

スマートフォン内臓センサとニューラルネットワーク を用いた歩行者デッドレコニング

山根 広暉^{†1,a)} 山下 晃弘^{†2,b)} 松林 勝志^{†2,c)}

概要: 歩行動作を検出して位置を推定する歩行者デッドレコニングは、GPS 衛星やビーコンとは異なり、環境側の機器に頼ることなく開始位置からの相対的な移動を推定して測位する手法である。そのため屋内環境でも利用可能であり、スマートフォンで実行可能などの利点があり、注目されている。しかし、歩行動作は人それぞれの癖があり、高精度なデッドレコニングを実現するためには様々な歩行動作に適応的な推定アルゴリズムが必要である。従来は、歩幅と歩数を推定することで移動距離を推定する手法が一般的であったが、この方法は様々な歩行動作の癖などに対応することが難しく、精度には限界があった。そこで本研究では、スマートフォン内臓の加速度センサの値を入力として、ニューラルネットワークを用いて歩行者の加速度パターンから一定期間内の平均速度を求めるという手法を提案する。ニューラルネットワークを学習させるために、高精度な位置測位が可能な RTK-GNSS を用いて歩行中の速度の教師データを作成し、これにより、計測の途中で歩行パターンが変わっても対応可能な、より高精度な歩行者デッドレコニングの実現可能性について検証を行った。

Pedestrian Dead Reckoning using Smartphone built-in Sensors and Neural Network

1. はじめに

デッドレコニング (Dead Reckoning) は、移動する物体に動作を検出するセンサを乗せ、計測開始から現在までの動作を全て足し合わせて現在の位置を推定する技術である。屋内で使用可能な位置測定手法として様々な場面で使用される。歩行者を対象としたデッドレコニング (Pedestrian Dead Reckoning, PDR) は、多くのセンサを搭載するスマートフォンの普及に伴い、スマートフォンで実行可能な歩行者位置推定手法として注目されている。

本研究では、複数の歩行者の、様々な歩行パターンのデータでニューラルネットワークを学習させることにより、汎用的な歩行者デッドレコニングモデルを構築することを目的とする。

歩行者デッドレコニングを達成するためには、歩行する速さと、向いている方角の両方を推定する必要がある。本研究では、歩行の速さを推定するモデルと、向いている方角を推定するモデルをそれぞれ独立なニューラルネットワークのモデルとして定義し、学習を行った。最終的には推定した歩行の速さと向いている方角に基づいて、歩行者の歩行速度をベクトルとして推定し、精度について検証した。

本研究では歩行の速さや向いている方角を推定するニューラルネットワーク与える教師データを得るために、Real Time Kinematic-GNSS (RTK-GNSS) を用いる。RTK-GNSS は、位置が既知の基準局を歩行者近傍の地上に設置し、基準局で得られた衛星データに基づいて歩行者の位置を補正することで、従来の GPS よりも高精度なセンチメートル単位の測位精度を実現可能な技術である。RTK-GNSS から得られた測位データに基づいて、歩行者の速さと向いている方角を計算し、これをニューラルネットワークの教師データとして学習を行った。研究の全体像を図 1 に示す。

^{†1} 現在、筑波大学
Presently with Tsukuba University

^{†2} 現在、東京工業高等専門学校
Presently with National Institute of Technology, Tokyo College

a) s2013551@s.tsukuba.ac.jp

b) yamashita@tokyo-ct.ac.jp

c) matsu@tokyo-ct.ac.jp




図 1 研究の全体像

2. 関連技術

2.1 デッドレコニング

デッドレコニングとは、加速度センサやジャイロセンサ、地磁気センサなどを用いて移動方向や速度を推定し、現在位置を推定する手法である。絶対的な位置を直接検出するのではなく、直前の位置からの相対的な変位の累積に基づいて位置を推定する。自律走行ロボットのホイールオドメトリや、航海術などがこれに分類される。

デッドレコニングの利点は、外部に機器を設置する必要がなく、事前情報がない未知の場所でも問題なく使用可能であり、また、屋内などのGNSS等が使用困難な環境でも使用可能であることなどが挙げられる。一方、欠点は、前回の推定位置からの変位を用いて次の位置を相対的に推定するため、位置を更新するたびに誤差が蓄積してしまうことである。誤差の蓄積はデッドレコニングの原理上避けることは難しく、長時間にわたって位置を推定するためには、何らかの絶対的な位置推定手法と併用し、定期的に補正するなどの手法が考えられる。

