


RNN

Sieci rekurencyjne i modelowanie sekwencji

Modelowanie sekwencji

- Dane sekwencyjne lub zależne od czasu: sygnał audio, tekst, ruch obiektów, EEG, ...
- Modelowanie sekwencji: generowanie tekstu (chaterboty), generowanie muzyki, etykietowanie obrazów, sterowanie ruchem robota, ...
- Przetwarzanie sekwencji: maszynowe tłumaczenie, rozpoznawanie mowy, rozpoznawanie pisma, przetwarzanie strumieni wideo, ...
- Klasyfikacja sygnałów czasowych, wykrywanie wzorców w sekwencjach, predykcja (np. przewidywanie notowań giełdowych)

Modelowanie sekwencji



- sieci jednokierunkowe: wejście i wyjście o stałym rozmiarze
- generowanie sekwencji dla pojedynczego wejścia: opis obrazów
- sekwencyjne wejście: np. klasyfikacja tekstów
- wejście i wyjście sekwencyjne:
 - bez dopasowania ramek, np. tłumaczenie maszynowe
 - z dopasowaniem ramek (*alignment*), np: etykietowanie ramek

Modelowanie sekwencji


- Model sekwencji: inwariantność względem czasu, aktualny stan zależy od przeszłości
- MLP: dodanie **stałego kontekstu** do wejścia: np. 2 ramki z lewej i prawej (poprzednie i przyszłe wektory wejściowe).

$$[\mathbf{x}^{t-2}, \mathbf{x}^{t-1}, \mathbf{x}^t, \mathbf{x}^{t+1}, \mathbf{x}^{t+2}]$$


- CNN: splot względem wymiaru czasu, stały kontekst odpowiada wielkości efektywnego pola recepcyjnego. TDNN (*time-delay neural network*) model ze splotem 1D w domenie czasu.

Uczenie sekwencji z MLP i CNN

MLP




TDNN




Przykłady

Model akustyczny, rozpoznawanie fonemów z nagrań audio



Analiza sygnałów EEG, CNN + widma EEG




Nurse, E., Mashford, B. S., Yepes, A. J., Kiral-Kornek, I., Harrer, S., & Freestone, D. R. (2016). Decoding EEG and LFP Signals using Deep Learning: Heading TrueNorth


RNN

- **Sieci jednokierunkowe**
używają jedynie kontekstu o skończonej długości, nie są w stanie wykryć zależności w dłuższych okresach czasu (*long-term*)
- **Sieci rekurencyjne (RNN)**
posiadają połączenia do wcześniejszych warstw, wyjście w chwili t zależy od stanu z czasu $t - 1$

Sieć jednokierunkowa




Sieć rekurencyjna Elmana



Stan ukryty jednostek RNN

$$\mathbf{h}^t = f(\mathbf{h}^{t-1}, \mathbf{x}^t; \theta)$$


- neurony z połączeniami rekurencyjnymi działają jak pamięć - potencjalnie są w stanie modelować relacje występujące z dowolnie długim odstępem czasowym (nieskończony kontekst)



$$\mathbf{h}^t = g(\mathbf{x}^t, \mathbf{x}^{t-1}, \dots, \mathbf{x}^1)$$


- wektor $\mathbf{h}^t$ tworzy skompresowaną reprezentację sekwencji, mapuje dowolnie długą sekwencję na wektor o skończonej długości
- stan początkowy $\mathbf{h}^0$ może być interpretowany jako dodatkowy sygnał wejściowy, typowo inicjowany zerami

Rozwinięcie rekurencji w czasie




Efektywność kodowania

- Sieć RNN z rekurencją w warstwach ukrytych spełnia wymagania **uniwersalnej maszyny Turinga**
- Ilość parametrów opisujących stan **$\mathbf{h}$** ma wpływ na wielkość pamięci ale nie musi zależeć od długości sekwencji




pełny model sekwencji, ilość parametrów $O(k^T)$



RNN, stan obecny zależy pośrednio od stanów z przeszłości, ilość parametrów stała względem dł. sekwencji $O(1)$


Sieć z jedną warstwą rekurencyjną



$$o_k^t = \text{softmax} \left(\sum_r v_{kr} h_r^t + b_k \right)$$

$$h_i^t = \sigma \left(\sum_j u_{ij} x_j^t + \sum_r w_{ir} h_r^{t-1} + b_j \right)$$

