを有利に提供する。

20

【0041】

好適には、コンテンツ適応アポダイゼーション重みを決定する際に使用される訓練済み人工ニューラルネットワークが上記の方法で訓練される。更に好適には、本発明の方法の訓練済み人工ニューラルネットワークが上記の訓練方法によって提供される。

【0042】

本発明は、命令を含むコンピュータプログラムにも関連しており、このプログラムが計算ユニットによって実行されるとき、計算ユニットに本発明の方法を実行させることができる。これは適応ビームフォーミング方法と訓練方法の両方に当てはまる。代替として、ニューラルネットワークは例えば、チップ又は他の処理ユニット上の固定接続を有するハードウェアとして実現されてもよい。本発明の方法を実行することができる計算ユニットは、CPU(中央処理ユニット)又はGPU(グラフィック処理ユニット)などの任意の処理ユニットとすることができる。計算ユニットは、コンピュータ、クラウド、サーバ、ラップトップ、タブレットコンピュータ、携帯電話、スマートフォンなどのモバイル装置の一部とすることができる。特に、計算ユニットは、超音波画像システムの一部でありうる。

30

【0043】

本発明はまた、計算ユニットによって実行されるとき、計算ユニットに本発明による方法を実行させる命令を含むコンピュータ可読媒体にも向けられる。このような計算可能媒体は、任意のデジタル記憶媒体、例えば、ハードディスク、サーバ、クラウドサーバ、光学又は磁気デジタル記憶媒体、CD-ROM、SSDカード、SDカード、DVD又はUSB又は他のメモリスティックであってもよい。別の態様によれば、本発明はまた、超音波信号を適応ビームフォーミングするシステムに関連し、本システムは、a)超音波送信に 응답して複数の超音波トランスデューサ素子によって取得されたRF信号を受信するように構成された第1のインターフェースと、b)訓練済み人工ニューラルネットワークをRF信号に適用し、それによってRF信号をビームフォーミングするためのコンテンツ適

40

50

応アポダイゼーション重みが生成され、コンテンツ適応アポダイゼーション重みをRF信号に適用してビームフォーミングされた出力信号を計算するように構成された計算ユニットと、c) ビームフォーミングされた出力信号を出力するように構成された第2のインターフェースと、を有する。

【0044】

システムは、好適には超音波信号の適応ビームフォーミングのための本発明の方法を実行するように構成される。このようなシステムは超音波イメージングシステム上に実現されてもよく、例えば、GPUなどのその処理ユニットの1つ上に実現される。しかしながら、超音波画像システムの超音波トランスデューサによって取得されたRF信号が例えば、インターネットを介して別の計算ユニット、ローカル又は遠隔に転送され、適応アポダイゼーション重みがそこから逆に転送され、ビームフォーミングされた出力信号を計算する際に使用されることも考えられる。

10

【0045】

更に、本発明は、本発明のトレーニング方法によって人工ニューラルネットワークを訓練するシステムにも関する。

【0046】

更なる態様によると、本発明は、超音波信号を送受信するように構成された超音波トランスデューサアレイと、受信された超音波信号の少なくとも一部に基づいて、RF信号とも呼ばれるチャンネルデータを送信するように構成された、前記超音波トランスデューサアレイに動作可能に結合された複数のチャンネルと、前記複数のチャンネルに動作可能に結合され、前記チャンネルデータを時間アラインするように構成されたビームフォーマと、前記ビームフォーマに動作可能に結合され、前記ビームフォーマと、前記ビームフォーマに動作可能に結合された信号プロセッサであって、請求項1乃至12のいずれか1項に記載の方法を実行するように構成されている信号プロセッサと、を有する超音波イメージングシステムに向けられる。前記方法の計算コストが低いため、このような信号プロセッサは、既存の超音波システムに組み込むことができる。

