

(12) 特許協力条約に基づいて公開された国際出願

(19) 世界知的所有権機関
国際事務局

(43) 国際公開日
2023年8月10日(10.08.2023)



(10) 国際公開番号

WO 2023/149236 A1

(51) 国際特許分類:
G06N 20/00 (2019.01)

(21) 国際出願番号: PCT/JP2023/001699

(22) 国際出願日: 2023年1月20日(20.01.2023)

(25) 国際出願の言語: 日本語

(26) 国際公開の言語: 日本語

(30) 優先権データ:
特願 2022-016691 2022年2月4日(04.02.2022) JP

(71) 出願人: 国立大学法人大阪大学 (OSAKA UNIVERSITY) [JP/JP]; 〒5650871 大阪府吹田市山田丘1番1号 Osaka (JP).

(72) 発明者: 佐々木 勇和 (SASAKI, Yuya); 〒5650871 大阪府吹田市山田丘1番1号 国立大学法人大

阪大学内 Osaka (JP). 山口 寛人 (YAMAGUCHI, Hiroto); 〒5650871 大阪府吹田市山田丘1番1号 国立大学法人大阪大学内 Osaka (JP). 鬼塚 真 (ONIZUKA, Makoto); 〒5650871 大阪府吹田市山田丘1番1号 国立大学法人大阪大学内 Osaka (JP). 前川 政司 (MAEKAWA, Seiji); 〒5650871 大阪府吹田市山田丘1番1号 国立大学法人大阪大学内 Osaka (JP).


(74) 代理人: 弁理士法人酒井国際特許事務所 (SAKAI INTERNATIONAL PATENT OFFICE); 〒1000013 東京都千代田区霞が関3丁目8番1号 虎の門三井ビルディング Tokyo (JP).

(81) 指定国(表示のない限り、全ての種類の国内保護が可能): AE, AG, AL, AM, AO, AT, AU, AZ,

(54) Title: LEARNING DEVICE, PREDICTION DEVICE, LEARNING METHOD, PREDICTION METHOD, LEARNING PROGRAM, AND PREDICTION PROGRAM

(54) 発明の名称: 学習装置、予測装置、学習方法、予測方法、学習プログラム及び予測プログラム

[図1]



(57) Abstract: A learning device (10) has: a sequence generation unit (145) for generating a fixed-length sequence from training data based on a plurality of time-series data items respectively acquired from a plurality of types of applications; a feature amount acquisition unit (146) for acquiring a feature amount of the sequence by using a first deep learning model; a calculation unit (147) for, by using a second deep learning model, determining a prediction result of occurrence of event

[続葉有]

BA, BB, BG, BH, BN, BR, BW, BY, BZ, CA, CH, CL, CN, CO, CR, CU, CV, CZ, DE, DJ, DK, DM, DO, DZ, EC, EE, EG, ES, FI, GB, GD, GE, GH, GM, GT, HN, HR, HU, ID, IL, IN, IQ, IR, IS, IT, JM, JO, JP, KE, KG, KH, KN, KP, KR, KW, KZ, LA, LC, LK, LR, LS, LU, LY, MA, MD, MG, MK, MN, MW, MX, MY, MZ, NA, NG, NI, NO, NZ, OM, PA, PE, PG, PH, PL, PT, QA, RO, RS, RU, RW, SA, SC, SD, SE, SG, SK, SL, ST, SV, SY, TH, TJ, TM, TN, TR, TT, TZ, UA, UG, US, UZ, VC, VN, WS, ZA, ZM, ZW.

- (84) 指定国(表示のない限り、全ての種類の広域保護が可能): ARIPO (BW, CV, GH, GM, KE, LR, LS, MW, MZ, NA, RW, SD, SL, ST, SZ, TZ, UG, ZM, ZW), ユーラシア (AM, AZ, BY, KG, KZ, RU, TJ, TM), ヨーロッパ (AL, AT, BE, BG, CH, CY, CZ, DE, DK, EE, ES, FI, FR, GB, GR, HR, HU, IE, IS, IT, LT, LU, LV, MC, ME, MK, MT, NL, NO, PL, PT, RO, RS, SE, SI, SK, SM, TR), OAPI (BF, BJ, CF, CG, CI, CM, GA, GN, GQ, GW, KM, ML, MR, NE, SN, TD, TG).

添付公開書類:

— 国際調査報告 (条約第21条(3))

or data corresponding to the training data from the feature amount of the sequence; and an update unit (143) for updating parameters of the first deep learning model and the second deep learning model such that an error between the prediction result and correct data from the training data becomes small.

(57) 要約: 学習装置 (10) は、複数種類のアプリケーションからそれぞれ取得された複数の時系列データに基づく学習データ学習から固定長のシーケンスを生成するシーケンス生成部 (145) と、第1の深層学習モデルを用いて、シーケンスの特徴量を取得する特徴量取得部 (146) と、第2の深層学習モデルを用いて、シーケンスの特徴量から、学習データに対応するイベントまたはデータの発生の予測結果を求める算出部 (147) と、予測結果と、学習データの正解データとの誤差が小さくなるように、第1の深層学習モデル及び第2の深層学習モデルのパラメータを更新する更新部 (143) と、を有する。

明 細 書

発明の名称：

学習装置、予測装置、学習方法、予測方法、学習プログラム及び予測プログラム

技術分野

[0001] 本発明は、学習装置、予測装置、学習方法、予測方法、学習プログラム及び予測プログラムに関する。

背景技術

[0002] 多くのアプリケーションにおいてユーザの行動や論文の引用、同時購入の商品などが時系列グラフによって表されている。例えば、Twitter（登録商標）上のユーザをノードとし、リツイートをクリックとするリツイートネットワーク、コミュニティ内の電子メールユーザをノードとし、電子メール履歴をクリックとする電子メールネットワークなどが存在する。

[0003] この時系列グラフからユーザの将来の行動を予測する技術が要望されている。実際に、ツイートの情報拡散を予測する手段として、リツイートグラフを用いて将来のリツイートを予測する研究が行われている（非特許文献1）。他にも、過去のリンク発生履歴を用いて将来のリンクを予測する時系列リンク予測手法の研究が行われている（非特許文献2～9）。

[0004] 従来手法では、連続時間グラフを用いた深層学習手法が数多く提案され、精度向上を達成している（非特許文献5～9）。連続時間グラフは、リンクの発生時刻を連続値で表現することが可能なグラフである。従来手法では、この連続時間グラフを活用することで、詳細なリンク発生の時系列を考慮したリンク予測を実現している。

[0005] 従来手法のうち、連続時間グラフを活用したリンク予測手法（非特許文献7，8）では、リンク発生を構造的傾向と時間的傾向の二つの側面から学習することで精度向上を達成している。非特許文献7，8記載の手法では、入力の連続時間グラフから最新のノード特徴を反映したnode embeddingを作成

する。これによって、非特許文献7，8記載の手法では、リンク発生の構造的傾向を学習し、最新のnode embeddingからリンク発生確率の算出する際に点過程を導入することで、リンク発生の時間的傾向を学習している。

先行技術文献

非特許文献

[0006] 非特許文献1: Qi Zhang, Yeyun Gong, Jindou Wu, Haoran Huang, and Xuanjing Huang, “Retweet Prediction with Attention-based Deep Neural Network”, In Proceedings of CIKM, 2016.

非特許文献2: Palash Goyal, Nitin Kamra, Xinran He, and Yan Liu, “DynGEM: Deep Embedding Method for Dynamic Graphs”, arXiv, 2018.

非特許文献3: Palash Goyal, Sujit Rokka Chhetri, and Arquimedes Canedo, “dyngraph2vec: Capturing network dynamics using dynamic graph representation learning”, Knowledge-Based Systems, 2020.

非特許文献4: Aravind Sankar, Yanhong Wu, Liang Gou, Wei Zhang, and Hao Yang, “DySAT: Deep Neural Representation Learning on Dynamic Graphs via Self-Attention Networks”, In Proceedings of WSDM, 2020.

非特許文献5: Giang Hoang Nguyen, John Boaz Lee, Ryan A. Rossi, Nesreen K. Ahmed, Eunye Koh, and Sungchul Kim, “Continuous-Time Dynamic Network Embeddings”, In Proceedings of WWW, 2018.

非特許文献6: Liang Qu, Huaisheng Zhu, Qiqi Duan, and Yuhui Shi, “Continuous-Time Link Prediction via Temporal Dependent Graph Neural Network”, In Proceedings of WWW, 2020.

非特許文献7: Hanjun Dai, Yichen Wang, Rakshit Trivedi, and Le Song, “Deep Coevolutionary Network: Embedding User and Item

Features for Recommendation”, arXiv, 2017.

非特許文献8: Rakshit Trivedi, Mehrdad Farajtabar, Prasenjeet Biswal, and Hongyuan Zha, “DYREP: LEARNING REPRESENTATIONS OVER DYNAMIC GRAPHS”, In Proceedings of ICLR, 2019.

非特許文献9: Srijan Kumar, Xikun Zhang, and Jure Leskovec, “Predicting Dynamic Embedding Trajectory in Temporal Interaction Networks”, In Proceedings of KDD, 2019.

発明の概要

発明が解決しようとする課題

- [0007] ここで、従来手法では、学習に利用できる教師データ（リンク）が少なく、学習データ内でリンクが未観測であるノードペア間については、リンク予測精度が上がらないという問題があった。
- [0008] 従来手法では、データセットごとにnode embeddingを計算するように設計されているため、データセットごとにモデルの学習が必要である。しかしながら、1つのデータセットから深層学習モデルを十分に学習するために必要な数の教師データを取得することは困難であった。このため、従来手法では、モデルの汎化性能を十分に向上させることができず、学習データ内でリンクが未観測であるノードペア間のリンク発生に対する予測精度を向上させることができなかった。
- [0009] 本発明は、上記に鑑みてなされたものであって、深層学習モデルを十分に学習させるために必要な数の教師データを取得し、深層学習モデルの精度向上を図ることができる学習装置、予測装置、学習方法、予測方法、学習プログラム及び予測プログラムを提供することを目的とする。

課題を解決するための手段

- [0010] 上述した課題を解決し、目的を達成するために、本発明に係る学習装置は、複数種類のアプリケーションからそれぞれ取得された複数の時系列データに基づく学習データ学習から固定長のシーケンスを生成する生成部と、第1の深層学習モデルを用いて、シーケンスの特徴量を取得する取得部と、第2

の深層学習モデルを用いて、シーケンスの特徴量から、学習データに対応するイベントまたはデータの発生の予測結果を求める予測部と、予測結果と、学習データの正解データとの誤差が小さくなるように、第1の深層学習モデル及び第2の深層学習モデルのパラメータを更新する更新部と、を有することを特徴とする。