Wsteczna propagacja w czasie




- Rozwinięta sieć odpowiada głębokiej sieci jednokierunkowej ze współdzielonymi wagami **W**, **V**, **U**
- Trening za pomocą wstecznej propagacji odbywa się analogicznie jak w jednokierunkowych sieciach:

BPTT backpropagation through time

Źródło grafiki: Goodfellow, Deep Learning, 2016

Wsteczna propagacja w czasie



Funkcja kosztu dla całej sekwencji:


$$L(\{\mathbf{x}^1, \mathbf{x}^2, \dots, \mathbf{x}^\tau\}, \{\mathbf{y}^1, \mathbf{y}^2, \dots, \mathbf{y}^\tau\}) = \frac{1}{\tau} \sum_t L^t$$

L^t – koszt w kroku t (np. cross-entropy) zależny od $\mathbf{x}^1, \dots, \mathbf{x}^t$

Źródło grafiki: Goodfellow, Deep Learning, 2016

Przykład: CharRNN

- model języka oparty na znakach (alfabet: h, e, l, o)
- RNN modeluje rozkład prawdopodobieństwa wystąpienia następnego znaku w sekwencji




👉 The Unreasonable Effectiveness of Recurrent Neural Networks

Wsteczna propagacja w czasie


- Rozwinięta w czasie sieć tworzy głęboką sieć neuronową ze wszystkimi tego konsekwencjami (zanikający gradient dla relacji odległych w czasie, rzadziej - wybuchający gradient)
- Obliczenia dla długich sekwencji są kosztowne
- **Truncated BPTT** - ograniczenie długości sekwencji do stałej wartości (np. 20)

Pojedyncze wyjście na końcu sekwencji




Sieć produkuje wyjście po obejrzeniu całej sekwencji, np. klasyfikacja wpisów w portalach społecznościowych pod względem emocji

Pojedyncze wejście generujące sekwencję



- Sieć produkuje sekwencję wyjść przy prezentacji stałego wzorca (np. etykietowanie zdjęć).
- Sygnał wejściowy pełni rolę kontekstu

Dwukierunkowa sieć RNN





Sieci dwukierunkowe RNN łączą warstwy z rekurencją zależną od sygnału przeszłego **h** z rekurencją zależną od przyszłego sygnału **g**

Schuster, Mike, and Kuldip K. Paliwal. "Bidirectional recurrent neural networks." Signal Processing, 1997

Dwukierunkowa sieć RNN

- informacja z przyszłości może zawierać istotną informację, np. dźwięki kolejnych fonemów (koartykulacja), znaczenie słów w zdaniu
- wyjścia sieci w dowolnym momencie zależą od całej sekwencji wejściowej
- zastosowanie: rozpoznawanie mowy (Graves, 2008, 2009), bioinformaryka (Baldi, 1999), rozpoznawanie pisma (Liwicki, Marcus, 2007)
- dla obrazów 2D możliwe zastosowanie sieci 4 kierunkowych, co pozwala modelować odległe relacje, jednak nie są one tak wydajne w tych zastosowaniach jak CNN

Model Encoder-Decoder



Sutskever et al (2014). "Sequence to Sequence Learning with Neural Networks", NIPS.


K Cho et al (2014). "Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation", EMNLP.

Model Encoder-Decoder

seq2seq (Sutskever, 2014) to dwie sieci RNN uczone jednocześnie:

- **enkoder** (reader, input) przetwarza sekwencję wejściową generując kontekst C
- **dekoder** (writer, output) zależnie od kontekstu C generuje sekwencję wyjściową
- wielkość kontekstu C może ograniczyć zdolność sieci do reprezentacji dalekich w czasie relacji
- dodanie uwagi (*attention model*, Bahdanan, 2015) - uwzględnienie w C więcej informacji z enkodera, które skalują wyjścia dekodera

Deep RNN




- warstwowe RNN - kolejne warstwy tworzą hierarchię reprezentacji (Graves, 2013)


Deep RNN

Problemy uczenia sieci RNN:

