

Numéros / n° 7-8 - Culture du code

« Exploration de dépendances structurelles mélodiques par réseaux de neurones récurrents »

Nathan Libermann

Résumé

Dans le cadre de la génération automatique de mélodie structurée, nous explorons la question des dépendances entre les notes d'une mélodie en utilisant des outils d'apprentissage profond. Plus précisément, nous utilisons le modèle d'apprentissage séquentiel GRU, que nous déclinons dans différents scénarios d'apprentissage afin de mieux comprendre les architectures optimales dans ce contexte. Nous souhaitons par ce moyen explorer différentes hypothèses relatives à la non-invariance temporelle des dépendances entre les notes au sein d'un segment structurel (motif, phrase, section). Nous définissons trois types d'architectures récurrentes correspondant à différents schémas d'exploitation de l'historique musical dont nous étudions les capacités d'encodage et de généralisation. Ces expériences sont conduites sur la base de données Lakh MIDI Dataset et plus particulièrement sur un sous-ensemble de 8 308 segments mélodiques monophoniques composés de 16 mesures. Les résultats indiquent une distribution non-uniforme des capacités de modélisation et de prédiction des réseaux récurrents testés, suggérant l'utilité d'un modèle non-ergodique pour la génération de segments mélodiques.

Introduction

La génération automatique de mélodie est une problématique régulièrement abordée en informatique musicale, mais qui reste incomplètement résolue. Récemment revenues au premier plan, les méthodes par réseaux de neurones apparaissent potentiellement capables de modéliser des mécanismes de génération de mélodie par apprentissage à partir d'exemples.

En 2001, Chun-Chi Chen et Risto Miikkulainen furent parmi les premiers auteurs à publier sur ce sujet. L'un des principaux problèmes qu'ils relevèrent est le manque de structure globale dans les mélodies générées. D'autres auteurs, comme Judy Franklin (2005), Douglas Eck et Jürgen Schmidhuber (2002), ont alors cherché à résoudre ce problème en utilisant des réseaux récurrents *long short-term memory*, ou LSTM (Hochreiter et Schmidhuber, 1997), sur un corpus de musique blues ou jazz. Ces travaux ont permis d'améliorer la qualité perçue de la musique générée mais les résultats continuent à présenter une insuffisance de structure. Nicolas Boulanger-Lewandowski, Yoshua Bengio et Pascal Vincent (2012) ont tenté de combiner le modèle LSTM avec des modèles génératifs, notamment le *restricted Boltzmann machines*, ou RBM (Chen et Miikkulainen, 2001). Dans leur ouvrage de 2016, Allen Huang et Raymond Wu s'intéressent à la représentation des notes dans un espace vectoriel (*embedding*). Natasha Jaques, Shixiang Gu, Richard Turner et Douglas Eck proposent, la même année, de restreindre un modèle LSTM préalablement appris grâce à l'apprentissage par renforcement de règles de musicologie prédéfinies. L'équipe Magenta ⁽¹⁾, quant à elle, propose un modèle d'attention inspiré du travail de Dzmitry Bahdanau, Cho Kyunghyun et Bengio Yoshua (2016). À notre connaissance, il n'existe pas aujourd'hui de modèle capable d'apprendre à générer des mélodies présentant une structure pleinement satisfaisante à l'échelle de plusieurs mesures consécutives.

Le travail présenté dans cet article est une étude exploratoire qui s'inscrit dans le cadre de la génération automatique de mélodie structurée et qui fait appel à des outils d'apprentissage profond. Nous considérons plus particulièrement le modèle séquentiel GRU (*gated recurrent units* ; Cho *et al.*, 2014), que nous étudions dans différents scénarios d'apprentissage, afin de mieux comprendre les potentialités

de cette approche pour la modélisation de mélodies. Nous souhaitons notamment cerner l'importance d'une hypothèse de non-ergodicité (non-invariance dans le temps) de la structure musicale, en mettant en évidence les limites des architectures récurrentes basées sur des GRU et en étudiant les possibilités de les adapter à la génération de motifs mélodiques. On suppose en effet qu'il existe une planification dans la construction d'un segment mélodique qui ne se contente pas de se référer aux k précédents éléments pour construire le suivant. Au contraire, nous faisons l'hypothèse qu'un segment mélodique forme un tout et que, au fil de ce dernier, les divers éléments se conditionnent de façon non-adjacente pour former le schéma mélodique global.