[0011] また、本実施の形態に係る予測装置は、イベントまたはデータの発生の予測対象のデータと、予測対象のデータに関連する時系列データとを入力とし、入力データから固定長のシーケンスを生成する生成部と、複数種類のアプリケーションからそれぞれ取得された複数の時系列データに基づく学習データを用いて学習された第1の深層学習モデルを用いて、シーケンスの特徴量を取得する取得部と、学習データを用いて学習された第2の深層学習モデルを用いて、シーケンスの特徴量から、予測対象のデータに対応するイベントまたはデータの発生の予測結果を求める予測部と、を有することを特徴とする。

発明の効果

[0012] 本発明によれば、深層学習モデルを十分に学習させるために必要な数の教師データを取得し、深層学習モデルの精度向上を図ることができる。

図面の簡単な説明

[0013] [図1]図1は、実施の形態に係る学習装置の構成の一例を模式的に示す図である。

[図2]図2は、図1に示す予測部の構成の一例を模式的に示す図である。

[図3]図3は、図2に示す予測部の処理の流れを説明する図である。

[図4]図4は、ソースノードの行動履歴及びターゲットノードの被行動履歴の取得アルゴリズムを示す図である。

[図5]図5は、ソースノードへの情報伝播経路の取得アルゴリズムを示す図である。

[図6]図6は、実施の形態に係る学習処理の処理手順を示すフローチャートである。

[図7]図7は、実施の形態に係る予測装置の構成の一例を模式的に示す図である。

[図8]図8は、実施の形態に係る予測処理の処理手順を示すフローチャートである。

[図9]図9は、シーケンス長を1～5の整数値に設定した場合の精度を示す図である。

[図10]図10は、プログラムが実行されることにより、学習装置及び予測装置が実現されるコンピュータの一例を示す図である。

発明を実施するための形態

[0014] 以下、図面を参照して、本発明の一実施形態を詳細に説明する。なお、この実施形態により本発明が限定されるものではない。また、図面の記載において、同一部分には同一の符号を付して示している。

[0015] [実施の形態]

[実施の形態の概略]

自然言語処理の分野では、1つのデータセットからでは学習データが不足するため、傾向が類似する複数のデータセットを用いて予測モデルを学習することで汎化性能を向上させる技術が普及している（参考文献1）。

参考文献1：Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova, “BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding”, In Proceedings of NAACL-HLT, 2019.

[0016] 実施の形態では、この自然言語処理の分野でのトレンドに着想を得て、グラフデータにおいても複数のデータセット間でのノードの行動には共通の傾向があると仮定する。そして、実施の形態では、この仮定に基づき、複数のデータセットから共通のリンク発生傾向を学習することで、将来のリンクの発生を予測するリンク発生予測の精度向上を図った。

[0017] 従来手法DyRep（非特許文献8）と、複数のデータセットで学習した本実施の形態におけるリンク発生予測精度の比較を表1に示す。

[0018] [表1]

表1: 未出リンクの予測精度

methods	DyRep	実態の形態
ia-enron-employees	0.08±0.00	0.36±0.08
ia-radoslow-email	0.01±0.00	0.36±0.09
ia-contact	0.00±0.00	0.28±0.06
ia-contacts-hypertext09	0.05±0.00	0.43±0.07

[0019] 表1は、実施の形態において評価実験（後述）で使用するデータセットにおける未出リンクの予測精度を示す。評価指標にはHits@10を用いており、値が大きいほど高精度であることを示している。なお、表1では、最高精度であることを太字で示す。

[0020] この表1より、複数のデータセットでモデルを学習する実施の形態を採用することで、学習データ内でリンクが未観測であるノードペアで発生したリンクに対しても、予測精度を、DyRepよりも大幅に向上させることができた。したがって、実施の形態を採用することで、予測モデルの汎化性能が向上していることが確認できる。

[0021] ここで、実施の形態では、以下の二つの課題を解決することで、複数のデータセットから共通のリンク発生傾向を学習可能な汎用的リンク発生予測モデルを設計した。

[0022] （１）どのようにして複数のデータセットのリンク発生を一つのモデルで学習するか。

（２）複数のグラフで共通のリンクの発生傾向を学習するためにどのような特徴を捉えるべきか。

[0023] 実施の形態では、（１）、（２）の課題に対してそれぞれ以下のアプローチを用いる。

[0024] まず、（１）の課題について説明する。複数のデータセットに共通するリンク発生傾向を捉えるため、実施の形態では、予測モデルの入力を、複数のデータセットで共通のリンク発生履歴シーケンスに抽象化した。これによって、本実施の形態では、複数のデータセットで共通のモデル学習を可能にす

る。

[0025] 実施の形態では、時系列深層学習モデル（例えば、Transformer encoder）を用いて固定長のリンク発生履歴シーケンスからリンク発生を学習する。これによって、実施の形態では、複数のデータセットに共通するリンクの発生傾向を学習することを可能とする。これは、自然言語処理の分野で複数のデータセットを用いて汎用的な文脈理解を達成しているBERT（参考文献1）に着想を得たものである。

[0026] 続いて、（2）の課題について説明する。実施の形態では、ノードの行動と行動時刻との2つを表現するノードの行動履歴シーケンスを、時系列深層学習モデルであるTransformer encoder に入力することで、ノードの行動傾向と行動時間間隔とを捉える。このノードの行動履歴シーケンスは、予測対象のノードの直近n件のlink embeddingにより直近n件のノードの行動を表現する。そして、実施の形態では、このlink embeddingに対して各リンク発生時刻に基づくtemporal encodingを行うことでノードの行動時刻情報を付与する。

[0027] 以上のアプローチにより、実施の形態では、複数のデータセットを用いた予測モデル学習を実現し、リンク予測の精度向上を達成する。以降、具体的に、実施の形態について説明する。

[0028] [事前説明]

[問題定義]

まず、実施の形態では、データセットとして、アプリケーションから取得された連続時間グラフを用いる。実施の形態では、1つのデータセットではなく、複数種類のアプリケーションからそれぞれ取得された複数のデータセットを用いて、予測モデルの学習を行う。

[0029] ここで、連続時間グラフとは、リンクに発生時刻のタイムスタンプが付与された単一のマルチグラフによってグラフ構造の変化を表現する時系列グラフである。連続時間グラフは、リンクの発生時刻を連続値で表現することが可能なグラフである。具体的には、連続時間グラフは、ソースノードとター

ゲットノードとのペアと、ペア間のリンクと、リンクが発生した時刻情報とによって構成される。

[0030] 例えば、N個のノードを持つ時刻 t の連続時間グラフは、 $G(t) = (V, E^t)$ で表される。 V は、各時刻で共通のノードセットであり、 E^t は時刻 t より前のリンクからなるタイムスタンプが付与されたリンクセットである。 $e_i = (v^{src}_i, v^{tgt}_i, t_i) \in E^t$ は、グラフ中で i 番目に発生したタイムスタンプ付きのリンクを表す。 v^{src}_i は、ソースノードであり、 v^{tgt}_i は、ターゲットノードであり、 t_i は、リンク発生時刻である。

[0031] 実施の形態では、予測対象の時刻 t と、予測対象のソースノードとターゲットノードとのペア、時刻 t までの連続時間グラフ $G(t)$ とを予測モデルの入力として、時刻 t における予測対象のソースノードとターゲットノードとのペア間のリンク発生確率を予測する。

[0032] [Transformer]

時系列深層学習モデルの一例として本実施の形態で採用するTransformer（参考文献2）は、BERT（参考文献1）、GPT（参考文献3）、XLnet（参考文献4）などのベースとなっている手法であり、自然言語処理の分野で幅広く利用されている手法である。

参考文献2：Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Ulszkoreit, Llion Jones, Aidan N. Gomez, Lukasz Kaiser, and Illia Polosukhin, “Attention Is All You Need”, In Proceedings of NeurIPS, 2017.

参考文献3：Alec Radford, Jeffrey Wu, Rewon Child, David Luan, Dario Amodei, and Ilya Sutskever, “Language Models are Unsupervised Multitask Learners”, 2019.

参考文献4：Zhilin Yang, Zihang Dai, Yiming Yang, Jaime Carbonell, Ruslan Salakhutdinov, and Quoc V. Le, “XLNet: Generalized Autoregressive Pretraining for Language Understanding”, In Proceedings of NeurIPS, 2019.

[0033] Transformerは、Encoder-Decoderモデルであり、encoderは、ベクトルシーケンスからそれらの潜在表現を出力し、decoderでは、encoderの潜在表現から目的シーケンスを出力する。encoder及びdecoderでは、シーケンスに対してattentionを適応することで各要素間の依存関係の強さを捉えた潜在表現及び目的シーケンスの取得が可能である。ただし、attentionのみでは入力シーケンスの順序を考慮できないため、要素の順序を表す情報をシーケンスに付与する必要がある。そこで、一般的にはシーケンス中の各要素の位置情報に基づくpositional encodingを入力シーケンスに加算することで各要素の順序関係を表現している。

[0034] 自然言語処理の分野では、複数のデータセットを用いてTransformer encoderを訓練することで汎用的な文脈理解を実現するBERTが提案され、幅広いタスクに利用されている。BERTでは、複数のデータセット内の文章をword embeddingシーケンスとしてTransformer encoderに入力することで一般的な単語間の依存関係を捉えることに成功している。

[0035] そこで、連続時間グラフのリンク予測においては、複数のデータセット内のリンク発生履歴シーケンスをTransformer encoderに入力することで、複数のデータセットで共通するリンク発生の依存関係を捉えることが可能になると考えた。

[0036] 以降、実施の形態では、Transformer encoderを適用して、複数種類のアプリケーションからそれぞれ取得された連続時間グラフのデータセットから共通のリンク発生傾向を捉えることで、時刻tにおける予測対象のソースノードとターゲットノードとのペア間のリンク発生確率を予測する予測モデルについて説明する。

[0037] [学習装置]

まず、予測モデルの学習を行う学習装置について説明する。図1は、実施の形態に係る学習装置の構成の一例を模式的に示す図である。図1に示すように、学習装置10は、通信部11、入出力部12、記憶部13及び制御部14を有する。