2.2 歩行者デッドレコニング

一般にデッドレコニングは、移動距離推定と進行方向推定の2つのタスクに分けて考えることができる。歩行者を対象としたデッドレコニング手法としては様々な手法が提案されているが、歩数と歩幅の推定値に基づいて位置を推定することが多い [1]。歩数は加速度センサから得られた波形に基づいて算出することができる。歩幅は、変動を無視して定数として扱う簡易的な手法が用いられることもあるが、加速度の波形の振幅から算出された値を用いる手法が多く使用されている。進行方向推定には、角速度センサの値を積分する手法と、地磁気センサと加速度センサで絶対的な角度を得る手法があるが、角速度センサでは積分が必要のためドリフト誤差と呼ばれる時間とともに累積する

誤差が発生し、地磁気センサは外部の磁場に影響を受けてしまう、加速度センサは動きの加速度に影響を受けてしまうという欠点があり、それらを組み合わせて用いられることが多い。

2.3 RTK-GNSS

Real Time Kinematic-GNSS (RTK-GNSS) は、cm 単位での高精度位置測位が可能な衛星測位システムである。GNSS 衛星の増加や機器の小型化・低価格化が進み、農業や自動運転等への応用に注目が集まっている。

通常のGNSSは、測位コードと呼ばれる信号を解析することによって信号が発せられた時間と衛星との距離を知るが、この方式では分解能は10cm程度が限界である。これに対し、RTK-GNSSは、搬送波の位相を観測することにより、理論上はmm単位の精度で衛星との距離推定を実現可能である。

RTK-GNSSは、あらかじめ正確な位置を測定済みの固定基準局(基準局)、利用者が保持する移動端末(移動局)、およびインターネット等を介した補正データ転送システムから構成される。固定局は常に測位衛星からの電波を受信し、搬送波の位相データと衛星の航法データを移動局に伝送する。移動局側でも搬送波の位相を観測し、固定局で受信した搬送波と移動局で受信した搬送波の位相差を算出する。これにより、固定局と移動局の相対位置を求めることができる。固定局はあらかじめ正確な位置がわかっているため、この情報を用いて移動局の位置を補正する。位相差に基づいて位置を推定することで、固定局と移動局で共通に発生する誤差要因(電離層、対流圏、衛星時計、衛星軌道)を排除することができる [2]。

著者らが所属する、東京工業高等専門学校情報工学科棟の屋上にRTK-GNSS基地局を設置した。実際に基地局を設置した様子を図2に示す。



図 2 東京高専情報工学科棟屋上の RTK-GNSS 基地局

3. 移動距離推定

3.1 従来手法

加速度センサの値に基づいて移動距離を推定する方法として、速度センサの値を2階積分する方法が最も単純である。しかし、一般的に加速度センサの値はノイズが非常に多く、そのまま使用する誤差の蓄積が非常に大きくなってしまふ。特に、スマートフォンを用いる場合、センサの精度は機種に依存するが、一般的に精度はそれほど高くないため、実用上は積分を用いた手法の適用は難しい。そのため、従来手法では歩数推定と歩幅推定を行い、歩数がカウントされるたびに歩幅を加算していく移動距離推定手法を採用することが多い。

歩幅は、年齢、性別、身長などの歩行者の特徴、地形などにより変化する。歩幅の推定は、常に一定と仮定する簡易的な方法と、一歩ごとに推定する方法に大別できる。

歩幅を一定とする方法の一つに、身長との相関性に注目して歩幅を推定する方法が提案されている。具体的には、歩幅を l 、身長を h とすると、

$$l = h - 1$$

または、 r を定数として、

$$l = rh$$

とする方法が提案されている。また、1分間の歩数をケージンス c として、

$$l = rc$$

とする方法も存在する。当然ながら、歩幅を一定とした場合、様々な状況での歩幅の変化は考慮しないため、移動距離推定における誤差の原因となる。

そこで、歩幅を動的に推定する手法が提案されている。例えば、歩行中の加速度に基づいて歩幅を推定する手法はその一例である。 r を定数、 $\max(a)$ 、 $\min(a)$ はそれぞれ単位時間中の鉛直成分加速度 a の最大値と最小値として、歩幅 l は、