Ainsi, dans l'esprit des travaux récents sur les modèles tensoriels/polytopiques de segments musicaux (Guichaoua, 2017 ; Louboutin et Bimbot, 2016), nous émettons l'hypothèse que, dans le cadre de mélodies simples constituées de motifs présentant des relations d'analogie, les dépendances structurelles dans la musique ne suivent pas un procédé purement séquentiel, mais plutôt des dépendances multi-échelles. Selon cette approche, un élément musical dépend de façon privilégiée des autres éléments qui se situent dans des positions métriques homologues dans le segment, plutôt que dans le voisinage immédiat. Autrement dit, les positions métriques des notes jouent un rôle dans la construction structurelle de la musique et les architectures neuronales doivent en tenir compte.

Nous définissons donc trois modèles récurrents basés sur des GRU : un modèle à historique glissant, qui correspond à une façon « standard » de construire et d'entraîner un modèle récurrent, un modèle à historique croissant, qui correspond à une façon « dynamique » d'apprendre un modèle récurrent et enfin un modèle à historique parallèle, avec des poids distincts selon les positions à prédire.

La comparaison des différents schémas d'apprentissage proposés selon leur capacité d'encodage de l'information musicale et de leur performance de prédiction permet d'étudier la pertinence et les limites de l'hypothèse de non-ergodicité dans les séquences mélodiques.

1. Protocole expérimental

1.1. Cellule de mémoire GRU et couche de prédiction

Pour définir les architectures étudiées, nous utilisons comme unité de base le réseau de neurones récurrent GRU (voir Figure 1) qui fonctionne comme suit : à chaque instant t , la cellule GRU reçoit en entrée, sous forme de vecteurs, l'observation courante x_t et une variable interne h_{t-1} qui tient lieu de mémoire des observations précédentes. À partir de ces deux entrées, la cellule GRU produit une remise à jour de h , laquelle est ensuite utilisée dans une cellule GRU semblable, qui prend h_t et l'observation x_{t+1} en entrée et ainsi de suite.

Dans nos expériences, x_t est un vecteur binaire de dimensions $n = 88$ correspondant à un ensemble discret de notes, chaque dimension représentant une note. Ce vecteur n'a qu'un seul symbole 1 (*one-hot*).

La cellule GRU se décompose en six sous-ensembles de poids de *propagation d'historique* ($U_h, U_r, U_z, W_h, W_r, W_z$) qui se combinent avec les entrées h_{t-1} et x_t pour former h_t selon les équations suivantes :

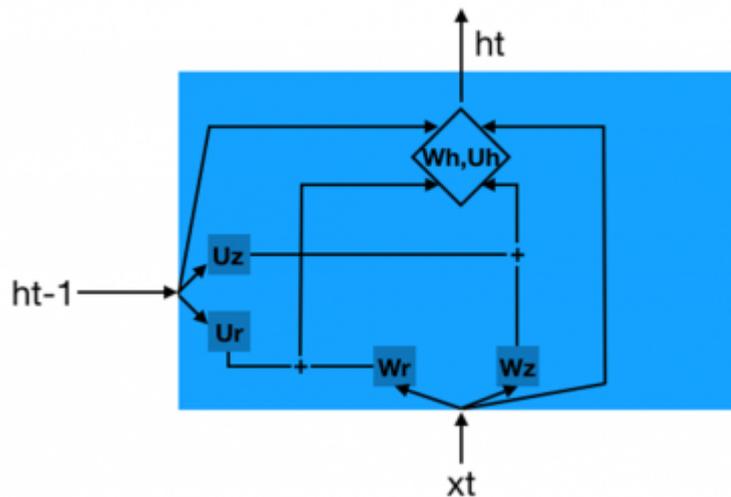
$$z_t = \sigma_g(W_z x_t + U_z h_{t-1} + b_z)$$

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

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

Où \circ désigne le produit matriciel de Hadamard, σ_g une fonction sigmoïde et σ_h une tangente hyperbolique.

Figure 1. *Gated recurrent units*



Source : Nathan Libermann, 2018

Nous avons aussi besoin, pour définir nos architectures, d'une couche de prédiction qui, à partir d'une mémoire h_t , fournit une distribution de probabilités $_x_{t+1}$ de la note suivante x_{t+1} . Pour ce faire, nous utilisons une couche entièrement connectée entre h_t et $_x_{t+1}$, constituée d'une matrice de poids de prédiction W_p et d'un vecteur de biais b_p , ce qui fournit en sortie une distribution de probabilité *a posteriori* sur l'ensemble des notes :

$$_x_{t+1} = W_p h_t + b_p$$

L'apprentissage est réalisé par rétropropagation du gradient à travers le temps (Werbos, 1990).