- [0038] 通信部 11 は、ネットワーク等を介して接続された他の装置との間で、各種情報を送受信する通信インタフェースである。通信部 11 は、NIC (Network Interface Card) 等で実現され、LAN (Local Area Network) やインターネットなどの電気通信回線を介した他の装置と制御部 14 (後述) との間の通信を行う。
- [0039] 入出力部 12 は、情報の入力を受け付け、また、情報の出力を行う。入出力部 12 は、ユーザによる入力操作に対応して、学習装置 10 に対する各種指示情報の入力を受け付けるマウスやキーボード等のデバイス装置である。入出力部 12 は、例えば、液晶ディスプレイなどによって実現され、学習装置 10 によって表示制御された画面が表示出力される。
- [0040] 記憶部 13 は、RAM (Random Access Memory)、フラッシュメモリ (Flash Memory) 等の半導体メモリ素子によって実現され、学習装置 10 を動作させる処理プログラムや、処理プログラムの実行中に使用されるデータなどが記憶される。記憶部 13 は、データ記憶部 131、学習データ記憶部 132、正解データ記憶部 133、シーケンス記憶部 134 及びパラメータ記憶部 135 を有する。
- [0041] データ記憶部 131 は、複数種類のアプリケーションからそれぞれ取得された連続時間グラフを含む複数のデータセットを記憶する。学習データ記憶部 132 は、複数のデータセットからデータ生成部 141 (後述) によって作成された学習データを記憶する。正解データ記憶部 133 は、各学習データの正解データを記憶する。
- [0042] シーケンス記憶部 134 は、シーケンス生成部 145 (後述) によって生成されたシーケンスを記憶する。シーケンスは、学習データから生成される固定長のシーケンスである。シーケンスは、ノードのペアのリンクの発生履歴を表す。具体的には、シーケンスは、ソースノードの行動履歴を表すソースノードの行動履歴シーケンス (第 1 のシーケンス)、ターゲットノードの被行動履歴を表すターゲットの被行動履歴シーケンス (第 2 のシーケンス)、及び／または、ソースノードへの情報伝搬経路を表す情報伝播経路シーケ

ンス（第3のシーケンス）である。

[0043] パラメータ記憶部135は、予測部142（後述）が有する各種モデルのパラメータを記憶する。

[0044] 制御部14は、学習装置10全体を制御する。制御部14は、例えば、CPU（Central Processing Unit）等の電子回路や、ASIC（Application Specific Integrated Circuit）、FPGA（Field Programmable Gate Array）等の集積回路である。また、制御部14は、各種の処理手順を規定したプログラムや制御データを格納するための内部メモリを有し、内部メモリを用いて各処理を実行する。また、制御部14は、各種のプログラムが動作することにより各種の処理部として機能する。制御部14は、データ生成部141、予測部142、更新部143及び制御処理部144を有する。

[0045] データ生成部141は、複数のデータセットから、学習データと、各学習データの正解データとを生成する。データ生成部141は、複数のデータセットから、学習対象のノードのペアと、学習対象のノードのペア間のリンク発生時刻より前にリンクが発生した所定数のノードのペアとを学習データとして抽出する。データ生成部141は、複数のデータセットから、学習対象のノードのペアと、学習対象のノードのペアのリンク発生時刻直近の時刻で発生したn件のノードのペアを学習データとして抽出する。データ生成部141は、学習対象のノードのペアにおいて実際にリンクが発生したか否かを示すデータを正解データとする。例えば、正解データは、2値（0（発生しない）、1（発生した））で示される。

[0046] ノードのペアは、ソースノードとターゲットノードとのペアである。例えば、アプリケーションがTwitterの場合、ツイートしたユーザがソースノードとなり、リツイートしたユーザがターゲットノードとなり、リツイートがリンクとなり、リツイート時間がリンクの発生時刻となる。また、アプリケーションが電子メールの場合、電子メールの送信元ユーザがソースノードとなり、電子メールの送信先ユーザがターゲットノードとなり、電子メール履歴がリンクとなり、電子メールの送信時間がリンクの発生時刻となる。また、

アプリケーションが購入アプリケーションである場合、購入者がソースノードとなり、購入（または予約）した商品またはサービスがターゲットノードとなり、購入履歴がリンクとなり、購入時間がリンクの発生時刻となる。

[0047] 予測部 142 は、学習対象のノードのペア間におけるリンクの発生を予測する。予測部 142 は、シーケンス生成部 145（生成部）と、特徴量取得部 146（取得部）と、算出部 147（予測部）とを有する。予測部 142 は、実施の形態における予測モデルに該当する。

[0048] シーケンス生成部 145 は、データ生成部 141 によって生成された各学習データから固定長のシーケンスを生成する。特徴量取得部 146 は、第 1 の深層学習モデルを用いてシーケンスの特徴量を取得する。算出部 147 は、第 2 の深層学習モデルを用いて、シーケンスの特徴量から、学習対象のノードのペア間におけるリンクの発生を予測する。算出部 147 は、例えば、学習対象のノードのペア間におけるリンク発生確率を算出する。

[0049] 更新部 143 は、算出部 147 が予測した予測結果と、学習データの正解データとの誤差が小さくなるように、第 1 の深層学習モデル及び第 2 の深層学習モデルのパラメータを更新する。更新部 143 は、所定の損失関数を用いて、第 1 の深層学習モデルのパラメータ及び第 2 の深層学習モデルのパラメータを更新する。

[0050] 制御処理部 144 は、所定の終了条件を満たすまで、特徴量取得部 146、算出部 147 及び更新部 143 による処理を繰り返し実行させる。所定の終了条件とは、例えば、所定の繰り返し回数に達すること、損失の値が所定範囲となること、第 1 の深層学習モデルと第 2 の深層学習モデルとのパラメータ更新量が所定の閾値未満となること等、第 1 の深層学習モデルと第 2 の深層学習モデルとの学習が充分に行われた状態となる条件である。

[0051] [予測部]

次に、図 1 に示す予測部 142 について説明する。図 2 は、図 1 に示す予測部 142 の構成の一例を模式的に示す図である。図 3 は、図 2 に示す予測部 142 の処理の流れを説明する図である。

- [0052] 図2に示すように、予測部142は、複数のデータセットに含まれる連続時間グラフから生成された学習データを入力とする。例えば、あるデータセットは、アプリケーションAから取得されたグラフ（例えば、図3のグラフG a（1））を含み、また、あるデータセットは、アプリケーションBから取得されたグラフ（例えば、図3のグラフG b（1））を含む。そして、予測部142は、シーケンス生成ステップ（図3の（A））と、リンク発生予測ステップ（図3の（B））との2つのステップを行う。
- [0053] シーケンス生成ステップにおいて、シーケンス生成部145は、複数のデータセットで共通するリンク発生傾向を学習可能とするために、複数のデータセットで共通の入力となるようなソースノードからターゲットノードへのリンク発生履歴シーケンスを作成する。リンク発生履歴シーケンスは、ノードの行動と、行動時刻とを表現するものであり、後段のTransformer encoder 1461-1～1461-3で、複数のデータセットに共通するノードの行動パターンとノードの行動時間間隔パターンを学習可能にする。
- [0054] シーケンス生成部145は、ノードの行動を表現するために、連続時間グラフから、学習対象のノードのペアと、学習対象のノードのペア間のリンク発生時刻より前にリンクが発生した所定数のノードのペアのそれぞれとについて、リンクの発生履歴を表す複数種類のシーケンス（リンク発生履歴シーケンス）を生成する。シーケンス生成部145は、学習対象のノードペアごとに直近n件のリンク発生履歴シーケンスを生成する（図3の（1））。
- [0055] 例えば、図3のグラフG a（1）に示すように、時刻 t_{10} においてノードa（ソースノード）からノードb（ターゲットノード）へのリンクの発生予測を学習する場合について説明する。
- [0056] この場合、シーケンス生成部145は、時刻 t_{10} に対応するリンク発生履歴シーケンスに加え、例えば、時刻 t_{10} の直近の6件の時刻 t_2 , t_3 , t_6 , t_7 , t_8 , t_9 に発生したリンクについてノードのペアを抽出し、それぞれのペアについてリンク発生履歴シーケンスを生成する。これにより、後段のTransformer encoderが、直近のノードの行動に起因するリンク発生を捉えることを可能にす

る。なお、シーケンス生成部145は、別のアプリケーションBから取得されたグラフ（例えば、Gb（1））からも、予測対象のリンク発生時刻より前にリンクが発生したノードのペアを抽出し、学習データとする。

[0057] そして、シーケンス生成部145は、リンク発生履歴シーケンスとして、ソースノードの行動履歴シーケンス、ターゲットの被行動履歴シーケンス、情報伝播経路シーケンスの3種のリンク発生履歴シーケンスを作成する。

[0058] ソースノードの行動履歴シーケンス、ターゲットノードの被行動履歴シーケンスでは、各ノードのリツイートパターンや被リツイートパターンのようなノードの行動・被行動パターンを捉えることが可能である。ソースノードへの直近の情報伝播経路シーケンスでは、インフルエンサーから一般ユーザへの情報伝播のような情報の伝播パターンを捉えることが可能である。これらのリンク発生履歴シーケンスによって、予測部142は、多様なノードの行動パターンを捉えることができる。

[0059] シーケンス生成部145は、作成したリンク発生履歴シーケンスを、Transformer encoder 1461-1～1461-3に入力可能であるlink embeddingのシーケンスに置き換える（図3の（2））。

[0060] 続いて、シーケンス生成部145は、行動時刻を表現するために、3種のシーケンスに対して、それぞれのリンク発生時刻に基づくtemporal encodingを行う（図3の（3））。シーケンス生成部145は、このtemporal encodingにおいて、入力シーケンスのリンク発生時刻と予測リンクの発生時刻との差分に基づいたencodingを行うことで、Transformer encoderがリンク発生の時間間隔パターンを捉えることを可能にする。

[0061] 続いて、特徴量取得部146について説明する。特徴量取得部146は、シーケンス生成部145によって生成されるシーケンスの種類ごとに、時系列深層学習モデル（第1の深層学習モデル）を有し、複数の時系列深層学習モデルの出力を結合して、算出部147に出力する。図2及び図3の例では、特徴量取得部146は、時系列深層学習モデルとして、例えばTransformer encoder 1461-1～1461-3を有する。そして、特徴量取得部14

6は、結合部1462を有する。

[0062] リンク発生予測ステップにおいて、Transformer encoder 1461-1（第1の時系列深層学習モデル）は、ソースノードの行動履歴シーケンスを入力とし、ソースノードの行動パターンを捉えた潜在表現（第1の潜在表現）を出力する（図3の（4））。Transformer encoder 1461-2（第2の時系列深層学習モデル）は、ターゲットの被行動履歴シーケンスを入力とし、ターゲットの被行動パターンを捉えた潜在表現（第2の潜在表現）を出力する（図3の（4））。Transformer encoder 1461-3（第3の時系列深層学習モデル）は、情報伝播経路シーケンスを入力とし、情報伝播パターンを捉えた潜在表現（第3の潜在表現）を出力する（図3の（4））。

[0063] 結合部1462は、ソースノードの行動パターンを捉えた潜在表現、ターゲットの被行動パターンを捉えた潜在表現、及び／または、情報伝播パターンを捉えた潜在表現に対し、それぞれの潜在表現の重要度に応じた重み α_1 、 α_2 、 α_3 で重み付けする（図3の（5））。結合部1462は、重み付けをした各潜在表現を結合することで特徴量を生成する（図3の（6））。重み α_1 、 α_2 、 α_3 は、例えば、ハイパーパラメータであり、解きたい問題に応じて適宜設定される。或いは、重み α_1 、 α_2 、 α_3 は、更新部143によって予測モデルの各パラメータとともに、最適化されてもよい。