20

【0047】

本発明の有用な実施形態を添付の図面を参照して説明する。類似の構成要素又は特徴は、図面において同じ参照符号で示される。

【図面の簡単な説明】

30

【0048】

【図1】従来のDASビームフォーミング技術の概略図。

【図2】適応ビームフォーマの概略図。

【図3】本発明の一実施形態によるニューラルネットワークの簡略図。

【図4】本発明の方法の実施形態の実現例を示す概略図。

【図5】本発明の一実施形態による人工ニューラルネットワークを示す概略図。

【図6】本発明の一実施形態による、(A)従来のDASビームフォーミング、(B)最小分散ビームフォーミング、(C)深層学習ベースのビームフォーマ、で得られた超音波画像を示す図。

【図7】本発明の一実施形態による超音波撮像システムを示す図。

40

【図8】代替的なニューラルネットワークベースのビームフォーミング方法の概要を示す図。

【図9】代替方法で使用される模擬ファントムからのトレーニングデータセットを示す図であって、原画像が左側に、代替ニューラルネットワーク方法で得られた画像が中央に、最小分散ビームフォーミング画像が右側に示されている図。

【図10】代替方法に係る模擬ファントムからの試験データセットを示し、オリジナル画像を左側に、代替ニューラルネットワーク法により得られた画像を途中で、最小分散ビームフォーミングされた画像を右側に示す。

【発明を実施するための形態】

【0049】

50

図1は、遅延和(DAS)法による従来のビームフォーミングを示す。例えば、トランスデューサ素子のアレイ4によって送信される超音波パルスに反応して、エコー3は、視野内の点構造(焦点)2から反射される。エコー3は、超音波トランスデューサのアレイ4によって記録される。このようにして取得された生RF信号5は、チャンネルデータとも呼ばれ、各生RF信号5は1つのトランスデューサ素子によって取得されており、従って1つのチャンネルに関連する。図1の例は、8つのチャンネルを示す。ビームフォーミングに関して、チャンネルデータ5は、ステップ6で補正される飛行時間であり、すなわち、トランスデューサアレイ4及び焦点2の形状に応じて、アレイ4によってエコー3が取得された異なる時間シフト $t_1$ 、 $t_2$ 、 $\dots$ 、 $t_n$ が補正される。これらの時間アラインされたRF信号 $S_1$ 、 $\dots$ 、 $S_n$ は、ステップ7でアポダイゼーション重み $w_1$ 、 $\dots$ 、 $w_n$ と乗算される。従来のDASビームフォーミングでは、これらの重みは予め設定されており、超音波画像のコンテンツに適応していない。すなわち、これらの重みはRF信号に適応していない。重み付き信号8は、ステップ9で合計されて、ビームフォーミングされた出力信号10を生成する。このビームフォーミングされた出力信号10は、更に処理されて、1つのピクセルの画像データを生成することができる。

#### 【0050】

図2に適応ビームフォーミング方法を示す。この方法では、時間アラインされたRF信号18  $S_1$ 、 $S_2$ 、 $\dots$ 、 $S_n$ は、ビームフォーミングアルゴリズム14によって、コンテンツ適応アポダイゼーション重み12を計算するために使用され、そのため、コンテンツ適応アポダイゼーション重み12は、DASビームフォーマにおいてそうであるように事前に決定されることはない。むしろ、信号は適応ビームフォーマ14、例えば最小分散ビームフォーマによって処理され、このビームフォーマは、画質を最大にするために最適重みを計算する。重み付けされたRF信号は、ステップ9で合計され、その結果、ビームフォーミングされた出力信号となる。

#### 【0051】

本発明によれば、従来の適応ビームフォーミングアルゴリズム/プロセッサ14は、ニューラルネットワークに置き換えられる。このようなニューラルネットワーク16の一例を図3に示す。この例示的なネットワークは層20、24、26、28、32、36に配置され、各層は多数のノードからなり、隣接する層間のノードはエッジによって接続される。各エッジ/接続は、第1のノードの値に対して実行される単純な演算に対応し、この演算の値は、接続されたノードの値に加算される。特に、ニューラルネットワークの各ノードには、実数又は複素数を値として割り当てることができる。