- znikający gradient dla odległych w czasie relacji (zanika wykładniczo z czasem), rozwiązaniem LSTM
- niestabilność uczenia - eksplodujący gradient, rozwiązanie: przycinanie gradientu i regularyzacja
- **gradient clipping** - ograniczenie wartości gradientu dla wszystkich wymiarów w mini-batchu, może zmienić kierunek spadku gradientu
- **norm clipping**: jeśli $\|g\| > v$ to $g \leftarrow \frac{gv}{\|g\|}$



Long Short-Term Memory



$$\begin{aligned}
 \mathbf{z}^t &= g(\mathbf{W}_z \mathbf{X}^t + \mathbf{R}_z \mathbf{y}^{t-1} + \mathbf{b}_z) \\
 \mathbf{i}^t &= \sigma(\mathbf{W}_i \mathbf{X}^t + \mathbf{R}_i \mathbf{y}^{t-1} + \mathbf{p}_i \odot \mathbf{c}^{t-1} + \mathbf{b}_i) \\
 \mathbf{f}^t &= \sigma(\mathbf{W}_f \mathbf{X}^t + \mathbf{R}_f \mathbf{y}^{t-1} + \mathbf{p}_f \odot \mathbf{c}^{t-1} + \mathbf{b}_f) \\
 \mathbf{c}^t &= \mathbf{i}^t \odot \mathbf{z}^t + \mathbf{f}^t \odot \mathbf{c}^{t-1} \\
 \mathbf{o}^t &= \sigma(\mathbf{W}_o \mathbf{X}^t + \mathbf{R}_o \mathbf{y}^{t-1} + \mathbf{p}_o \odot \mathbf{c}^t + \mathbf{b}_o) \\
 \mathbf{y}^t &= \mathbf{o}^t \odot h(\mathbf{c}^t)
 \end{aligned}$$

Sepp Hochreiter, Jürgen Schmidhuber, "Long short-term memory", 1997

LSTM


- LSTM niweluje wpływ zanikania gradientu, dzięki czemu pozwala mapować odległe w czasie relacje
- Wprowadza dodatkową wewnętrzną jednostkę stanu $\mathbf{c}$
- Stan $\mathbf{c}^t$ zależy w sposób liniowy od stanu poprzedniego $\mathbf{c}^{t-1}$ (liniowa rekurencja), więc nawet przy bardzo długich rekurencjach gradient ma szansę nie zaniknąć (*long-term memory*)
- Bramki wejściowa, wyjściowa i bramka zapominania sterują zapamiętywanymi informacjami, zależą od sygnału wejściowego i stanu poprzedniego
- Funkcja różniczkowalna - można uczyć metodami spadku gradientu i wsteczną propagacją

LSTM

- Bramka wejściowa ma wpływ na to jaki sygnał zostanie zapisany w jednostce stanu $\mathbf{c}$
- Bramka zapominania (*forget gate*) steruje wpływem poprzedniego stanu $\mathbf{c}^{t-1}$ na obecny stan $\mathbf{c}^t$
- bramka wejściowa i zapominania wpływają na to co umieszczane jest i co jest usuwane ze stanu
- Bramka wyjściowa - steruje ilością informacji przepływającą ze stanu wewnętrznego do wyjścia jednostki, pozwala np. zachować na później informacje, które w tym momencie nie są istotne

Gated Recurrent Unit

- GRU (Kyunghyun Cho et al., 2014) brak jednooki wewnętrznej **c** i bramki wyjściowej
- bramka resetu R_t i bramka aktualizacji Z_t
- mniej parametrów wzgl. LSTM, porównywalna jakość wyników dla wielu problemów



$$z_t = \sigma_g(W_z x_t + U_z h_{t-1} + b_z)$$

$$r_t = \sigma_g(W_r x_t + U_r h_{t-1} + b_r)$$

$$h_t = (1 - z_t) \circ h_{t-1} + z_t \circ \sigma_h(W_h x_t + U_h (r_t \circ h_{t-1}) + b_h)$$