$$l = r \sqrt{\max(a) - \min(a)}$$

とする [3]。ただし、この方法でも定数 r は対象者によって異なるため、これが誤差の原因となる問題がある。

3.2 ニューラルネットワークを用いた歩行の速さの推定

歩幅を定数として扱う手法では、対象の歩行者が途中で走り出すなど歩幅に変化があった場合大きな誤差が発生してしまう。また、歩幅を動的に推定する手法においても、対象者ごとにパラメータを調整する必要があった。このため、全く事前情報のない対象者に対し、歩幅の変化にも対応して移動距離推定を行うことは困難であった。

そこで、歩幅を推定するのではなく、ニューラルネットワークを用いて直接歩行の速さを推定し、その値を積分することによる移動距離推定を提案する。提案手法は教師あり学習に基づいてニューラルネットワークを学習する。RTK-GNSS は、cm 精度での位置情報が得られるため、これを微分することで速度を取得し、ニューラルネットワークの学習に用いる教師データとする。入力データは、スマートフォンの加速度センサから得られる3軸の加速度を用いる。

提案手法の実装にはディープラーニングフレームワークの TensorFlow[4]、Keras[5] を使用した。

3.2.1 利用するデータ

RTK-GNSS から 5[Hz] で取得した緯度・経度のデータを速度データに変換し、1秒毎の平均値を教師データに用いた。人の歩行速度の上限を 2.5[m/s] と仮定し、この値を上限として出力値を [0, 1] の範囲に収めるために、実際に RTK-GNSS のデータから得られた速度の値を 2.5 で割って正規化した値を教師データとして用いた。入力データは、スマートフォンの加速度センサから 50[Hz] で得られた x, y, z 方向の3次元の加速度データを用いた。実験は、 x, y, z の3次元ベクトルをニューラルネットワークの入力として利用する方法と、 x, y, z の3次元ベクトルのノルムを計算して入力とする方法の2種類について行った。これらのデータの対応関係を図3に示す。実験には、Huawei 製スマートフォン P20 lite を用いた。データの収集は、スマートフォンを腰の後ろに固定して加速度を取得し、教師データに使用する RTK-GNSS のアンテナを頭の上に固定した状態で計測しながら歩行することで行った。このとき、意図的に歩く速さを変えることにより、様々な速さのデータを集めた。実験は東京高専のグラウンドで行った。

5人の被験者に10分から30分程度の時間歩行してもらい、データを収集した。被験者をそれぞれ、被験者 A~E と呼ぶことにする。データ数は被験者ごとにそれぞれ 1860 個、671 個、715 個、554 個、663 個となった。

3.2.2 予備実験

ニューラルネットワークのモデルを決定するため、予備




図 3 データの対応関係

表 1 モデルごとの平均絶対誤差

	学習データ [cm/s]	テストデータ [cm/s]
3層	4.82	11.2
4層	3.42	8.51
5層	3.23	8.21
6層	2.50	7.56
7層	3.13	8.55

表 2 6層 Dropout モデルの平均絶対誤差

	学習データ [cm/s]	テストデータ [cm/s]
平均絶対誤差	5.85	7.07

実験を行った。3~7層のモデルをそれぞれ独立に用意し、各モデルに対して5回ずつ学習を行った。各モデルの平均絶対誤差 (MAE) の平均を表1に示す。活性化関数は Rectified Linear Unit (ReLU) を使い、出力層のみ Sigmoid 関数を用いた。損失関数は MSE、最適化には Adam、学習率は 0.001、バッチサイズは 32、エポックは 100 回で学習を行った。データには被験者 A のものを用い、9:1 に分け、それぞれ学習データとテストデータとして利用した。

上記の実験と同じデータを用い、モデルは最も性能の高かった 6 層モデルの入力層の直後に Dropout 層を追加したものを用いて実験を行った。Dropout 層で人工ニューロンの連結を断ち切る確率は 0.2 に設定した。5 回実験を行い、平均絶対誤差の平均を表 2 に示した。