#### 【0052】

ニューラルネットワーク16は、入力として、複数の超音波トランスデューサから取得され、1ピクセルの計算に使用される時間アラインされたRF信号18  $S_1$ 、 $S_2$ 、 $\dots$ 、 $S_n$ を受信する。入力層20内のノード21の数は、寄与するRF信号の数である $n$ に対応する。この実施形態では、出力層36のノード34の数 $n$ が入力層20のノード21の数 $n$ に対応する。コンテンツ適応アポダイゼーション重み $w_1$ 、 $\dots$ 、 $w_n$ を計算するために、入力値信号 $S_1$ 、 $S_2$ 、 $\dots$ 、 $S_n$ がニューラルネットワークを通して伝搬される。

#### 【0053】

この実施形態では入力層20は、完全結合層であり、すなわち、入力層の各ノード21はエッジ22によって、次の層24の各ノード23に接続される。この演算は行列乗算に対応し、入力層20の各値は、それを次の層24のノード23に接続するエッジの重みと乗算される。

#### 【0054】

次の層は活性化層24であり、この例では反正規化層である。この反正規化器は、負の信号成分及び入力のダイナミックレンジを保持しながら、非線形性を効果的に導入する。入力の正の部分と負の部分とを連結するので、各ノード23は2つのエッジ24a及び24bによって示されるように、正の入力値を有するか負の入力値を有するかに応じて異な

10

20

30

40

50

る出力を有するので、次の層 2 6 におけるノード 2 5 の数を事実上 2 倍にする。その他の点では、次の層 2 6 に含まれるノード 2 5 の構造は、活性化層 2 4 のノード 2 3 の構造と同等であり、すなわち、層 2 4 内の隣接するノード 2 3 間に相互接続はない。

#### 【 0 0 5 5 】

活性化層 2 4 に続く層 2 6 は、再び完全結合層であり、すなわち、この層の各ノード 2 5 は次の層 2 8 の各ノード 2 7 に接続される。この後続の層 2 8 は、前の層 2 6 よりも著しく少ないノード 2 7 を有する。ノードの数を減らすことによって、トレーニングされる必要があるパラメータ/重みの数が減らされる。これは、ネットワーク内の計算量を減少させ、オーバーフィッティングの制御につながる。例えば、3 ~ 6 倍の次元削減があってもよく、図示の例ではファクタは 3 であり、すなわち、層 2 8 は先行する層 2 6 の 3 分の 1 のサイズを有する。有用な実施形態では、ファクタは 5 である。この場合も、層 2 8 は活性化層、すなわち、反正規化層であり、これは、サンプリングごとの L 2 正規化を 2 つの R e L U 活性化と組み合わせ、それによって、入力の正の部分と負の部分とを連結する。これにより、次の層 3 2 内のノード 2 9 の数が 2 倍になる。層 3 2 の各ノードは出力層 3 6 の各ノード 3 4 に接続されているので、この層 3 2 も完全結合層である。出力層 3 6 で出力される値は、コンテンツ適応アポディゼーション重み  $w_1$ 、 $\dots$ 、 $w_n$  である。

#### 【 0 0 5 6 】

図 3 の実施形態ではニューラルネットワークが 3 つの完全結合層を有し（出力層 3 6 は次の層に値を伝播しないので、1 としてカウントしない）、完全結合層は 2 0、2 6、及び 3 2 と名付けられる。更に、ネットワークは 2 つの活性化層 2 3 及び 2 8 を有し、各々は、一對の完全結合層の間にある。他の有用な実施形態では、別の完全結合層と、それに続く活性化層、すなわち、合計 4 つの完全結合層及び 3 つの活性化層があってもよい。