Źródło: https://en.wikipedia.org/wiki/Recurrent_neural_network

Connectionist Temporal Classification

- metoda treningu sekwencji, gdy nie ma dostępnego dopasowania ramek (*alignment*), długość sekwencji wejściowej jest dłuższa od sekwencji wyjściowej, np. transkrypcja tekstu na podstawie nagrań audio
- wyjście softmax uzupełnione o dodatkową etykietę 'blank' $\mathcal{L}' = \mathcal{L} \cup \{blank\}$ generuje rozkład prawdopodobieństw zaobserwowania sekwencji etykiet (ścieżki) $\mathbf{y}'$ o długości T

$$P(\mathbf{y}'|\mathbf{x}) = \prod_{t=1}^T P(y'_t|\mathbf{x})$$

Connectionist Temporal Classification

- CTC poszukuje sekwencji etykiet o największej wiarygodności $P(\mathbf{y}|\mathbf{x})$ marginalizując po wszystkich możliwych ścieżkach $\mathbf{y}'$ z blankiem

$$p(\mathbf{y}|\mathbf{x}) = \sum_{\mathbf{y}' \in \mathcal{M}^{-1}(\mathbf{y})} P(\mathbf{y}'|\mathbf{x})$$

gdzie $\mathcal{M}$ mapuje sekwencję etykiet o długości T do sekwencji krótszej poprzez usunięcie wszystkich blanków i powtarzających się etykiet


$$\mathcal{M}(a - ab -) = \mathcal{M}(-aa - -abb) = aab$$

- funkcja kosztu

$$L = - \sum \log P(\mathbf{y}|\mathbf{x})$$


Graves, A., Fernández, S., Gomez, F., Schmidhuber, J., Connectionist temporal classification: labelling unsegmented sequence data with recurrent neural networks. 2006.

Predyckj CTC




- CTC generuje sekwencję pików etykiet (fonemów) przedzielonych etykietą 'blank'
- w sieci z kosztem CE przesunięcie granic fonemu względem poprawnego dopasowania owocuje błędem nawet gdy fonem jest poprawnie przewidziany
- wyjście CTC może być wykorzystane bezpośrednio (bez konieczności dalszego przetwarzania) do transkrypcji

Automatyczne rozpoznawanie mowy



Źródło grafiki: <https://www.esat.kuleuven.be/psi/spraak/theses/08-09-en/MDT.php>


Głęboki model akustyczny



- input: MFCC + context
- output: phonemes or CD states
- node type: LSTM

Sak, Haşim, et al. "Fast and accurate recurrent neural network acoustic models for speech recognition." arXiv preprint arXiv:1507.06947 (2015).

Deep Speech 2



Read Speech			
Test set	DS1	DS2	Human
WSJ eval'92	4.94	3.60	5.03
WSJ eval'93	6.94	4.98	8.08
LibriSpeech test-clean	7.89	5.33	5.83
LibriSpeech test-other	21.74	13.25	12.69

Amodei, Dario, et al. "Deep speech 2: End-to-end speech recognition in english and mandarin."(2015).

Analiza sygnałów EEG

„Film” EEG - sekwencja obrazów spektralnych: CNN + LSTM




Figure 2: Overview of our approach: (1) EEG time series from multiple locations are acquired; (2) spectral power within three prominent frequency bands is extracted for each location and used to form topographical maps for each time frame (image); (3) sequence of topographical maps are combined to form a sequence of 3-channel images which are fed into a recurrent-convolutional network for representation learning and classification.

Bashivan, P., Rish, I., Yeasin, M., & Codella, N. (2015). Learning Representations from EEG with Deep Recurrent-Convolutional Neural Networks.

Analiza sygnałów EEG

- dane zachowują relacje przestrzenne, czasowe i widmo mocy EEG
- sieci CNN wydobywają inf. przestrzenne (położenie elektrod) i widmo (kanały)
- sieć RNN - relacje czasowe pomiędzy ramkami
- klasyfikacja pojemności pamięci roboczej (4 klasy): błąd SVN 15.3% → CNN+LSTM 8.9%

Gromadzenie informacji czasowej





Figure 3: Different multi-frame architectures; the notation here is as follow. C: 7-layer ConvNet; max: maxpool layer across time frame features; FC: fully-connected layer; SM: softmax layer; Conv: 1-D convolution layer across time frames; L: LSTM layer.

Bashivan, P., Rish, I., Yeasin, M., Codella, N. (2015). Learning Representations from EEG with Deep Recurrent-Convolutional Neural Networks.

NeuralTalk - generator opisów zdjęć



Multimodal Recurrent Neural Network 🖱️ NeuralTalk2

Karpathy A., Fei-Fei L. „Deep Visual-Semantic Alignments for Generating Image Descriptions”, 2015