[0064] 続いて、算出部147は、第2の深層学習モデルを用いて、学習対象のノードのペア間におけるリンク発生確率を算出し（図3の（7））、算出したリンク発生確率を出力する。算出部147は、第2の深層学習モデルとして、例えば、MLP（Multilayer Perceptron）1471を用いる。算出部147は、第2の深層学習モデルとして、畳み込みニューラルネットワークなどを用いてもよい。

[0065] 更新部143は、算出部147が予測した予測結果と、学習データの正解データとの誤差が小さくなるように、Transformer encoder 1461-1～1461-3の各パラメータ及びMLP 1471のパラメータを更新する。更新部143は、重み α_1 、 α_2 、 α_3 についても更新し、最適化してもよい。

[0066] [シーケンス生成処理]

次に、3種のリンク発生履歴シーケンスの作成処理について説明する。シーケンス生成部145は、リンク発生履歴の抽出、link embeddingの作成、及び、temporal encodingを行うことによって、3種のシーケンスを生成する。

[0067] [リンク発生履歴の抽出]

まず、リンク発生履歴の抽出について説明する。3種のシーケンスを作成するために、シーケンス生成部145は、初めに、ソースノードの行動履歴、ターゲットノードの被行動履歴、ソースノードへの情報伝播経路を取得する。

[0068] 図4は、ソースノードの行動履歴及びターゲットノードの被行動履歴の取得アルゴリズムを示す図である。図5は、ソースノードへの情報伝播経路の取得アルゴリズムを示す図である。

[0069] シーケンス生成部145は、図4のAlgorithm1にしたがって、リンク発生予測対象の時刻 t の直前から直近 l_{src} 件（予測対象のリンクを含む）のリンク発生履歴を抽出することでソースノードの行動履歴シーケンスを作成する。ソースノードの行動履歴シーケンスを作成する際には、Algorithm1の「node」を「src」として説明する。

[0070] 具体的には、シーケンス生成部145は、まず、予測対象のリンク（例えば、図3に示す (a, b, t_{10}) ）をソースノードの行動履歴 S_{src} に追加する（Algorithm1の1行目）。これにより、予測部142がどのノードペア間でのリンク発生確率を予測するかを判別可能にする。

[0071] 続いて、シーケンス生成部145は、リンク発生時刻でソートされたリンク発生履歴を時刻 t の直近から過去へ探索し、ソースノードが生成したリンク履歴を、長さが l_{src} になるまで、ソースノードの行動履歴 S_{src} に追加する（Algorithm1の2-9行目）。シーケンス生成部145は、ソースノードの行動履歴 S_{src} の要素をリンク発生時刻で昇順に並べ替えを行うことで、実際のリンク発生の時系列順に変換し（Algorithm1の10行目）、ソースノードの行動履歴シー

ケンス（例えば、図3のシーケンスSc1）を作成する。

[0072] シーケンス生成部145は、ソースノードの行動履歴の取得と同様に、図4のAlgorithm1の処理を行うことで、時刻 t の直前から直近 l_{tgt} 件のターゲットノードの被リンク履歴を抽出する。ターゲットノードの被リンク履歴シーケンスを作成する際には、Algorithm1の「node」は「tgt」となる。これによって、シーケンス生成部145は、ターゲットノードの被行動履歴シーケンス（例えば、図3のシーケンスSc2）を作成する。

[0073] また、シーケンス生成部145は、図5のAlgorithm2にしたがって、長さ $l_{propagation}$ の直近の予測対象のソースノードへの情報伝播経路を抽出することで、情報伝播経路シーケンス（例えば、図3のシーケンスSc3）を作成する。

[0074] 具体的には、シーケンス生成部145は、まず、予測対象のノードペア（例えば、図3に示す (a, b, t_{10}) ）を情報伝播経路 $S_{propagation}$ に追加する（Algorithm2の1行目）。続いて、シーケンス生成部145は、ソースノードの行動履歴シーケンスの取得と同様にリンク発生履歴を探索し、 $S_{propagation}$ の長さが $l_{propagation}$ と等しくなるまで情報伝播経路を追加する（Algorithm2の2-11行目）。そして、シーケンス生成部145は、情報伝播経路 $S_{propagation}$ の要素をリンク発生時刻で昇順に並べ替えを行うことで、実際のリンク発生の時系列順に変換し（Algorithm2の12行目）、情報伝播経路シーケンス（例えば、図3のシーケンスSc3）を作成する。

[0075] [link embeddingの作成]

シーケンス生成部145は、作成したリンク発生履歴シーケンスを、Transformer encoder 1461-1~1461-3に入力可能なlink embeddingのシーケンス（例えば、図3のSc1-1）に置き換える。link embeddingは、事前学習した既存のnode embedding手法で得られるリンクの両端のノードペアのembeddingを結合したものである。シーケンス生成部145は、連続時間グラフのnode embedding手法のうち、TDGNN（Temporal Dependent Graph Neural Network）（非特許文献6）を用いる。

[0076] TDGNNは、任意の時刻の任意のノードのembeddingを取得可能なモデル

である。TDGNNは、入力時刻以前の連続時間グラフを用いて、より直近にリンクが発生した隣接ノードのembeddingを重く伝播することで、直近にリンクが発生したノードの特徴をより強く反映したnode embeddingを出力する。TDGNNは、ソースノードの行動履歴、ターゲットノードの被行動履歴、ソースノードへの情報伝播経路ごとにそれぞれ設けられる。各TDGNNは、アプリケーションごとの連続時間グラフを用いて、直近にリンクが発生したノードの特徴をより強く反映したnode embeddingを出力するように、事前に学習済みである。

[0077] シーケンス生成部145は、各シーケンスにそれぞれ対応したTDGNNを用いて、3種の各シーケンスを、link embeddingのシーケンスに置き換える。これによって、シーケンス生成部145は、ノード特徴の時系列変化を表現したlink embeddingを取得することができる。シーケンス生成部145は、TDGNNの初期値として、node2vec（参考文献5）で得られるnode embeddingを用いることで、連続時間グラフの構造情報をより正確に反映したnode embeddingを取得している。

参考文献5：Aditya Grover and Jure Leskovec, “node2vec: Scalable Feature Learning for Networks”, In Proceedings of KDD, p.855–864. Association for Computing Machinery, 2016.

[0078] [Temporal encoding]

Transformer encoder1461-1～1461-3は、入力シーケンスの順序を考慮しない。このため、シーケンス生成部145は、入力シーケンスに対してリンク発生の時刻情報を付与する（例えば、図3のSc1-2）。

[0079] シーケンス生成部145は、自然言語処理で用いられているPositional Encodingと同様に、上記で作成したlink embeddingに対して、リンク発生時刻に基づくTemporal encodingを加算する。シーケンス生成部145は、リンク予測時刻とシーケンス内のリンク発生時刻との差分に基づいてencodingすることで、各データセットのリンク発生の絶対時間に依存することなく、複数のデータセットにおけるリンク発生の時間的傾向を同様に扱うことを可

能にする。シーケンス生成部 145 では、上記の条件を満たす encoding 方法として、例えば、式 (1) を用いる。

[0080] [数1]

$$TE(t_k) = (t - t_k)W \quad \dots (1)$$

[0081] 式 (1) において、 t_k は、各リンクの発生時刻である。 W は、学習パラメータである。 W は各シーケンスの種類に応じて、 W_{src} 、 W_{tgt} または $W_{propagation}$ に置き換えられる。

[0082] [リンク発生予測ステップ]

特徴量取得部 146 は、リンク発生予測ステップにおいて、シーケンス生成ステップで作成した 3 種類のシーケンスから、Transformer encoder 1461-1 ~ 1461-3 を用いてリンクの発生傾向を示す特徴量を取得する。特徴量取得部 146 は、3 種類のシーケンスをそれぞれ異なる Transformer encoder 1461-1 ~ 1461-3 に入力することで、各潜在表現 $H_{src_node_seq}$ 、 $H_{tgt_node_seq}$ 、 $H_{propagation_seq}$ を取得する。

[0083] 結合部 1462 は、これらの各潜在表現 $H_{src_node_seq}$ 、 $H_{tgt_node_seq}$ 、 $H_{propagation_seq}$ を重み α_1 、 α_2 、 α_3 で重み付けし、重み付けをした各潜在表現を結合した特徴量を生成する。算出部 147 は、この特徴量を MLP 1471 に入力し、リンク発生確率を算出する。

[0084] 更新部 143 は、損失関数として、一般的な二値分類で用いられる Binary Cross Entropy loss を利用する。学習装置 10 は、学習データと同数の negative sample を用いて予測モデルの学習を行う。

[0085] [学習処理の処理手順]

次に、学習装置 10 が実行する学習処理について説明する。図 6 は、実施の形態に係る学習処理の処理手順を示すフローチャートである。

[0086] 図 6 に示すように、学習装置 10 は、複数のデータセットから、学習データ及び各学習データの正解データを生成する (ステップ S1)。シーケンス生成部 145 は、データ生成部 141 によって生成された各学習データから

、固定長の、ソースノードの行動履歴シーケンス、ターゲットノードの被行動履歴シーケンス、ソースノードへの情報伝播経路シーケンスを生成する（ステップS2）。

[0087] 学習装置10は、Transformer encoder 1461-1～1461-3を用いて、3種のシーケンスの特徴量をそれぞれ取得する（ステップS3）。学習装置10は、MLP 1471を用いて、3種シーケンスの特徴量を基に、学習対象のノードのペア間におけるリンクの発生を予測する（ステップS4）。

[0088] 学習装置10は、ステップS4において予測した予測結果と、学習データの正解データとの誤差が小さくなるように、Transformer encoder 1461-1～1461-3の各パラメータ及びMLP 1471のパラメータを更新する（ステップS5）。

[0089] 学習装置10は、所定の終了条件を満たすか否かを判定する（ステップS6）。所定の終了条件を満たさない場合（ステップS6：No）、学習装置10は、ステップS3に戻り、特徴量取得処理（ステップS3）、リンク発生予測処理（ステップS4）、及び、パラメータ更新処理（ステップS5）を実行する。所定の終了条件を満たす場合（ステップS6：Yes）、学習装置10は、この学習データに対する学習処理を終了する。

[0090] [予測装置]

次に、学習装置10によって学習された予測モデルを適用した予測装置について説明する。図7は、実施の形態に係る予測装置の構成の一例を模式的に示す図である。予測装置20は、通信部21、入出力部22、記憶部23及び制御部24を有する。