#### 【 0 0 5 7 】

図 4 には、本発明の方法の可能な実施例の概略図が示されている。（生の）R F 信号が 4 0 で入力データとして示されており、データは、各々がいくつかの軸方向サンプルを有するいくつかのチャンネルを有する。ステップ 4 2 において、生の R F データは従来的方法を使用して時間アラインされ、異なる平面は異なるチャンネルのデータを表す。この実施形態では、R F 信号の飛行時間補正が事前に計算され、バッファに格納される。代替的に、飛行時間補正は、G P U 内でオンザフライで計算することもでき、それによって、通信及びメモリアーヘッドを低減する。更に、この実施態様では、1 つのピクセルに関連する様々なチャンネルからのすべてのデータ 4 3 が、ステップ 4 4 で新しいフォーマット 4 5 に再配置され、その結果、各ピクセルのデータ 4 3 は、N N 内で単一のバッチとして処理されることができる。時間アラインされた及び再配置された R F 信号 4 5 に N N 1 6 を適用する次のステップは、4 6 で示されている。スキップ接続 4 8 が入力（時間アラインされた R F 信号）から出力 5 0 に追加され、ここで、時間アラインされた R F 信号は、ステップ 5 2 で、N N によって生成されたアポディゼーション重みと乗算される。その結果、1 つのピクセル 5 4 に関連するビームフォーミングされたデータ 5 5 が得られ、これは、超音波画像 5 1 を再構成するために使用される。N N によるビームフォーミング後、ビームフォーミングピクセルはその空間位置に従って再配置される。

#### 【 0 0 5 8 】

この好適な実施形態のニューラルネットワーク 1 6 は、図 5 により詳細に示されている。各層の上には、その出力サイズ（寄与する 1 2 8 個の R F 信号に対して）が示されている。完全結合層は暗い陰影で示され、反正規化層は白色で示され、ドロップアウト層（ネットワークのトレーニング中にのみ存在する）は明るい陰影で示されている。この N N 1 6 は、入力層及び出力層のための 1 2 8 個のノードと、内部層のための 3 2 個のノードとを備える 4 つの完全結合層を備える。この次元削減 5 8 は、第 1 の反正規化層に続いて 8 倍（ $2^3$ ）、又は入力層倍であり、ネットワークに、よりコンパクトなデータ表現を見付けさせる。完全結合層（最後の層を除く）の各々の後には、反正規化層が続く。最後の完全結合層 6 0 は、出力層であるが、又は出力層（図示せず）に直接接続される。トレーニング中、完全結合層の各対の間に、例えば 0 . 2 の確率でドロップアウトが適用される。

言い換えれば、トレーニング中に、ドロップアウトレイヤ内のノードの固定パーセンテージがドロップアウトされる。従って、ドロップアウト層は、ネットワークのトレーニング中にのみ存在する。ドロップアウトは、トレーニングデータに対するニューラルネットワークのオーバーフィッティングを低減するのに役立つ。

【 0 0 5 9 】

NNは、TensorFlow (Google, CA, USA) バックエンドを有する K e r a s A P I を使用して P y t h o n で実現されてもよい。訓練のために、Adamオプティマイザが、0.001の学習速度で使用され、それにより、単一画像に属するピクセルのバッチ全体にわたって確率的に最適化する。図5に示されるニューラルネットワークは、インビボ超音波画像データに対し実現され、訓練された。

10

【 0 0 6 0 】

図5に示すニューラルネットワークを訓練する場合、従来のアルゴリズムを使用する公知の適応ビームフォーミング技術によって計算されたアポダイゼーション重みを出力トレーニングデータとして使用することができる。入力トレーニングデータは、対応する時間アラインされたRF信号である。トレーニング中、NN16が、計算された出力データを生成するためにトレーニング入力データに適用される。計算された出力データと出力トレーニングデータとの間の比較は、ニューラルネットワーク16内の重みを、この場合、例えば0.0005~0.01の学習速度で再帰的に適応させるために使用される。オーバーフィッティングを防止するために、正規化の方法、すなわち、正規化に基づく人工的に計算されたデータ又は重み減衰を使用するノードのドロップアウト、が使用されることが

