

Graph Neural Networks for Natural Language Processing

A systematic literature review

Introduzione

Un'enorme varietà di problemi del NLP può essere espressa tramite strutture a grafo, in particolare Graph Neural Networks.


Questo si è già visto con popolari tecniche di deep-learning come Convolutional Neural Network (Cnn) o Recurrent Neural Network (Rnn), usate per realizzare nuove tecniche basate su grafi.

L'obiettivo di questa SLR è stato quello di investigare queste nuove tecniche ed esaminarle nell'ambito dell'iniezione di conoscenza

Keywords and Keyphrases

Keyword individuate:

- Nlp
- Gnn
- Gcn
- Graph Embedding
- Knowledge base completion



Query:

- Nlp *AND* Gnn
- Nlp *AND* Gnn *AND* Gcn
- Nlp *AND* Gnn *AND* Graph *AND* Embedding
- Nlp *AND* Gnn *AND* Knowledge *AND* Aware *AND* Model
- Nlp *AND* Gnn *AND* Knowledge *AND* Base *AND* Completion

Fonti

- Google Scholar
- Semantic Scholar
- Scopus

	Semantic Scholar	Google Scholar	Scopus
Nlp Gnn	5250	6300	28
Nlp Gnn Gcn	343	3350	1
Nlp Gnn Graph Embedding	1030	5760	7
Nlp Gnn Knowledge Aware Model	172	3760	1
Nlp Gnn Knowledge Base Completion	87	3540	13

Selezione primaria dei paper

Sono stati inclusi:

- Paper completi inerenti alle domande della ricerca in lingua inglese

Sono stati esclusi:

- Documenti duplicati
- Documenti non inerenti alle domande della ricerca
- Libri

Nessuna restrizione in termini di data

Successiva selezione

Esaminati titoli ed abstract dei primi 100 documenti per ogni ricerca, questo ha ristretto ad una prima lista di 43 documenti.

Esaminando questi documenti alcuni sono stati scartati in seguito, arrivando al numero finale di 39.

Le domande di ricerca

- Quali sono i problemi del NLP in cui sono state utilizzate tecniche di deep learning basate sui grafi?
- Come possono essere classificate?
- Come sono state usate per l'iniezione di conoscenza? E che tipo di conoscenza è stata iniettata?
- Quali sono i vantaggi e gli svantaggi dell'utilizzo di queste tecniche rispetto ai metodi tradizionali?

Tecniche utilizzate


Sono state proposte soluzioni per numerosi problemi del NLP, come:

- Sentiment analysis
- Machine reading comprehension
- Question answering
- Text classification
- Fake news detection
- Knowledge base completion
- Natural language inference

Sentiment analysis

Tecnica per determinare se un testo ha una connotazione positiva, negativa o neutra

Le Gnn riescono a catturare le caratteristiche strutturali del testo, e a imitare la capacità di comprendere il linguaggio a diversi livelli



Es: Multi-Level Graph Neural Network

Sfruttando Gnn su multipli livelli si riesce a catturare informazioni da ogni livello del testo

Questo simula la capacità umana di ragionare sul testo con diverse prospettive

Machine reading comprehension

Il problema di addestrare un modello in grado di comprendere domande e formulare risposte

Una soluzione in particolare propone Graph Sequential Network, in grado di lavorare direttamente su sequenze di feature, rappresentate come nodi di un grafo.

Co-attention per message passing → impara le rappresentazioni del nodo corrente con conoscenza dei nodi vicini

Questo rinforza la capacità di ragionare su sequenze

Simile al modello impiegato da ChatGPT


Question answering

QA-GNN, modello per effettuare ragionamenti su conoscenza strutturata e non strutturata

Fonde modelli linguistici con knowledge graph

Dato un contesto è in grado di recuperare conoscenza da un Kg e creare così un joint graph.

Mentre il sistema di attention della Gnn opera sul grafo, farà leva e aggiornerà la rappresentazione del contesto e del KG. (Joint reasoning)




Text classification

Classificazione di etichette di testo in categorie

Categoria di lavori molto popolata, la maggior parte dei documenti tratta questo argomento

Preso in esempio VGCN-BERT, dove una Gcn è impiegata su un grafo vocabolario ottenendo i word embedding, dati poi in pasto ad un encoder con self-attention.

Classifica informazioni locali e globali



Natural language inference

Determinare se un ipotesi è vera, falsa o indeterminata data una premessa

La possibilità di iniettare conoscenza pregressa è stata considerata solo di recente

ConSeqNet : sfrutta sia informazioni dal testo, sia conoscenza strutturale ottenuta da diverse knowledge base esterne

Modello suddiviso in due parti:

- Modello text-based → effettua l'encoding di premessa e ipotesi usando Recurrent Neural Networks con un layer di attention
- Modello graph-based → genera grafi per ipotesi e premessa mappando frasi a concetti presenti in un knowledge graph

I risultati dei due modelli sono poi concatenati e passati ad una rete feed-forward per la classificazione finale

Classificazione delle metodologie

Le principali tipologie di Graph Neural Network utilizzate dai paper esaminati

	Works
GNN	[7] [10] [13] [11] [8] [24] [38] [20] [36] [37]
GCN	[19] [9] [18] [37] [26] [11] [29] [27] [5] [25] [16]
GGNN	[40] [34] [26]
GIN	[6] [23]
LSTM	[20] [29] [39] [30]
GAT	[36] [21] [15]
MPNN	[34]

Molte soluzioni però hanno proposto varianti delle versioni base di questi modelli, ed ottenendo successi.