[0091] 通信部21は、ネットワーク等を介して接続された他の装置との間で、各種情報を送受信する通信インタフェースである。入出力部22は、マウスやキーボード等のデバイス装置や、液晶ディスプレイなどによって実現され、図1に示す入出力部12と同様の機能を有する。記憶部23は、RAM、フラッシュメモリ等の半導体メモリ素子によって実現され、図1に示す記憶部

13と同様の機能を有する。

[0092] 制御部24は、例えば、CPU等の電子回路、ASIC等の集積回路、プログラムや制御データを格納するための内部メモリを有し、図1に示す制御部14と同様の機能を有する。制御部24は、予測部241を有する。

[0093] 予測部241は、予測対象のノードのペア間におけるリンクの発生を予測する。予測部241は、シーケンス生成部242、特徴量取得部243及び算出部244を有する。予測部241は、実施の形態における予測モデルに該当する。

[0094] シーケンス生成部242は、図1及び図2に示すシーケンス生成部145と同じ機能を有する。シーケンス生成部242は、リンク発生予測の対象であるソースノード、ターゲットノード、時刻の入力を受け付けると、リンク発生予測の対象であるソースノード、ターゲットノードのペアを含む連続時間グラフから、予測対象のリンク発生時刻より前にリンクが発生した所定数のノードのペアをデータとして抽出する。シーケンス生成部242は、予測対象のリンク発生時刻の直近n件のリンクについて、ノードのペア及びリンク発生時刻を抽出する。

[0095] シーケンス生成部242は、抽出したデータと、入力を受け付けた予測対象のデータとから、固定長の、ソースノードの行動履歴シーケンス、ターゲットの被行動履歴シーケンス、情報伝播経路シーケンスの3種のシーケンスを生成する。

[0096] 特徴量取得部243は、図1及び図2に示す特徴量取得部146と同様の機能を有する。特徴量取得部243は、第1の深層学習モデルであるTransformer encoder 2431-1～2431-3及び結合部2432を有する。Transformer encoder 2431-1～2431-3は、学習装置10によって学習済みである。

[0097] 特徴量取得部243は、Transformer encoder 2431-1～2431-3に、それぞれ対応するソースノードの行動履歴シーケンス、ターゲットの被行動履歴シーケンス、情報伝播経路シーケンスを入力し、ソースノードの

行動履歴シーケンス、ターゲットの被行動履歴シーケンス、情報伝播経路シーケンスの各潜在表現を取得する。結合部 2432 は、それぞれの潜在表現の重要度に応じた重み α_1 , α_2 , α_3 で重み付け後、各潜在表現を結合した特徴量を生成し、算出部 244 に出力する。

[0098] 算出部 244 は、例えば、MLP 2441 を第 2 の深層学習として用いて、予測対象のノードのペア間におけるリンクの発生を予測する。MLP 2441 は、学習装置 10 によって学習済みである。算出部 244 は、例えば、予測対象のノードのペア間におけるリンク発生確率を算出する。

[0099] [予測処理の処理手順]

次に、予測装置 20 が実行する予測処理について説明する。図 8 は、実施の形態に係る予測処理の処理手順を示すフローチャートである。

[0100] 予測装置 20 は、リンク発生予測の対象であるソースノード、ターゲットノード、時刻の入力を受け付ける（ステップ S11）。予測装置 20 は、リンク発生予測の対象であるソースノード、ターゲットノードのペアを含む連続時間グラフから、予測対象のリンク発生時刻より前にリンクが発生した所定数のノードのペアをデータとして抽出する。予測装置 20 は、抽出したデータと、入力を受け付けた予測対象のデータとから、固定長の、ソースノードの行動履歴シーケンス、ターゲットの被行動履歴シーケンス、情報伝播経路シーケンスの 3 種のシーケンスを生成する（ステップ S12）。

[0101] 予測装置 20 は、各シーケンスの特徴量として、Transformer encoder 1461-1 ~ 1461-3 を用いて、ソースノードの行動履歴シーケンス、ターゲットの被行動履歴シーケンス、情報伝播経路シーケンスの各潜在表現を取得する（ステップ S13）。予測装置 20 は、MLP 2441 を用いて、予測対象のノードのペア間におけるリンクの発生を予測する（ステップ S14）。

[0102] [評価実験]

実施の形態に係る予測装置 20 について評価実験を行った。

[0103] [実験設定]

本評価実験では、ある時刻にあるソースノードとリンクが発生するターゲットノードを予測する。

[0104] 具体的には、テストデータのリンク発生履歴 (v^{src}_i , v^{tgt}_i , t_i) ごとに、時刻 t_i においてノード v^{src}_i とその他の全ノードとのリンク発生確率を予測する。

[0105] 評価指標には、Mean Rank (参考文献6) と、Hits@10 (参考文献7) とを用いる。

参考文献6 : Xiaofu Chang, Xuqin Liu, Jianfeng Wen, Shuang Li, Yanming Fang, Le Song, and Yuan Qi, “Continuous-Time Dynamic Graph Learning via Neural Interaction Processes”, In Proceedings of CIKM, 2020.

参考文献7 : Seyed Mehran Kazemi, Rishab Goel, Kshitij Jain, Ivan Kobyzev, Akshay Sethi, Peter Forsyth, and Pascal Poupart, “Relational Representation Learning for Dynamic (Knowledge) Graphs: A Survey”, arXiv, 2019.

[0106] Mean Rank (MR) は各テストデータで予測した全ノードとのリンク発生確率から正解のターゲットノード v^{tgt}_i のランキングを取得し、全テストデータで平均値を取ったものである。したがって、MRの値は小さいほど良い精度であることを示す。

[0107] Hits@10は上記と同様の方法で取得した正解データのランキングが上位10位以内に入っているものの割合を示す。したがって、Hits@10の値は大きいほど良い精度であることを示す。以降の実験結果では5回の精度評価を行なった平均値と標準偏差を示す。

[0108] [データセット]

本実験では、以下に示す5つの連続時間グラフを用いる。

[0109] Ia-enron-employees (参考文献8) と、ia-radoslow-email (参考文献9) は、電子メールの送受信を表した電子メールネットワークである。ia-contact (参考文献8) と、a-contacts-hypertext09 (参考文献8) とは、人の接触を表す接触ネットワークである。rt-pol (参考文献10) は、Twitterのリツ

イト関係を表したネットワークである。それぞれのデータセットの統計情報を表2に示す。

参考文献8 : Ryan A. Rossi and Nesreen K. Ahmed, “The Network Data Repository with Interactive Graph Analytics and Visualization”, In Proceedings of AAAI, 2015.

参考文献9 : Radoslaw Michalski, Sebastian Palus, and Przemyslaw Kazienko, “Matching Organizational Structure and Social Network Extracted from Email Communication”, In Lecture Notes in Business Information Processing, 2011.

参考文献10 : M.D. Conover, J. Ratkiewicz, M. Francisco, B. Goncalves, A. Flammini, and F. Menczer, “Political Polarization on Twitter”, In Proceedings of ICWSM, 2011.

[0110] [表2]

表2: データセット

dataset	#nodes	#links	Timespan (days)
ia-enron-employees	151	50.5K	1137.55
ia-radoslow-email	167	89.2K	271.19
ia-contact	274	28.2K	3.97
ia-contacts-hypertext09	113	20.8K	2.46
rt-pol	4036	60.2K	48.78

[0111] [比較手法]

評価実験では、本実施の形態に係る予測方法と、連続時間グラフを用いたリンク予測手法を含む5つの従来手法との比較を行う。以下に実験で用いる従来手法の概要を記載する。

[0112] GraphSAGE (参考文献11) は、任意のノードをembedding取得可能な静的グラフのinductiveなnode embedding手法である。

参考文献11 : William L. Hamilton, Rex Ying, and Jure Leskovec, “Inductive Representation Learning on Large Graphs”, In Proceedings of NeurIPS, 2017.

[0113] DySAT（非特許文献４）は、離散時間グラフを活用する最新のリンク予測手法である。TDGNN（非特許文献６）と、JODIE（非特許文献９）とは、連続時間グラフのnode embedding手法である。Dyrep（非特許文献８）は、点過程を用いた連続時間グラフのリンク予測手法である。

[0114] Prop_AllDataは、実施の形態に係る予測方法であって、使用する全データセットの学習データで学習したモデルを表す。Prop_SingleDataは、実施の形態に係る予測手法をテストするデータセットの学習データのみで学習したモデルを表す。

[0115] [精度評価結果１]

従来手法と実施の形態に係る予測方法との精度比較の結果を表３に示す。

[0116]

[表3]

表3: 精度評価											
datasets		ia-enron-employees		ia-radoslow-email		ia-contact		ia-contacts-hypertext09		rt-pol	
metrics	MR	Hits@10	MR	Hits@10	MR	Hits@10	MR	Hits@10	MR	Hits@10	
GraphSAGE	65.91±5.29	0.08±0.01	50.61±4.95	0.12±0.04	56.05±8.93	0.25±0.02	49.49±8.00	0.12±0.05	1709.50±398.29	0.00±0.00	
DySAT	43.73±1.79	0.21±0.00	63.03±2.57	0.10±0.01	94.11±24.92	0.05±0.04	53.44±7.79	0.16±0.08	1544.30±151.32	0.03±0.01	
TDGNN	45.44±0.34	0.14±0.03	32.70±0.02	0.27±0.00	41.35±6.73	0.19±0.00	31.61±0.47	0.25±0.00	1099.72±263.78	0.03±0.00	
JODIE	25.32±0.97	0.66±0.00	15.22±0.10	0.68±0.00	49.05±1.91	0.27±0.00	15.17±1.73	0.76±0.01	635.51±61.37	0.18±0.00	
DyRep	23.12±0.42	0.56±0.00	17.42±0.84	0.55±0.00	33.79±0.12	0.25±0.00	19.00±1.44	0.59±0.00	767.44±20.03	0.23±0.00	
Prop_AllData	18.32±2.18	0.64±0.03	9.73±2.94	0.74±0.11	14.91±2.51	0.88±0.02	14.99±1.43	0.75±0.03	329.00±18.77	0.09±0.02	
Prop_SingleData	19.49±1.29	0.55±0.01	24.97±1.61	0.26±0.04	23.06±6.50	0.68±0.23	15.81±0.92	0.72±0.02	341.51±16.86	0.10±0.01	

太字の結果は最高精度であることを表し、下線の結果は2番目に良い結果であることを示す。

太字の結果は最高精度であることを表し、下線の結果は2番目に良い結果であることを示す。

[0117] 全データセットを用いて学習したProp_AllDataは、ほぼ全てのデータセッ

トにおいて従来手法以上の精度を達成している。このことから、複数のデータセットから共通のリンク発生傾向を学習する本実施の形態に係る予測方法の有効性が確認できる。

[0118] 特に、Prop_AllDataでは、ia-contact及びrt-polのMRの値は、従来手法と比較して約2倍向上している。これら2つのデータセットは、表2に示すように、1ノードあたりのリンク数が少ない。このため、従来手法では、グラフサイズに対して学習に利用できる教師データ数が少ないため精度が低くなる。