20

【 0 0 6 1 】

図5のNNは、単一平面波伝送を用いて取得した画像についてテストされ、その結果が図6に示されている。Aで示される画像は、DASビームフォーマで再構成された画像を示す。画像Bは最小分散ビームフォーマを使用し、画像Cでは本発明の実現による深層学習ベースのビームフォーマが適用された。NNビームフォーマは、MVターゲットに匹敵する高コントラスト画像を著しく少ないクラッタで生成することができることが観察されることができる。更に、両方の適応技術は、DASと比較してCNR (コントラスト対雑音比) 及び解像度が向上しており、後者についてはNNがMVターゲットを上回る結果となっており、これは、NNがトレーニングデータの統計量を平均化することで、ビームフォーミングプロセスに生成可能な事前情報を組み込むことができるためであると考えられる。より高品質の画像に関する訓練は、NNの性能を更に向上させることを可能にする。本発明のこの実施形態による方法は解像度とコントラストを比較するために、シミュレートされた画像についてもテストされた。分解能は、すべての点散乱体の半値全幅 (FWHM) の平均を評価することによって評価された。コントラストは無エコーのシストの平均CNRを用いて評価された。その結果を表1に示す。従って、NNビームフォーマは、MVターゲットよりも著しく少ないクラッタで、高コントラスト画像を生成することができる。

30

パラメータ	DAS	NN	MV
FWHM <sub>lat</sub> (mm)	0.846	0.704	0.778
FWHM <sub>ax</sub> (mm)	0.431	0.342	0.434
CNR (dB)	10.96	11.48	12.45

40

表1：解像度及びコントラストメトリック

【 0 0 6 2 】

図7は、本発明の一実施形態による、本発明の方法を実行するように構成された超音波

50

システム 100 の概略図である。超音波システム 100 は、CPU 104、GPU 106 及びデジタル記憶媒体 108、例えばハードディスク又はソリッドステートディスクを有する通常の超音波ハードウェアユニット 102 を有する。コンピュータプログラムは CD-ROM 110 から、又はインターネット 112 を介して、ハードウェアユニットにロードされることができる。ハードウェアユニット 102 は、キーボード 116 及び任意選択でタッチパッド 118 を備えるユーザインターフェース 114 に接続される。また、タッチパッド 118 は、撮像パラメータを表示するための表示装置として機能してもよい。ハードウェアユニット 102 は超音波プローブ 120 に接続され、超音波トランスデューサ 122 のアレイを有し、これは、被検体又は患者（図示せず）からの生の超音波画像の取得を可能にする。超音波プローブ 120 で取得されたライブ画像 124 及び CPU 104 及び / 又は GPU によって実行される本発明の方法に従ってビームフォーミングされ、スクリーン 126 上に表示され、スクリーン 126 は、任意の市販の表示ユニット、例えばスクリーン、テレビセット、フラットスクリーン、プロジェクタなどであってもよい。

10

### 【0063】

更に、例えばインターネット 112 を介して、リモートコンピュータ又はサーバ 128 への接続が存在してもよい。本発明による方法は、ハードウェアユニット 102 の CPU 104 又は GPU 106 によって実行されてもよいが、遠隔サーバ 128 のプロセッサによって実行されてもよい。また、図 8 乃至図 10 は、アポディゼーション重みを計算するために NN を使用せず、適応的にビームフォーミングされた RF データを出力する、本発明の代替の態様に関する。この代替態様の目的は、適応ビームフォーミングの効果を画像ドメインで純粋に学習するだけではなく、チャンネルごとのデータ（すなわち、RF 信号）及びビームフォーミング RF データを含む適応 BF アルゴリズムの実際の数学的動作を学習することによって、所与の適応ビームフォーミング（BF）アルゴリズムの挙動をより正確に学習することとして記述されることができる。この代替態様は、MV 又は上述の他の技術のような、計算的に高価な適応ビームフォーミングアルゴリズムを学習するために、多層パーセプトロン（MLP）を含む機械学習フレームワークを提供する。しかしながら、この機械学習フレームワークは、元の画像と適応的にビームフォーミングされた画像のピクセル値の間のマッピングとは対照的に、整列された複雑なチャンネルごとのデータと適応的にビームフォーミングされた RF データの間のマッピングを学習することを目的とする。