3.2.3 ニューラルネットワークモデル

実験には 2 種類の入力モデルを用意し、それぞれニューラルネットワークモデルで学習を行った。一つは、加速度データをベクトルとして入力するベクトル入力モデルと、もう一つは加速度の絶対値のみを入力するノルム入力モデルである。加速度データをベクトルからノルムに変換すると情報は減ってしまうが、歩行者がスマートフォンをどのように保持した場合でもその方向を無視できるため、計測時の機器の設置誤差に対してロバストなモデルを作成することができると考えた。ベクトル入力を図 4 に、ノルム入力モデルを図 5 に示す。

活性化関数は ReLU を使い、出力層のみ Sigmoid を用い

表 3 実験 1 結果 各被験者の平均絶対誤差

	ベクトル入力 [cm/s]		ノルム入力 [cm/s]	
	学習	テスト	学習	テスト
被験者 A	5.42	6.73	5.12	7.13
被験者 B	3.71	7.75	6.00	9.54
被験者 C	4.81	7.31	4.34	6.98
被験者 D	5.34	8.19	5.48	7.72
被験者 E	4.49	5.80	3.44	4.64
平均	4.76	7.16	4.87	7.20

表 4 実験 2 結果 各被験者の平均絶対誤差

	ベクトル入力 [cm/s]	ノルム入力 [cm/s]
被験者 A	4.00	5.53
被験者 B	3.82	6.83
被験者 C	5.25	8.27
学習データ	4.23	6.40
被験者 D	8.68	11.7
被験者 E	6.89	6.46
テストデータ	7.70	8.85

た。損失関数は MSE、最適化には Adam、学習率は 0.001、バッチサイズは 32、エポックは 100 回で学習を行った。それぞれのモデルで 5 回ずつ学習を行い、テストデータに対する各モデルの平均絶対誤差の平均を表 1 に示す。

3.2.4 実験 1 歩行者のデータを用いて事前に学習した場合の推定結果

利用者の歩行パターンを測定し、そのデータを用いて事前に学習することを前提とした利用を想定し、一人の被験者のデータを 9:1 に分け、それぞれ学習データとテストデータとして利用した学習実験を行った。結果を表 3 に示す。

3.2.5 実験 2 歩行者のデータを事前の学習に用いない場合の推定結果

計測した 5 名の歩行中の加速度センサのデータのうち、被験者 A,B,C の 3 名のデータを教師データとして学習を行い、残りの被験者 D,E のデータをテストデータとして検証を行った。この実験は、あらかじめ多数の歩行データを用いて汎用的なモデルを構築しておき、実際の利用者に対しては個別の学習を行わない利用を想定した実験である。実験結果を表 4 に示す。また、ベクトル入力モデルの場合の学習結果のグラフを図 6 に、ノルム入力の場合の学習結果のグラフを 7 にそれぞれ表す。

3.2.6 歩行者デッドレコニング

上記のニューラルネットワークを用いて歩行の速さの推定を行い、方向については地磁気センサの値を用いて歩行者デッドレコニングを実行し、その精度を評価した。検証データとして、被験者 d, e のものを使用した。

3.2.7 考察

ニューラルネットワークを用いた手法で、cm/s 単位での精度の歩行の速さの推定が可能であることが示された。また、学習データに様々な人物のデータを含めれば、全く学習していない人物でも一定精度で速度推定が可能である




図 4 ベクトル入力モデル




図 5 ノルム入力モデル




図 6 実験 2 結果 ベクトル入力 (左: 被験者 D 右: 被験者 E)




図 7 実験 2 結果 ノルム入力 (左: 被験者 D 右: 被験者 E)




図 8 デッドレコニング結果 (左: 被験者 D 右: 被験者 E)




図 9 移動距離誤差 (左: 被験者 D 右: 被験者 E)




図 10 位置誤差 (左: 被験者 D 右: 被験者 E)

ことが分かった。さらに、加速度の方向を無視して大きさのみ入力した場合でも、精度の低下はあるものの速度推定を行うことができた。

4. 進行方向推定

4.1 地磁気センサを用いた進行方向推定

地磁気センサは地球の磁北の向きを示す。また、静止時の加速度センサは重力加速度の向きを示す。この2つを組み合わせることで、端末の絶対座標系での向きを推定できる。

この手法は、その場におけるセンサデータの値から向きを推定するため、誤差が蓄積する問題は生じない。しかし、地球の磁場を利用するため、周囲の環境によっては磁場の影響を強く受けてしまい、精度の低下を招く。また、端末が動いているときは重力加速度以外の加速度がかかってしまうため、誤差が発生してしまう。