[0119] 一方、Prop_AllDataでは、複数のデータセットを用いてモデルを学習するため、学習に利用できる教師データ数が少ないデータセットに対しても高精度なリンク予測が可能である。したがって、本実施の形態に係る予測方法は、従来手法と比較して予測精度を向上させることが可能である。

[0120] [精度評価結果2]

複数のデータセットでモデルを学習することで精度が向上することを確認するために、表3のProp_AllDataと、Prop_SingleDataとを比較する。この結果から、ほとんどのデータセットにおいて、複数のデータセットで学習した方が、1つのデータセットで学習した場合と比して、精度が高いことが確認できた。したがって、実施の形態に係る予測方法は、複数のデータセットを用いて学習することで、より高精度なリンク予測を実現できる。

[0121] [精度評価結果3]

次に、実施の形態に係る予測手法で導入した3種のシーケンス（ソースノードの行動履歴シーケンス、ターゲットノードの被行動履歴シーケンス、ソースノードへの情報伝播経路シーケンス）について、それぞれの有効性を確認する。ソースノードの行動履歴シーケンス、ターゲットノードの被行動履歴シーケンス、ソースノードへの情報伝播経路シーケンスのいずれかのシーケンスをそれぞれ削除した場合の予測精度を表4に示す。

[0122]

[表4]

表4: 各シーケンスを削除した場合の予測精度									
methods	Prop_AllData		Prop w/o src_seq		Prop w/o tgt_seq		Prop w/o propagation_seq		
	MR	Hits@10	MR	Hits@10	MR	Hits@10	MR	Hits@10	
ia-enron-employees	18.32±2.18	0.64±0.03	20.72±1.70	0.59±0.07	21.42±0.89	0.54±0.01	18.87±1.25	0.62±0.03	
ia-radoslow-email	9.73±2.94	0.74±0.11	12.10±4.70	0.66±0.15	19.79±0.22	0.41±0.01	9.19±3.46	0.74±0.15	
ia-contact	14.91±2.51	0.88±0.02	15.89±3.04	0.84±0.05	34.80±0.57	0.19±0.01	14.79±1.00	0.89±0.01	
ia-contacts-hypertext09	14.99±1.43	0.75±0.03	16.80±1.69	0.73±0.10	24.24±1.92	0.51±0.02	16.04±1.43	0.74±0.02	
rt-pol	329.00±18.77	0.09±0.02	349.06±37.63	0.08±0.02	786.24±6.43	0.09±0.00	365.83±85.18	0.09±0.03	

太字の結果は最高精度であることを表し、下線の結果は2番目に良い結果であることを示す。

[0123] Prop w/o src_seqは、3種のシーケンスのうち、ソースノードの行動履

歴シーケンスを削除した場合の予測精度である。Prop w/o tgt_seqは、3種のシーケンスのうちターゲットノードの被行動履歴シーケンスを削除した場合の予測精度である。Prop w/o propagation_seqは、3種のシーケンスのうちソースノードへの情報伝播経路シーケンスを削除した場合の予測精度である。

[0124] 表4より、ソースノードの行動履歴シーケンス、ターゲットノードの被行動履歴シーケンス、ソースノードへの情報伝播経路シーケンスのいずれかのシーケンスのいずれかを削除した場合でも、一定の予測精度を保持することができる。

[0125] そして、表4では、3種のシーケンス全てを用いた場合の予測精度が最も高いことが示されている。したがって、3種のシーケンスを用いて予測を行うことで、予測精度をさらに向上させることができることが分かった。また、シーケンスを削除したモデルの中ではProp w/o tgt seq が最も低い精度であった。これは、リンク発生が直前のターゲットノードの被リンクと強い依存関係があることを示している。

[0126] [精度評価結果4]

次に、予測装置20が作成するシーケンスの長さが予測精度に与える影響を評価した。図9は、シーケンス長を1～5の整数値に設定した場合の精度を示す図である。

[0127] 図9に示すように、予測装置20では、シーケンス長が2または3であるほうが、他のシーケンス長と比して精度が高いことが確認できた。したがって、予測装置20では、シーケンス長を2または3とすることが望ましい。

[0128] [実施の形態の効果]

このように、実施の形態では、複数のデータセットを用いて、Transformer encoder 1461-1～1461-3及びMLP 1471を学習する。このため、実施の形態では、学習に利用できる教師データ数が少ないデータセットがあっても、他のデータセットから必要な数の教師データを取得する。したがって、本実施の形態では、豊富な学習データから多様なリンク発生傾向

を学習可能となり、リンク発生予測の精度向上を図ることができる。

[0129] また、実施の形態では、複数のデータセットから、固定長のシーケンスを生成することで、Transformer encoder 1 4 6 1 - 1 ~ 1 4 6 1 - 3 の入力を、共通のシーケンスとすることを可能とする。これによって、実施の形態では、サイズがそれぞれ異なる複数のデータセットを用いる場合であっても、これらのデータセットに共通するリンク発生傾向を学習した予測モデルを実現することができる。

[0130] したがって、実施の形態では、複数種類のアプリケーションに共通のリンク発生予測モデルを実現することができた。このように、実施の形態では、リンクの発生をシーケンスとして表すことで、グラフデータの大きさや種類によらず、固定長の特徴を抽出し、複数のグラフデータから横断的に予測モデルを構築することができる。

[0131] また、実施の形態では、Transformer encoderを用いて固定長のリンク発生履歴シーケンスからリンク発生を学習することで、複数のデータセットに共通するリンクの発生傾向を適切に学習することができる。

[0132] また、実施の形態では、学習データから、ソースノードの行動履歴シーケンスに加え、ターゲットノードの被行動履歴シーケンス、及び／または、ソースノードへの情報伝播経路シーケンスを生成する。そして、実施の形態では、シーケンスの種類ごとにTransformer encoder 1 4 6 1 - 1 ~ 1 4 6 1 - 3 を設けて、各シーケンスの特徴量を取得し、複数のTransformer encoderの出力を結合した特徴量を基に、リンク発生予測を行う。

[0133] したがって、実施の形態では、リンク発生の構造的傾向として、ソースノードの行動パターンとともにターゲットノードの被行動パターンを捉え、さらに、リンク発生の時間的傾向としてソースノードへの情報伝播経路を捉えることで、多様なリンク発生傾向を捉えた予測モデルを実現した。

[0134] また、実施の形態では、リンク発生の時間的傾向を学習するために、ノードの行動履歴シーケンスに対してリンク発生時刻に基づくtemporal encodingを行うことで、Transformer encoderが一般的なノードの行動周期を学習す

る。また、実施の形態では、予測対象データを用いずに学習モデルを構築し、その後少量の予測対象データの学習のみFinetuningで、予測の精度を向上させることも可能である。

[0135] なお、実施の形態では、予測時刻におけるソースノードとターゲットノードとの間のリンクの発生を予測する場合を例に説明したが、これに限らない。実施の形態では、複数の予測結果を組み合わせ、さらに発展的な予測を可能とすることができる。

[0136] 例えば、電子メールネットワークの場合を例に説明する。ソースノードであるユーザが、17時にどのユーザに電子メールを送信するかを予測する場合を例とする。この場合、予測装置20は、ターゲットノードを、送信先となり得る各ユーザに変えて、各ユーザにソースノードであるユーザが17時に電子メールを出す確率（リンク発生確率）を予測する。そして、予測装置20は、最も高い確率を示すユーザを予測結果として出力する。

[0137] また、ソースノードであるユーザが、17時から18時の間に何回電子メールを送るかを予測する場合を例とする。この場合、予測装置20は、この間の単位時間ごとの予測結果を積算し、積算結果を予測結果として出力する。この場合には、予測装置20の入力として、ターゲットノードを指定せずともよい。このように、予測対象となるアプリケーションや予測内容に応じて、ソースノードの行動履歴、ターゲットノードの被行動履歴、及び、ソースノードへの情報伝播経路のいずれを重要視するかが異なる。

[0138] したがって、実施の形態では、常に、ソースノードの行動履歴シーケンス、ターゲットノードの被行動履歴シーケンス、及び、ソースノードへの情報伝播経路シーケンスの全てを作成する必要はなく、解きたい問題に応じた種類のシーケンスを作成すればよい。これにともない、実施の形態では、シーケンスの種類に応じた数のTransformer encoderを設ければよい。したがって、実施の形態で使用するTransformer encoderの数は、複数に限らず、単数であってもよい。

[0139] また、実施の形態では、連続時間グラフを用いて予測する場合を例に説明

したが、用いるデータは、ソースノードとターゲットノードとの間のリンクの発生、及び、リンクの発生時刻が判別できる時系列データであれば足りる。

[0140] 実施の形態に係る予測方法は、SNS (Social Networking Service) 等を介してネットワーク上に発信したメッセージがどのくらいまで広まるかを予測するトレンド予測システム、電子メールネットワークでの業務メッセージの流れの予測結果を用いたスケジュール管理システム、誰が何をいつ買うかの予測結果に基づく商品の在庫管理システムや商品のレコメンドシステムなど、広く適用可能である。

[0141] [実施の形態のシステム構成について]

学習装置10及び予測装置20の各構成要素は機能概念的なものであり、必ずしも物理的に図示のように構成されていることを要しない。すなわち、学習装置10及び予測装置20の機能の分散及び統合の具体的形態は図示のものに限られず、その全部または一部を、各種の負荷や使用状況などに応じて、任意の単位で機能的または物理的に分散または統合して構成することができる。

[0142] また、学習装置10及び予測装置20においておこなわれる各処理は、全部または任意の一部が、CPU、GPU (Graphics Processing Unit)、及び、CPU、GPUにより解析実行されるプログラムにて実現されてもよい。また、学習装置10及び予測装置20においておこなわれる各処理は、ワイヤードロジックによるハードウェアとして実現されてもよい。

[0143] また、実施の形態において説明した各処理のうち、自動的におこなわれるものとして説明した処理の全部または一部を手動的に行うこともできる。もしくは、手動的におこなわれるものとして説明した処理の全部または一部を公知の方法で自動的に行うこともできる。この他、上述及び図示の処理手順、制御手順、具体的名称、各種のデータやパラメータを含む情報については、特記する場合を除いて適宜変更することができる。

[0144] [プログラム]

図10は、プログラムが実行されることにより、学習装置10及び予測装置20が実現されるコンピュータの一例を示す図である。コンピュータ1000は、例えば、メモリ1010、CPU1020を有する。また、コンピュータ1000は、ハードディスクドライバインタフェース1030、ディスクドライバインタフェース1040、シリアルポートインタフェース1050、ビデオアダプタ1060、ネットワークインタフェース1070を有する。これらの各部は、バス1080によって接続される。