20

30

### 【0064】

MLP は、フィードフォワード人工ニューラルネットワークであり、入力データの組を取り込み、適切な出力の組にマッピングする。MLP は、非線形活性化関数を持つニューロンの複数の層からなり、各層は次の層に完全に接続されている。任意の連続マッピング  $y = f(x_1, x_2, \dots, x_n)$  を表すために必要とされるレイヤの最小数は、入力層、隠れ層、及び出力層を有する 3 であることがすでに実証されている。3 層 MLP（又は、同等に 1 隠れ層 MLP）は関数  $f: \mathbb{R}^n \rightarrow \mathbb{R}^1$  であり、ここで、 $n$  は、入力ベクトル  $x$  のサイズであり、 $1$  は、出力ベクトル  $f(x)$  のサイズであり、行列表記において、以下のよう表される：

$$y \cong f(x) = G\{b^{(2)} + W^{(2)}[s(b^{(1)} + W^{(1)}x)]\},$$

40

ここで、 $b^{(1)}$  及び  $b^{(2)}$  は、バイアスベクトルであり、 $W^{(1)}$  及び  $W^{(2)}$  は、重み行列であり、 $G$  及び  $s$  は、活性化関数である。一般的に使用される活性化関数は、シグモイド関数の形である：

$$g(z) = \frac{1}{1+e^{-\lambda z}},$$

50

ここで、 $\beta$  は、0 から 1 への遷移の傾きを示す。重み行列  $W^{(1)}$  及び  $W^{(2)}$  は、Levenberg Marquardt あるいはバックプロパゲーションアルゴリズムのような訓練アルゴリズムを用いて計算される。

#### 【0065】

この代替態様で使用されるニューラルネットワークは、まず、Field IIシミュレーションによって生成されたトレーニングデータセットに基づいて適応ビームフォーミングアルゴリズムを学習するように訓練され、次に、訓練されたニューラルネットワークは、概念を証明するために2つの異なるテストデータセットに適用される。代替の態様は十分な量の入出力データ対が利用可能である限り、多くの他の計算的に高価な適応ビームフォーミング技法に一般化することができるフレームワークである。もう1つの態様は、限られた量のトレーニングデータセットから計算的に高価な適応ビームフォーミングアルゴリズムを学習し、推論を介してかなり低い計算コストで新しいデータセット上に学習したアルゴリズムを適用することができる機械学習フレームワークを提供する。本発明の代替的な側面は、時には平均以上の価格帯のGPUを使用してリアルタイムで実行することが非常に難しい、計算量の多い適応ビームフォーミングアルゴリズムのリアルタイム処理を可能にするものでありうる。本発明の別の態様の主な構成要素は、チャンネル当たりの時間アラインされた複素RFデータを複素ビームフォーミングされたRFデータにマッピングするニューラルネットワークである。多層パーセプトロン(MLP)、畳み込みニューラルネットワーク(CNN)、及び回帰及び/又は生成ネットワークなどのより高度なネットワークなどのいくつかのタイプのニューラルネットワークを使用して同様のタスクを実行することができるが、代替の態様はMLPモデルを使用して、機械学習/深層学習フレームワークを使用して高度な適応ビームフォーミング技術を学習及び適用することの実現可能性を実証する。MVビームフォーマはテストアルゴリズムとして使用されるが、ここで示したコア概念は他の適応ビームフォーミングアルゴリズムにも拡張できる。