また、地球の自転の影響で、実際の北である真北と地磁気センサで得られる磁北は一定の角度ずれてしまう。ずれる角度は測定する場所によって異なり、真北を求めるためには磁北の情報と位置の情報を組み合わせる必要がある。

4.2 ジャイロセンサを用いた進行方向推定

ジャイロセンサは角速度を測定するセンサであり、値を積分することで角度を得ることができる。地磁気センサとは異なり、周囲の環境に影響を受けずに測定することができるため、端末に加速度がかかっても問題なく測定可能であるが、初期値は別の何らかの方法で得る必要がある。また、角度を得るためには積分する必要があり、ドリフト誤差と呼ばれる時間とともに増大する誤差が発生してしまうという欠点がある。このため、単純に累積する手法の他に、過去 N 時刻の標本に主成分分析を行う手法 [6]、直進を判定し、その間は角速度を 0 とみなす手法 [7] などが提案されている。

4.3 複数センサを用いた進行方向推定

上記のようにセンサはそれぞれ利点と欠点があるため、複数のセンサを用いて欠点を補うということが試みられている。短期的にはジャイロセンサ、長期的には地磁気センサの値を信用するように加重平均をとる手法 [8]、センサ値の変化の仕方によって信用するセンサを切り替える手法 [9]




図 11 進行方向推定モデル

などがあげられる。

4.4 ニューラルネットワークを用いた進行方向推定

4.4.1 実験条件

本研究では、前述の方向推定手法に代替する新たな手法として、ニューラルネットワークを用いた方向推定について検証を行った。

スマートフォンの角速度センサにより取得した、過去3秒間の角速度データをニューラルネットワークの入力データとして使用する。サンプリング周波数は50[Hz]とした。RTK-GNSSから5[Hz]で取得した角速度データを3秒間の平均角速度に直し、これを教師データに用いることで学習を行った。50[Hz]×3秒×3方向で450個の入力を持ち、一個の出力(平均角速度)を持つニューラルネットワークを構築した。ニューラルネットワークのモデルとしては、フィードフォワードのみの6層のモデルを使用し、入力層の直後に0.2の確率で連結を断ち切るDropout層を追加して過学習を抑制した。使用したニューラルネットワークモデルを図11に示す。損失関数はMSE、最適化にはAdam、学習率は0.001、バッチサイズは32、エポックは100回で学習を行った。

データの収集は、スマートフォンを腰の後ろに固定し、RTK-GNSSのアンテナを頭の上に固定した状態で約10分間歩行することで行った。実験は東京高専の校庭で行った。このとき、5分ごとに意図的に歩く速さを変えることにより、様々な角速度のデータを集めた。データを時系列で半分に分け、それぞれ学習データとテストデータとして利用した。

4.4.2 実験結果

学習結果の平均絶対誤差を表5に示す。また、学習結果のグラフを図12に示す。結論として、テストデータでの検証では十分な精度は得られなかった。また、学習データでの結果とテストデータでの結果の差が大きく、過学習が発生していると考えられるが、Dropoutなどの過学習を抑制する手段を用いても結果が大きく変わらなかった。このことから、歩行中に曲がる動作は毎回動き方が異なり、学習データとテストデータで特徴が異なってしまっていると考えられる。さらに、歩行している時間のうちほとんどは

表 5 進行方向推定 平均絶対誤差

	学習データ [deg/s]	テストデータ [deg/s]
平均絶対誤差	1.07	6.94




図 12 進行方向推定結果 (左:学習データ 右:テストデータ)

直進しており、曲がる動作をするのはごくわずかの時間のため、歩行の速さの推定と比較してかなり多くのデータ数が求められ、今回の実験ではデータが不十分であったと思われる。