[0145] メモリ1010は、ROM1011及びRAM1012を含む。ROM1011は、例えば、BIOS (Basic Input Output System) 等のブートプログラムを記憶する。ハードディスクドライバインタフェース1030は、ハードディスクドライブ1090に接続される。ディスクドライバインタフェース1040は、ディスクドライブ1100に接続される。例えば磁気ディスクや光ディスク等の着脱可能な記憶媒体が、ディスクドライブ1100に挿入される。シリアルポートインタフェース1050は、例えばマウス1110、キーボード1120に接続される。ビデオアダプタ1060は、例えばディスプレイ1130に接続される。

[0146] ハードディスクドライブ1090は、例えば、OS (Operating System) 1091、アプリケーションプログラム1092、プログラムモジュール1093、プログラムデータ1094を記憶する。すなわち、学習装置10及び予測装置20の各処理を規定するプログラムは、コンピュータ1000により実行可能なコードが記述されたプログラムモジュール1093として実装される。プログラムモジュール1093は、例えばハードディスクドライブ1090に記憶される。例えば、学習装置10及び予測装置20における機能構成と同様の処理を実行するためのプログラムモジュール1093が、ハードディスクドライブ1090に記憶される。なお、ハードディスクドライブ1090は、SSD (Solid State Drive) により代替されてもよい。

[0147] また、上述した実施の形態の処理で用いられる設定データは、プログラムデータ1094として、例えばメモリ1010やハードディスクドライブ1

０９０に記憶される。そして、ＣＰＵ１０２０が、メモリ１０１０やハードディスクドライブ１０９０に記憶されたプログラムモジュール１０９３やプログラムデータ１０９４を必要に応じてＲＡＭ１０１２に読み出して実行する。

[0148] なお、プログラムモジュール１０９３やプログラムデータ１０９４は、ハードディスクドライブ１０９０に記憶される場合に限らず、例えば着脱可能な記憶媒体に記憶され、ディスクドライブ１１００等を介してＣＰＵ１０２０によって読み出されてもよい。あるいは、プログラムモジュール１０９３及びプログラムデータ１０９４は、ネットワーク（ＬＡＮ（Local Area Network）、ＷＡＮ（Wide Area Network）等）を介して接続された他のコンピュータに記憶されてもよい。そして、プログラムモジュール１０９３及びプログラムデータ１０９４は、他のコンピュータから、ネットワークインタフェース１０７０を介してＣＰＵ１０２０によって読み出されてもよい。

[0149] 以上、本発明者によってなされた発明を適用した実施の形態について説明したが、本実施の形態による本発明の開示の一部をなす記述及び図面により本発明は限定されることはない。すなわち、本実施の形態に基づいて当業者等によりなされる他の実施の形態、実施例及び運用技術等は全て本発明の範疇に含まれる。

符号の説明

- [0150] １０ 学習装置
- １１， ２１ 通信部
- １２， ２２ 入出力部
- １３， ２３ 記憶部
- １４， ２４ 制御部
- ２０ 予測装置
- １３１ データ記憶部
- １３２ 学習データ記憶部
- １３３ 正解データ記憶部

1 3 4 シーケンス記憶部

1 3 5 パラメータ記憶部

1 4 1 データ生成部

1 4 2, 2 4 1 予測部

1 4 3 更新部

1 4 4 制御処理部

1 4 5, 2 4 2 シーケンス生成部

1 4 6, 2 4 3 特徴量取得部

1 4 7, 2 4 4 算出部

1 4 6 1 - 1 ~ 1 4 6 1 - 3, 2 4 3 1 - 1 ~ 2 4 3 1 - 3 Transformer
encoder

1 4 6 2, 2 4 3 2 結合部

1 4 7 1, 2 4 4 1 MLP

請求の範囲

- [請求項1] 複数種類のアプリケーションからそれぞれ取得された複数の時系列データに基づく学習データから固定長のシーケンスを生成する生成部と、
- 第1の深層学習モデルを用いて、前記シーケンスの特徴量を取得する取得部と、
- 第2の深層学習モデルを用いて、前記シーケンスの特徴量から、前記学習データに対応するイベントまたはデータの発生の予測結果を求める予測部と、
- 前記予測結果と、前記学習データの正解データとの誤差が小さくなるように、前記第1の深層学習モデル及び前記第2の深層学習モデルのパラメータを更新する更新部と、
- を有することを特徴とする学習装置。
- [請求項2] 前記第1の深層学習モデルは、時系列深層学習モデルであることを特徴とする請求項1に記載の学習装置。
- [請求項3] 前記生成部は、前記学習データから複数種類の前記シーケンスを生成し、
- 前記取得部は、前記シーケンスの種類ごとに前記時系列深層学習モデルを有し、複数の前記時系列深層学習モデルの出力を結合して、前記予測部に出力することを特徴とする請求項2に記載の学習装置。
- [請求項4] 前記時系列データは、ノードのペアと、前記ペア間のリンクと、前記リンクが発生した時刻情報とによって構成された時系列グラフであり、
- 前記予測部は、学習対象のノードのペア間におけるリンクの発生を予測し、
- 前記生成部は、複数の前記時系列グラフを基に、前記学習対象のノードのペアと、前記学習対象のノードのペア間のリンク発生時刻より前にリンクが発生した所定数のノードのペアのそれぞれとについて、

前記リンクの発生履歴を表すシーケンスを生成することを特徴とする請求項3に記載の学習装置。

[請求項5]

前記生成部は、複数の前記時系列グラフを基に、前記学習対象のノードのペアと、前記所定数のノードのペアのそれぞれについて、ソースノードの行動履歴を表す第1のシーケンス、ターゲットノードの被行動履歴を表す第2のシーケンス及び／または前記ソースノードへの情報伝搬経路を表す第3のシーケンスを生成し、

前記取得部は、

前記第1のシーケンスを入力とし、前記ソースノードの行動パターンを捉えた第1の潜在表現を出力する第1の前記時系列深層学習モデルと、

前記第2のシーケンスを入力とし、前記ターゲットノードの被行動パターンを捉えた第2の潜在表現を出力する第2の前記時系列深層学習モデルと、

前記第3のシーケンスを入力とし、前記ソースノードへの情報伝搬パターンを捉えた第3の潜在表現を出力する第3の前記時系列深層学習モデルと、

前記第1の潜在表現、前記第2の潜在表現及び／または前記第3の潜在表現に対し、それぞれの潜在表現の重要度に応じて重み付けをした後に結合した特徴量を生成する結合部と、

を有し、

前記予測部は、深層学習モデルを用いて、前記学習対象のノードのペア間におけるリンクの発生を予測することを特徴とする請求項4に記載の学習装置。

[請求項6]

イベントまたはデータの発生の予測対象のデータと、前記予測対象のデータに関連する時系列データとを入力とし、入力データから固定長のシーケンスを生成する生成部と、

複数種類のアプリケーションからそれぞれ取得された複数の時系列

データに基づく学習データを用いて学習された第1の深層学習モデルを用いて、前記シーケンスの特徴量を取得する取得部と、

前記学習データを用いて学習された第2の深層学習モデルを用いて、前記シーケンスの特徴量から、前記予測対象のデータに対応するイベントまたはデータの発生の予測結果を求める予測部と、

を有することを特徴とする予測装置。

[請求項7]

学習装置が実行する学習方法であって、

複数種類のアプリケーションからそれぞれ取得された複数の時系列データに基づく学習データから固定長のシーケンスを生成する工程と、

第1の深層学習モデルを用いて、前記シーケンスの特徴量を取得する工程と、

第2の深層学習モデルを用いて、前記シーケンスの特徴量から、前記学習データに対応するイベントまたはデータの発生の予測結果を求める工程と、

前記予測結果と、前記学習データの正解データとの誤差が小さくなるように、前記第1の深層学習モデル及び前記第2の深層学習モデルのパラメータを更新する工程と、

を含んだことを特徴とする学習方法。

[請求項8]

予測装置が実行する予測方法であって、

イベントまたはデータの発生の予測対象のデータと、前記予測対象のデータに関連する時系列データとを入力とし、入力データから固定長のシーケンスを生成する工程と、

複数種類のアプリケーションからそれぞれ取得された複数の時系列データに基づく学習データを用いて学習された第1の深層学習モデルを用いて、前記シーケンスの特徴量を取得する工程と、

前記学習データを用いて学習された第2の深層学習モデルを用いて、前記シーケンスの特徴量から、前記予測対象のデータに対応するイ

ベントまたはデータの発生の予測結果を求める工程と、
を含んだことを特徴とする予測方法。

[請求項9] 複数種類のアプリケーションからそれぞれ取得された複数の時系列データに基づく学習データから固定長のシーケンスを生成するステップと、

第1の深層学習モデルを用いて、前記シーケンスの特徴量を取得するステップと、

第2の深層学習モデルを用いて、前記シーケンスの特徴量から、前記学習データに対応するイベントまたはデータの発生の予測結果を求めるステップと、

前記予測結果と、前記学習データの正解データとの誤差が小さくなるように、前記第1の深層学習モデル及び前記第2の深層学習モデルのパラメータを更新するステップと、

をコンピュータに実行させるための学習プログラム。


[請求項10] イベントまたはデータの発生の予測対象のデータと、前記予測対象のデータに関連する時系列データとを入力とし、入力データから固定長のシーケンスを生成するステップと、

複数種類のアプリケーションからそれぞれ取得された複数の時系列データに基づく学習データを用いて学習された第1の深層学習モデルを用いて、前記シーケンスの特徴量を取得するステップと、


前記学習データを用いて学習された第2の深層学習モデルを用いて、前記シーケンスの特徴量から、前記予測対象のデータに対応するイベントまたはデータの発生の予測結果を求めるステップと、

をコンピュータに実行させるための予測プログラム。


[図1]



[図2]



[図3]



[図4]

Algorithm 1 Extracting node action sequence

Require: test data (v^{src}, v^{tgt}, t) , CTDN $g(t)$, sequence length,

$node \in \{src, tgt\}, l^{node}$

Ensure: node action sequence S^{node}

```

1:  $S^{node} = [(v^{src}, v^{tgt}, t)]$ 
2: for  $i = 0$  to  $|\varepsilon^t|$  do
3:   if  $v_{|\varepsilon^t|-i}^{node} == v^{node}$  then
4:     add  $e_{|\varepsilon^t|-i}$  to  $S^{node}$ 
5:   end if
6:   if  $|S^{node}| == l^{node}$  then
7:     break
8:   end if
9: end for
10: Sort  $S^{node}$  by  $t$  in ascending order
11: return  $S^{node}$ 

```

[図5]

Algorithm 2 Extracting information propagation sequence

Require: test data (v^{src}, v^{tgt}, t) , CTDN $g(t)$, sequence length $l^{propagation}$


Ensure: source node action sequence $S^{propagation}$

```


1:  $S^{propagation} = [(v^{src}, v^{tgt}, t)]$ 
2:  $v_{temp} = v^{src}$ 
3: for  $i = 0$  to  $|\varepsilon^t|$  do
4:   if  $v_{|\varepsilon^t|-i}^{tgt} == v_{temp}$  then
5:     add  $e_{|\varepsilon^t|-i}$  to  $S^{propagation}$ 
6:      $v_{temp} = v_{|\varepsilon^t|-i}^{src}$ 
7:   end if
8:   if  $|S^{propagation}| == l^{propagation}$  then
9:     break
10:  end if
11: end for
12: Sort  $S^{propagation}$  by  $t$  in ascending order
13: return  $S^{propagation}$ 

```


[図6]




[図7]




[図8]



[図9]



[図10]



INTERNATIONAL SEARCH REPORT

International application No.