#### 【0066】

本発明の代替の態様においてニューラルネットワークを訓練する際に使用される入出力対は元のビームフォーマ画像及びMVビームフォーマ画像からのピクセルではなく、むしろ、入力データは所与の深度における時間アラインされた複素チャンネルRF信号から成り、出力データはMVビームフォーマのための対応する複素ビームフォーマ出力である。主なステップは図8に示されている。ステップ1では、ニューラルネットワークトレーニングのトレーニングデータセットが準備される。これは、入力としてのチャンネル当たりの時間アラインされた複素データと、ターゲットとしての複素MVビームフォーミングされたデータとからなる。Nチャンネルシステムの場合、M個の入力-出力対が、所与のピクセル位置における2N個の入力/チャンネルデータ(実数及び虚数)と、対応するMVビームフォーマ出力(実数及び虚数)とから得られる。入力及び出力データは共に実部及び虚部を有する。従って、入力データ行列は $M \times 2N$ であり、出力データ行列は $M \times 2$ である。MVビームフォーミングは、そのような入力-出力対を得るためにオフラインで実行されるべきである。MVビームフォーミングはデータ準備段階で一度だけ実行されるので、それに関連する計算上の負担は本方法の制限ではない。

#### 【0067】

ステップ2では、トレーニングデータセットを使用して学習アルゴリズムを訓練する。このステップは、マッピングエラーが所定のレベルに収束するまで反復的に実行される。この概念を証明するために、MLPモデルが使用された。しかし、畳み込みニューラルネットワークを含むより高度なネットワークアーキテクチャを使用することができる。これについては、後の実施形態としてより詳細に説明する。

#### 【0068】

ステップ3では、学習アルゴリズムが以前には処理していなかった、チャンネル当たりの時間アラインされた複素データの形のテストデータセットが導入される。訓練されたアルゴリズムは、入力データに作用して、その複素MVビームフォーマ出力を予測(又は推論)する。推論ステップは、加算及び乗算のみを使用してMVBFBにおける計算集約的な動

10

20

30

40

50

作を近似するので、M V B Fの直接計算よりも著しく高速であることが期待される。例えば、標準D A Sに関連する計算量は、要素数 $O(N)$ に対して線形である。しかしながら、M V B Fに対する計算量は、サブアレイサイズに比例し、最適開口重みを計算するために必要な行列反転により $O(L^3)$ になる。しかし、M L Pを使用すると、追加される計算負荷を大幅に低減することができ、潜在的に、リアルタイム処理をより実現可能にする。

【0069】

いくつかの予備シミュレーション結果を図9及び10に示す。図9は、単一の大きな無響性嚢胞を含むファントムをシミュレートしたトレーニングデータセットで、原画像(左)、ニューラルネットワーク画像(中)、真のM V B F画像(右)を示している。64素子P4 2位相ドレイをシミュレートした。すべての画像は事前にスキャン変換された画像であり、すべての画像は60dBのダイナミックレンジで表示される。M V B F画像は、より微細なスペックルサイズ及び嚢胞内のサイドローブの減少した量を示すことに留意されたい。また、ニューラルネットワーク画像は嚢胞内のサイドローブが減少し、スペックルサイズがわずかに小さくなっていることを示している。

10

【0070】

図10は、3つの小さい無エコーのシストを含む模擬ファントムからのテストデータセットを示す。原画像(左)、ニューラルネットワーク画像(中央)、及び真のM V B F画像(右)が示されている。64素子P4 2位相アレイがシミュレートされた。すべての画像は、プリスキャンコンパート画像であり、すべての画像は、60dBのダイナミックレンジで表示される。M V B F画像は、無エコーのシストにおいて、より微細なスペックルサイズ及び減少したサイドローブを示すことに留意されたい。ニューラルネットワーク画像が同様の改善を示す。

