

O que significam esses 5.599.881 parâmetros?

Estevan Barbará

RNN-Folk

- Rede Neural para geração de músicas “folk”, utilizando Redes de longa memória de curta duração (LSTM)
 - Proposta por (STURM et al, 2016)
 - Disponível em <https://github.com/IraKorshunova/folk-rnn>
 - Implementação acessível em <https://folkrnn.org/>



X:1

T:Notes

M:C

L:1/4

K:C

C, D, E, F, | G, A, B, C | D E F G | A B c d | e
f g a | b c' d' e' | f' g' a' b' |]

Notes



RNN-Folk – entradas e saídas

- Músicas em notação ABC
 - Descrita em <http://abcnotation.com/>
 - Padrão para diversos usos de música, particularmente o estilo “folk”
 - Composta por duas partes:
 - Cabeçalho de cinco linhas, contendo Id (X), Título (T), Compositor (C), Métrica (M), Duração padrão (L) e Tom (K). Cabe observar que apenas X, T e K são realmente obrigatórios, sendo o M padrão o compasso 4/4 e o L padrão a colcheia (1/8 de tempo).
 - Notas, em representação por letra
 - Letras maiúsculas (C B A) representam a oitava de baixo (logo abaixo da marcação numa clave de Sol)
 - Letras minúsculas (g f c) representam a oitava de cima
 - Uma vírgula após a nota indica que ela está uma oitava abaixo
 - Um apóstrofo indica uma oitava acima

X:1

T:Note lengths and default note length

M:C

K:C

L:1/16

A/2 A/ A A2 A3 A4 A6 A7 A8 A12 A15 A16|]

L:1/8

A/4 A/2 A/ A A2 A3 A4 A6 A7 A8 A12 A15|]

L:1/4

A/8 A/4 A/2 A/ A A2 A3 A4 A6 A7|]

Note lengths and default note length



RNN-Folk – entradas e saídas

- Os tempos são dados por uma numeração multiplicativa após a nota:
 - No exemplo, a primeira linha tem como padrão a semicolcheia (1/16). As notas da linha possuem os tempos:
 - Fusa (1/32 ou semicolcheia/2)
 - Fusa (a barra de divisão sozinha pode ser tratada como /2)
 - Semicolcheia (1/16)
 - Colcheia (1/8 ou semicolcheia x 2)
 - Colcheia + meio-tempo (3/16 ou semicolcheia * 3)
 - Semínima (1/4 ou semicolcheia * 4)
 - Semínima + Colcheia (3/8 ou semicolcheia * 6)
 - Semínima + Colcheia + Semicolcheia (7/16 ou semicolcheia * 7)
 - Mínima (1/2 ou semicolcheia * 8)
 - Mínima + Semínima (3/4 ou semicolcheia * 12)
 - Mínima + Semínima + Colcheia + Semicolcheia (15/16 ou semicolcheia * 15)
 - Semibreve (1 ou semicolcheia * 16)

RNN-Folk – composição gerada

- Partindo de uma rede treinada com o dataset obtido em <http://thesession.org>
 - A figura de cima representa uma composição gerada pelo RNN-Folk
 - A figura de baixo representa a composição Páidín Ó Raifeartaigh (também repetida na música The Quaker's Wife).
 - Considerada a composição de treinamento mais similar à composição gerada



RNN-Folk – composição gerada

- O resultado apresenta uma forma folk padrão
 - Forma AABB
 - 8 tempos em cada compasso
 - Ambas as partes começam e terminam em notas tônicas, apresentam forte repetição e variação de uma melodia base
- No entanto, a composição não possui equivalente no dataset.
 - *De onde vieram as diferenças? Onde na rede estão codificadas as variações de tom, métrica, altura e duração das notas?*



RNN-Folk – Arquitetura da rede ➤

- A rede RNN-folk é composta por um layer de entrada, três layers LSTM intermediários e um SOFTMAX de saída
 - Os layers de entrada e de saída correspondem a um vetor binário de 137 dimensões, representando:
 - transcription (2);
 - meter (7);
 - mode (4);
 - measure (5);
 - pitch (85);
 - grouping (9);
 - and duration (25).

RNN-Folk – Arquitetura da rede

- Layers internos:
 - Cada layer interno é composto por 512 Neurônios LSTM, cada um carregando a seguinte notação:
 - I_t : saída dos *input gates*
 - F_t : saída dos *forget gates*
 - O_t : saída dos *output gates*
 - C_t : saída dos *cell gates*
 - H_t : estado oculto do layer
 - B_i, B_f, B_o, B_c : Viéses associados aos *gates*
 - $W_{xi}, W_{xf}, W_{xo}, W_{xc}$: peso associado à entrada e aos *gates*
 - $W_{hi}, W_{hf}, W_{ho}, W_{hc}$: peso associado ao estado oculto e aos *gates*

$$i_t^{(i)} \leftarrow g(W_{xi}^{(i)} y_t^{(i)} + W_{hi}^{(i)} h_{t-1}^{(i)} + b_i^{(i)}) \quad (1)$$

$$f_t^{(i)} \leftarrow g(W_{xf}^{(i)} y_t^{(i)} + W_{hf}^{(i)} h_{t-1}^{(i)} + b_f^{(i)}) \quad (2)$$

$$o_t^{(i)} \leftarrow g(W_{xo}^{(i)} y_t^{(i)} + W_{ho}^{(i)} h_{t-1}^{(i)} + b_o^{(i)}) \quad (3)$$

$$\begin{aligned} c_t^{(i)} \leftarrow & \tanh(W_{xc}^{(i)} y_t^{(i)} + W_{hc}^{(i)} h_{t-1}^{(i)} + b_c^{(i)}) \odot i_t^{(i)} \\ & + f_t^{(i)} \odot c_{t-1}^{(i)} \end{aligned} \quad (4)$$

$$h_t^{(i)} \leftarrow \tanh(c_t^{(i)}) \odot o_t^{(i)}. \quad (5)$$

RNN-Folk – arquitetura interna


- O layer de saída (SOFTMAX) implementa a função mostrada
 - T representa uma *temperatura de amostragem*, dada pelo usuário ao rodar a rede
- No total teremos 5.599.881 parâmetros numéricos

$$\mathbf{p}_t = \text{softmax} \left(\frac{1}{T_s} \left[\mathbf{W}_s \mathbf{h}_t^{(3)} + \mathbf{b}_s \right] \right) \quad (6)$$