PCT/JP2023/001699

A. CLASSIFICATION OF SUBJECT MATTER**G06N 20/00**(2019.01)i

FI: G06N20/00 130

According to International Patent Classification (IPC) or to both national classification and IPC

B. FIELDS SEARCHED

Minimum documentation searched (classification system followed by classification symbols)

G06N20/00

Documentation searched other than minimum documentation to the extent that such documents are included in the fields searched

Published examined utility model applications of Japan 1922-1996
 Published unexamined utility model applications of Japan 1971-2023
 Registered utility model specifications of Japan 1996-2023
 Published registered utility model applications of Japan 1994-2023

Electronic data base consulted during the international search (name of data base and, where practicable, search terms used)

C. DOCUMENTS CONSIDERED TO BE RELEVANT

Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
A	山口真弥, 敵対的生成ネットワークの複数データセット同時学習によるデータ拡張, 第11回データ工学と情報マネジメントに関するフォーラム (第17回日本データベース学会年次大会) [online], 06 March 2019, P1-114, pp. 1-8 in particular, see chapter "3 Domain Fusion", (YAMAGUCHI, Shinya), non-official translation (Data augmentation by simultaneous learning of multiple datasets for generative adversarial networks. The 11th Forum on Data Engineering and Information Management (The 17th Annual Conference of the Database Society of Japan) [online].)	1-10
A	WO 2021/149528 A1 (OSAKA UNIVERSITY) 29 July 2021 (2021-07-29) paragraphs [0017], [0020], [0029]-[0030]	1-10
A	JP 2019-502212 A (PREFERRED NETWORKS INC) 24 January 2019 (2019-01-24) paragraphs [0002], [0015], [0023]-[0024]	1-10
A	ZUO, Simiao et al. Transformer Hawkes Process. PMLR: Proceedings of Machine Learning Research. 18 July 2020, vol. 119, pp. 11692-11702, http://proceedings.mlr.press/v119/zuo20a/zuo20a.pdf , ISSN 2640-3498 entire text, all drawings	1-10



Further documents are listed in the continuation of Box C.



See patent family annex.

* Special categories of cited documents:

"A" document defining the general state of the art which is not considered to be of particular relevance
 "E" earlier application or patent but published on or after the international filing date
 "L" document which may throw doubts on priority claim(s) or which is cited to establish the publication date of another citation or other special reason (as specified)
 "O" document referring to an oral disclosure, use, exhibition or other means
 "P" document published prior to the international filing date but later than the priority date claimed

"T" later document published after the international filing date or priority date and not in conflict with the application but cited to understand the principle or theory underlying the invention
 "X" document of particular relevance; the claimed invention cannot be considered novel or cannot be considered to involve an inventive step when the document is taken alone
 "Y" document of particular relevance; the claimed invention cannot be considered to involve an inventive step when the document is combined with one or more other such documents, such combination being obvious to a person skilled in the art
 "&" document member of the same patent family

Date of the actual completion of the international search

15 March 2023

Date of mailing of the international search report

04 April 2023

Name and mailing address of the ISA/JP

Japan Patent Office (ISA/JP)
 3-4-3 Kasumigaseki, Chiyoda-ku, Tokyo 100-8915
 Japan

Authorized officer

Telephone No.

INTERNATIONAL SEARCH REPORT
Information on patent family members

International application No.
PCT/JP2023/001699

Patent document cited in search report			Publication date (day/month/year)	Patent family member(s)	Publication date (day/month/year)
WO	2021/149528	A1	29 July 2021	US 2023/058585 A1 paragraphs [0056], [0059], [0070]-[0071]	
JP	2019-502212	A	24 January 2019	WO 2017/122784 A1 paragraphs [0002], [0015], [0023]-[0024]	
				US 2017/0206464 A1	

A. 発明の属する分野の分類（国際特許分類（IPC）） G06N 20/00(2019.01)i FI: G06N20/00 130										
B. 調査を行った分野 調査を行った最小限資料（国際特許分類（IPC）） G06N20/00 最小限資料以外の資料で調査を行った分野に含まれるもの <table border="0"> <tr> <td>日本国実用新案公報</td> <td>1922 - 1996年</td> </tr> <tr> <td>日本国公開実用新案公報</td> <td>1971 - 2023年</td> </tr> <tr> <td>日本国実用新案登録公報</td> <td>1996 - 2023年</td> </tr> <tr> <td>日本国登録実用新案公報</td> <td>1994 - 2023年</td> </tr> </table> 国際調査で使用した電子データベース（データベースの名称、調査に使用した用語）			日本国実用新案公報	1922 - 1996年	日本国公開実用新案公報	1971 - 2023年	日本国実用新案登録公報	1996 - 2023年	日本国登録実用新案公報	1994 - 2023年
日本国実用新案公報	1922 - 1996年									
日本国公開実用新案公報	1971 - 2023年									
日本国実用新案登録公報	1996 - 2023年									
日本国登録実用新案公報	1994 - 2023年									
C. 関連すると認められる文献										
引用文献の カテゴリー*	引用文献名 及び一部の箇所が関連するときは、その関連する箇所の表示	関連する 請求項の番号								
A	山口真弥, 敵対的生成ネットワークの複数データセット同時学習によるデータ拡張, 第11回データ工学と情報マネジメントに関するフォーラム（第17回日本データベース学会年次大会）[online], 2019.03.06, P1-114, pp.1-8 特に「3 Domain Fusion」の章を参照。	1-10								
A	WO 2021/149528 A1（国立大学法人大阪大学）29.07.2021（2021 - 07 - 29） 段落[0017], [0020]及び[0029]-[0030]	1-10								
A	JP 2019-502212 A（株式会社Preferred Networks）24.01.2019（2019 - 01 - 24） 段落[0002], [0015]及び[0023]-[0024]	1-10								
A	ZUO, Simiao et al., Transformer Hawkes Process, PMLR: Proceedings of Machine Learning Research, 2020.07.18, Vol.119, pp.11692-11702, http://proceedings.mlr.press/v119/zuo20a/zuo20a.pdf , ISSN 2640-3498 全文, 全図	1-10								
☐ C欄の続きにも文献が列挙されている。 ☒ パテントファミリーに関する別紙を参照。										
<table border="0"> <tr> <td> * 引用文献のカテゴリー “A” 特に関連のある文献ではなく、一般的技術水準を示すもの “E” 国際出願日前の出願または特許であるが、国際出願日以後に公表されたもの “L” 優先権主張に疑義を提起する文献又は他の文献の発行日若しくは他の特別な理由を確立するために引用する文献（理由を付す） “O” 口頭による開示、使用、展示等に言及する文献 “P” 国際出願日前で、かつ優先権の主張の基礎となる出願の日の後に公表された文献 </td> <td> “T” 国際出願日又は優先日後に公表された文献であって出願と抵触するものではなく、発明の原理又は理論の理解のために引用するもの “X” 特に関連のある文献であって、当該文献のみで発明の新規性又は進歩性がないと考えられるもの “Y” 特に関連のある文献であって、当該文献と他の1以上の文献との、当業者にとって自明である組合せによって進歩性がないと考えられるもの “&” 同一パテントファミリー文献 </td> </tr> </table>			* 引用文献のカテゴリー “A” 特に関連のある文献ではなく、一般的技術水準を示すもの “E” 国際出願日前の出願または特許であるが、国際出願日以後に公表されたもの “L” 優先権主張に疑義を提起する文献又は他の文献の発行日若しくは他の特別な理由を確立するために引用する文献（理由を付す） “O” 口頭による開示、使用、展示等に言及する文献 “P” 国際出願日前で、かつ優先権の主張の基礎となる出願の日の後に公表された文献	“T” 国際出願日又は優先日後に公表された文献であって出願と抵触するものではなく、発明の原理又は理論の理解のために引用するもの “X” 特に関連のある文献であって、当該文献のみで発明の新規性又は進歩性がないと考えられるもの “Y” 特に関連のある文献であって、当該文献と他の1以上の文献との、当業者にとって自明である組合せによって進歩性がないと考えられるもの “&” 同一パテントファミリー文献						
* 引用文献のカテゴリー “A” 特に関連のある文献ではなく、一般的技術水準を示すもの “E” 国際出願日前の出願または特許であるが、国際出願日以後に公表されたもの “L” 優先権主張に疑義を提起する文献又は他の文献の発行日若しくは他の特別な理由を確立するために引用する文献（理由を付す） “O” 口頭による開示、使用、展示等に言及する文献 “P” 国際出願日前で、かつ優先権の主張の基礎となる出願の日の後に公表された文献	“T” 国際出願日又は優先日後に公表された文献であって出願と抵触するものではなく、発明の原理又は理論の理解のために引用するもの “X” 特に関連のある文献であって、当該文献のみで発明の新規性又は進歩性がないと考えられるもの “Y” 特に関連のある文献であって、当該文献と他の1以上の文献との、当業者にとって自明である組合せによって進歩性がないと考えられるもの “&” 同一パテントファミリー文献									
国際調査を完了した日 15.03.2023		国際調査報告の発送日 04.04.2023								
名称及びあて先 日本国特許庁(ISA/JP) 〒100-8915 日本国 東京都千代田区霞が関三丁目4番3号		権限のある職員（特許庁審査官） 坂庭 剛史 5B 9288 電話番号 03-3581-1101 内線 3545								

国際調査報告
パテントファミリーに関する情報

国際出願番号

PCT/JP2023/001699

引用文献			公表日	パテントファミリー文献			公表日
WO	2021/149528	A1	29.07.2021	US	2023/058585	A1	
				段落[0056], [0059]及び [0070]-[0071]			
JP	2019-502212	A	24.01.2019	WO	2017/122784	A1	
				段落[0002], [0015]及び [0023]-[0024]			
				US	2017/0206464	A1	