20

【0071】

他のネットワークアーキテクチャが使用されることにより、適応ビームフォーミングアルゴリズムを学習することができる。重要なコンポーネントは、ネットワークが、チャンネルごとの入力から、ビームフォーミングされた出力にマッピングすることである。例えば、畳み込みニューラルネットワークは、良好な結果を与えることが期待される。入力データは、チャンネルごとの整列された実数(又は複素数)データである。処理は、ローカル(チャンネルごとの関連データから1つのピクセル値を学習する)又はグローバル(アラインされたデータスタック全体からビームフォーミングされたRFフレーム全体を学習する)なものでありうる。ローカル処理は、入力データがいずれにせよローカルであるアルゴリズム(最小分散ビームフォーマなど)を模倣するのに適しているように思われる。十分なデータが提供されれば、グローバルアルゴリズムはまた、解剖学的構造情報を学習し、使用する可能性がなければならない。本発明のこの代替態様の理念に沿って、以下に、畳み込みニューラルネットワークを用いたローカルアプローチを説明する。各ピクセルごとのアラインされたチャンネルごとのデータは、関心のあるサンプル深さのあたりで高速でクロッピングされ、(numTime\*numElements)データ行列を生成する。時間のディメンションはステアリング効果に敏感であるように、典型的には数波長である。トレーニングデータセットサイズは、利用可能な画像の数におけるそのようなデータウィンドウの数によって決定される。1つの単一画像は、典型的には何十万もの独立したトレーニング入力-出力対をもたらすことができる。全入力データにわたる受信フィールドを有し、単一のスカラを出力する完全畳み込みニューラルネットワークは、関心のある深さで適応的にビームフォーミングされた値を学習するように訓練されることができ。

30

40

【0072】

上記の議論は単に本システムを例示することを意図しており、添付の特許請求の範囲を任意の特定の実施形態又は実施形態のグループに限定するものと解釈されるべきではない。従って、本システムは例示的な実施形態を参照して特に詳細に発明されてきたが、当業者であれば、以下の特許請求の範囲に記載される本システムのより広く意図された精神及び範囲から逸脱することなく、多数の修正及び代替実施形態を考案することができることも理解されたい。従って、本明細書及び図面は例示的なものであり、添付の請求項の範囲

50

を限定することを意図したものではありません。

【図面】

【図 1】




Fig. 1

【図 2】




Fig. 2

10

20

30

40

50



【 図 7 】


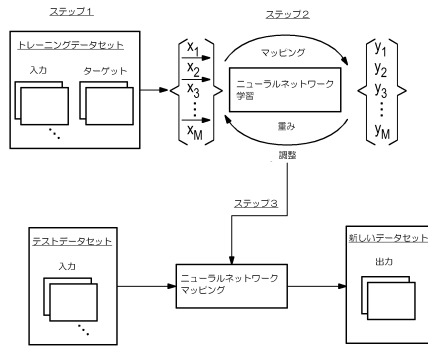



Fig. 7

【 図 8 】




10

【 図 9 】



【 図 10 】



20

30

40

50

## フロントページの続き

## (33)優先権主張国・地域又は機関

欧州特許庁(EP)

ヤミン

オランダ国 5 6 5 6 アーエー アインドーフェン ハイ テック キャンパス 5

(72)発明者 ファン スローン ルード ヨハネス ジェラルドウス

オランダ国 5 6 5 6 アーエー アインドーフェン ハイ テック キャンパス 5

(72)発明者 デ ブルイン フレデリック ヤン

オランダ国 5 6 5 6 アーエー アインドーフェン ハイ テック キャンパス 5

(72)発明者 シュメッツ ハロルド アグネス ウィルヘルムス

オランダ国 5 6 5 6 アーエー アインドーフェン ハイ テック キャンパス 5

審査官 下村 一石

(56)参考文献 国際公開第2018/167101(WO, A1)

米国特許出願公開第2017/0363725(US, A1)

LUCHIES, Adam C., et al., Deep Neural Networks for Ultrasound Beamforming, IEEE TRANSACTIONS ON MEDICAL IMAGING, 米国, IEEE, 2018年09月, VOL.37, NO.9, pp.2010-2021

(58)調査した分野 (Int.Cl., DB名)

A 6 1 B 8 / 0 0 - 8 / 1 5