RNN-Folk - treinamento


- O treinamento da rede busca minimizar a função de custo mostrada ao lado, que indica quão bem um modelo descreve o dataset.
- A figura mostra o decaimento da função de custo após 100 épocas de treinamento.

$$L(s) := -\frac{1}{|s|} \sum_{t=1}^{|s|} \log[\mathbf{p}_t]_{s(t)}$$




Análise do layer SOFTMAX

- O estado oculto do 3º layer de LSTM é a entrada do SOFTMAX
 - Os gráficos mostram a amplitude de valores do LSTM contra as saídas de SOFTMAX




Análise do layer SOFTMAX

- Linha 1: parâmetros W_s (cinza) e b_s (preto) contra o vetor de saída
 - Bias baixos relativos aos tokens <s>; =f'; 16; (7; ^f'; =C..
 - <s> é o token de entrada – aparece em todos os casos, possuindo semântica quase nula.
 - Os outros raramente são gerados pela rede, e quase não aparecem nos dados de treinamento.




Análise do layer SOFTMAX

- Linha 2: W_s relativos às linhas 34, 203 e 497 do L3
 - Linha 497 tende a aumentar a probabilidade dos tokens =B,; _C e _c; e reduzir a probabilidade dos tokens _A e ^g (ou vice-versa)
 - Notas iguais sendo tratadas de forma similar
 - As outras linhas também apresentam probabilidades de tokens similares, mas demonstram ser opostas em polaridade
 - Diversas outras instâncias de pesos em L3 sugerem que suas colunas funcionam como grupos direcionadores do SOFTMAX
 - Baseado nisso, executou-se uma decomposição em valores singulares do vetor W_s




Decomposição de W_s em valores singulares

- Os maiores valores singulares respondem pela maior variância nos resultados
- Particularmente, o principal valor responde por 7,5 vezes mais variância que qualquer outro valor




Análise do layer SOFTMAX – valores singulares

- Linha 3: W_s relativos aos 5 maiores valores singulares
 - O principal valor responde igualmente em todos os tokens, aumentando a probabilidade onde seu valor absoluto é maior e atenuando onde é menor
 - O segundo valor aumenta a probabilidade dos quatro modais e reduz dos tokens de três oitavas
 - O terceiro aumenta de diversos tokens de tempo e alguns multiplicadores (como 2, ou $/2$) e reduz a mesmas três oitavas do anterior
 - O quarto aumenta de alguns tokens de tons graves
 - O quinto aumenta fortemente os tokens de compasso, e atenua alguns de duração.



Sequências de estados ocultos em L3

- Distribuição esparsa
- Alguns ativam na entrada de cada token de compasso, outros a cada 6 ou 7 passos (a duração mais comum de compasso), outros logo antes de um token de repetição de compasso
- Projetados sobre os 30 maiores valores singulares de W_s a



Redução do espaço vetorial de W_s

- Ao truncar a soma na decomposição de valores singulares, foi reduzido o espaço vetorial para os 30 pares de vetores singulares de maior valor
- O compasso se mantém, bem como a estrutura AABB, e o início e fim em notas tônicas, mas uma maior variação no tema é introduzida




Redução do espaço vetorial de W_s

- Ao contrário, ao reduzir o espaço em 1 e alterar o SOFTMAX para $W_s \leftarrow W_s - \sigma_5 u_5 v_5^T$, a melodia perde o sentido.
- Aparentemente o componente de "direção" da melodia é severamente dependente dos tokens de compasso
- Os comportamentos internos de cada parte da melodia não parecem ser muito afetados por essa "lobotomia"



Teste da hipótese anterior




- Para testar essa hipótese, a amostragem de SOFTMAX é alterada para excluir o token |
 - O resultado é uma melodia de compasso similar à original, porém sem direcionamento.



Teste da hipótese anterior

- Ao remover todos os tokens de compasso, o resultado perde mais características, embora mantenha parte da estrutura
- O gráfico mostra que diferente do teste anterior, quase não há tentativas de encerrar o compasso.



Deslocamento do SOFTMAX

- A partir disso, podemos generalizar o softmax de modo a criar uma expressão em que possamos avaliar a partir de cada token de saída

Bibliografia

- Sturm, B. L. What do these 5,599,881 parameters mean?: An analysis of a specific LSTM music transcription model, starting with the 70,281 parameters of its softmax layer. *International Conference on Computational Creativity*. 2018. Disponível em <http://www.diva-portal.org/smash/get/diva2:1260836/FULLTEXT01.pdf>
- Sturm, B. L.; Santos, J. F.; Ben-Tal, O.; and Korshunova, I. Music transcription modelling and composition using deep learning. *1st Conference on Computer Simulation of Musical Creativity*. 2016. Disponível em <https://arxiv.org/pdf/1604.08723.pdf>