5. おわりに

本研究では、スマートフォンを用いた歩行者デッドレコニングの手法としてニューラルネットワークを用いた手法を提案し、推定精度の検証を行った。状況の違いや個人差に対応するのが難しいという従来の移動距離推定の問題を解決するため、1秒間の加速度を入力するとその間の平均速度を出力するニューラルネットワークを構築する実験を行った。これにより、歩行中の速度変化に対応して、数cm/sの精度での速度推定を実現することができた。また、複数人の学習データを用いることで、全く学習していない人物の歩行速度も推定することができた。さらに、入力データとしてx,y,z軸全ての加速度データをベクトルとして与えた場合と、加速度の方向を無視して、ベクトルの大きさのみを入力した場合の両方について速度推定を行う実験を行った。その結果、精度は落ちるものの、ベクトルの方向を無視して大きさのみを入力する方法でも数cm/sの精度での速度推定を実現することができた。

また、速度推定モデルと同じ手法で、方向を推定する実験も行った。3秒間の角速度を入力するとその間の平均角速度を出力するニューラルネットワークを構築する実験を行ったが、十分な精度は得られなかった。これは、速度推定が歩行特有の周期的な加速度変化を利用するのに対し、角速度推定は突発的な角速度変化を扱うため周期性がなく、毎回変化のパターンが異なるため、ニューラルネットワークを正しく学習させるための学習データが不足していたことが原因と考えられる。

今回はニューラルネットワークによる速さ推定を実現したが、ニューラルネットワークによる方向推定は十分な精度を実現できなかったため、この改善は今後の課題である。また、今回はスマートフォンを腰に装着した場合のみの実験だったが、より実用的なデッドレコニング手法を実現するためには、手持ちやポケットに入れた状態など、様々な条件での実験を行う必要がある。

今後は、より実用シーンを意識し、GPSなどの絶対位置推定手法と組み合わせた場合の精度や、カルマンフィルタやパーティクルフィルタを用いての補正、あらかじめ用意した地図データと照合するマップマッチングなどの技術との併用について検証する必要がある。

謝辞 本研究の一部は JSPS 科研費 19K12906 の助成を受けたものです。

参考文献

- [1] 上坂大輔, 村松茂樹ほか: 実世界に広がる装着型センサを用いた行動センシングとその応用: 2. スマートフォンを用いた歩行者デッドレコニング-センサで人の位置が分かる仕組み, 情報処理, Vol. 54, No. 6, pp. 570–573 (2013).
- [2] 白井澄夫: 高精度衛星測位技術と精密計測への応用, 精密工学会誌, Vol. 77, No. 4, pp. 358–361 (2011).
- [3] 上坂大輔, 村松茂樹, 岩本健嗣, 横山浩之ほか: 手に保持されたセンサを用いた歩行者向けデッドレコニング手法の提案, 情報処理学会論文誌, Vol. 52, No. 2, pp. 558–570 (2011).
- [4] Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., Corrado, G. S., Davis, A., Dean, J., Devin, M., Ghemawat, S., Goodfellow, I., Harp, A., Irving, G., Isard, M., Jia, Y., Jozefowicz, R., Kaiser, L., Kudlur, M., Levenberg, J., Mané, D., Monga, R., Moore, S., Murray, D., Olah, C., Schuster, M., Shlens, J., Steiner, B., Sutskever, I., Talwar, K., Tucker, P., Vanhoucke, V., Vasudevan, V., Viégas, F., Vinyals, O., Warden, P., Wattenberg, M., Wicke, M., Yu, Y. and Zheng, X.: TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems (2015).
- [5] Chollet, F. et al.: Keras (2015).
- [6] 星尚志, 藤井雅弘, 羽多野裕之, 伊藤篤, 渡辺裕ほか: スマートフォンを用いた歩行者デッドレコニングのための進行方向推定に関する研究, 情報処理学会論文誌, Vol. 57, No. 1, pp. 25–33 (2016).
- [7] 北川拓ほか: スマートフォン内蔵ジャイロセンサによる屋内方位推定精度向上, 研究報告ユビキタスコンピューティングシステム (UBI), Vol. 2013, No. 11, pp. 1–8 (2013).
- [8] 遠藤巖, 藤田悟ほか: 複数のセンサを組み合わせた屋内歩行者位置推定, マルチメディア, 分散協調とモバイルシンポジウム 2013 論文集, Vol. 2013, pp. 188–195 (2013).
- [9] Kang, W. and Han, Y.: SmartPDR: Smartphone-based pedestrian dead reckoning for indoor localization, *IEEE Sensors journal*, Vol. 15, No. 5, pp. 2906–2916 (2014).