Si notano però molte costanti nell'utilizzo di meccanismi come quello dell'attention nelle varie soluzioni

Iniezione di conoscenza

Dagli esempi visti in precedenza si può notare come i grafi possano essere utilizzati per l'iniezione di conoscenza


I nodi rappresentano il testo di base (parole, paragrafi, documenti etc..) mentre i collegamenti rappresentano relazioni (struttura sintattica, relazioni semantiche, somiglianza lessicale ed altri collegamenti basati su conoscenza)

Queste relazioni vengono usate come conoscenza di background, che da metodi tradizionali viene spesso ignorata, ma sono conosciute e captate normalmente dagli esseri umani

Iniezione di conoscenza

Ad esempio molti dei lavori individuati fanno leva su ConceptNet, una knowledge base per rappresentare il raziocinio

Questo permette di comprendere meglio il significato del linguaggio e del significato che si cela dietro le singole parole



Pro e contro

Gran parte delle soluzioni individuate hanno prodotto miglioramenti, anche significativi

Method	Dim.	SST-binary	SenTube-A	SenTube-T
BOW	–	80.7	60.6	66
AVE	50	74.1	62	61.7
	100	76.7	61.5	61.8
	200	78.2	60.6	62.8
	300	80.3	61.5	64.3
LSTM	50	80.5 ± 0.4	58.9 ± 0.8	63.4 ± 3.1
	100	79.5 ± 0.6	58.9 ± 1.1	63.1 ± 0.4
	200	80.9 ± 0.6	58.6 ± 0.6	65.2 ± 1.6
	300	81.7 ± 0.6	57.4 ± 1.3	63.6 ± 0.7
BiLSTM	50	82.9 ± 0.7	59.5 ± 1.1	65.6 ± 1.2
	100	79.8 ± 1.0	58.6 ± 0.8	66.4 ± 1.4
	200	80.1 ± 0.6	58.9 ± 0.3	63.3 ± 1.0
	300	82.6 ± 0.7	59.3 ± 1.0	66.2 ± 1.5
CNN	50	81.7 ± 0.3	55.2 ± 0.7	57.4 ± 3.1
	100	81.6 ± 0.5	56.0 ± 2.2	61.5 ± 1.1
	200	80.7 ± 0.4	56.3 ± 1.8	64.1 ± 1.1
	300	81.3 ± 1.1	57.3 ± 0.5	62.1 ± 1.0
Huang et al.	50	82.5 ± 0.1	60.0 ± 0.3	67.3 ± 0.1
	100	82.6 ± 0.1	60.2 ± 0.2	67.3 ± 0.1
	200	82.5 ± 0.3	59.7 ± 0.1	67.1 ± 0.1
	300	82.6 ± 0.2	59.7 ± 0.1	67.4 ± 0.2
MLGNN	50	81.3 ± 0.5	61.5 ± 2.9	67.9 ± 0.5
	100	82.4 ± 0.5	61.2 ± 3.5	68.1 ± 0.5
	200	82.4 ± 1.1	61.5 ± 1.5	67.7 ± 0.6
	300	83.1 ± 0.4	62.2 ± 0.5	68.0 ± 0.4

Performance di MLGNN per sentiment analysis su diversi dataset di commenti sul web

Migliori performance su SST-binary e SenTube-A con word embedding di dimensione 300 e su SenTube-T a dimensione 100

Pro e contro

Altro esempio: punteggio F1 per la classificazione del testo tra VGCN-BERT e altri metodi baseline

Si nota come versioni modificate dello stesso modello proposto, portino ulteriori miglioramenti

Model	SST-2	MR	CoLA	ArangoHate	FountaHate
MLP	80.78	75.55	61.39 (53.20)	84.71 (84.42)	79.22 (65.33)
Text-GCN	80.45	75.67	56.18 (52.30)	84.77 (84.43)	78.74 (64.54)
Bi-LSTM	81.32	76.39	62.88 (55.25)	84.92 (84.58)	79.04 (65.13)
VGCN	81.64	76.42	63.59 (54.82)	85.97 (85.69)	79.00 (64.04)
BERT	<u>91.49</u>	86.24	<u>81.22</u> (<u>77.02</u>)	87.99 (87.75)	80.59 (66.61)
Vanilla-VGCN-BERT	91.38	86.49	80.70 (76.30)	<u>88.01</u> (<u>87.79</u>)	<u>81.11</u> (<u>67.86</u>)
VGCN-BERT	91.93	<u>86.35</u>	83.68 (80.46)	88.43 (88.22)	81.26 (68.45)

Pro e contro

Altri miglioramenti non quantificabili:

- Tecniche in grado di catturare la struttura del testo, ignorata da metodi tradizionali
- Permettono di catturare elementi nascosti nel testo, come sarcasmo e umorismo

Pro e contro

Principale svantaggio:

- Molti lavori fanno notare l'introduzione di problemi sostanziali di capacità computazionali, specialmente operando su larghe quantità di dati, per via della natura ricorrente dei modelli
- Alcuni optano per la specializzazione su testi corti, altri propongono metodi alternativi per ridurre l'impatto sulle performance
- In generale si notano successi, ma rimane una problematica da tenere in considerazione

Conclusioni

Dal lavoro è risultato evidente che i problemi del NLP possono essere affrontati utilizzando un approccio basato su grafi con successo

Ma costruire dei grafi di buona qualità e specifici per i domini da affrontare richiede ancora molto lavoro e conoscenza del dominio

Risultano un passo avanti nel campo dell'intelligenza artificiale, specialmente nel campo della comprensione ed emulazione di conoscenza ed emozioni

Grazie per l'attenzione