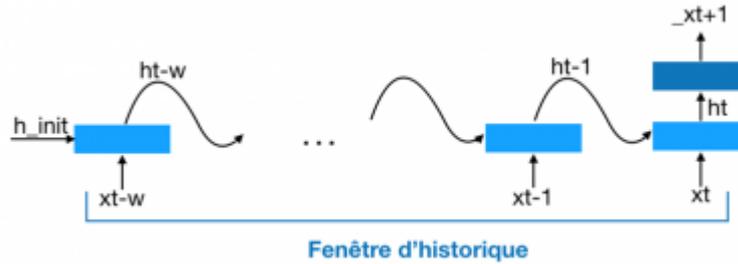
1.2. Spécification des architectures

Dans cette étude, nous considérons des segments mélodiques correspondant à des unités structurales de type phrase ou section musicale. Dans cette optique, nous modélisons des séquences de $N = 64$ notes, obtenues en échantillonnant des mélodies qui s'étendent sur 16 mesures.

Trois architectures basées sur des GRUs sont étudiées :

- L'architecture à *historique glissant* correspond à une façon standard de construire un réseau récurrent. On choisit une fenêtre d'historique de taille fixe k . Pour prédire la note $_x_{t+1}$, on alimente la couche de prédiction W_p avec l'historique h_t , qui, dans ce cas, est initialisé aléatoirement puis propagé depuis h_{t-k} jusqu'à h_t (voir Figure 2). La fenêtre d'historique $[t - k, t]$ étant fixe, on ne peut calculer les prédictions $_x_{t+1}$ qu'à partir de l'instant $k + 1$. Les poids des couches de propagation d'historique sont partagés (c'est-à-dire indépendants de t) et il en est de même des poids des couches de prédiction. Ainsi, cette architecture repose sur une hypothèse d'invariance dans le temps des éléments musicaux.

Figure 2. Architecture à historique glissant



Source : Nathan Libermann, 2018

- L'architecture à *historique croissant* correspond à une façon plus dynamique de construire un modèle récurrent. Ici, on procède de la même façon que pour l'architecture du modèle à historique glissant, mais on considère une fenêtre d'historique qui couvre l'intégralité de l'intervalle $[1, t]$ et qui, par conséquent, croît au fur et à mesure que l'on progresse dans le temps (voir Figure 3). Comme dans l'architecture précédente, les poids de la couche de propagation d'historique sont communs pour les différentes positions de notes à prédire et il en est de même pour les poids de la couche de prédiction. Dans cette variante, néanmoins, il devient possible de prédire les notes dans toutes les positions temporelles, à partir d'un historique qui va croissant. On note toutefois que cette architecture repose aussi sur une hypothèse d'invariance dans le temps, du fait du partage des poids.

Figure 3. Architecture à historique croissant



Source : Nathan Libermann, 2018

- Enfin, l'architecture à *historique parallèle* repose sur le même principe que l'architecture à historique croissant, à ceci près que les poids des couches de propagation et de prédiction sont indépendants pour chaque position à prédire $_{xt+1}$. On peut ainsi voir cette configuration comme $N - 1$ réseaux à historique croissant, indépendants les uns des autres et correspondant à chaque position à prédire $_{xt+1}$. L'indépendance de ces réseaux en fonction de la position est censée permettre à cette architecture de prendre en compte la non-invariance dans le temps et de tenir compte, si nécessaire, de dépendances complexes.

1.3. Données

Pour ce travail d'exploration, nous utilisons les données du Lakh MIDI Dataset (Raffel, 2016), qui contient 176 581 fichiers MIDI multipistes sans appréciation de genres. Étant donné que nous nous intéressons uniquement aux pistes mélodiques monophoniques, nous en avons sélectionné environ 70 000 qui possédaient cette propriété dans le corpus original. De ce sous-ensemble, nous avons extrait 8 308 blocs structurels de 16 mesures sous forme de fichier MIDI. Ne disposant pas de segmentation automatique assez fiable, nous sélectionnons uniquement les 16 premières mesures de mélodies monophoniques de type 4/4.

Afin de permettre au modèle de pouvoir mieux extraire les relations relatives entre les notes, nous avons représenté ces mélodies en référence à la première note de la séquence (arbitrairement fixée à *do*), de

sorte à être indépendant de la tonalité initiale. Nous obtenons donc 8 308 séquences mélodiques de 16 mesures.

Pour simplifier la représentation traitée, on considère dans un premier temps une discrétisation de l'information mélodique dans ces segments. Nous avons procédé à un découpage des mesures en quatre portions égales et relevé à chaque fois la note active sur ces positions. Si un silence apparaît sur l'un des temps considérés, nous prolongeons la valeur de la note précédente, ce qui évite d'avoir à gérer des absences de notes.

Le résultat de ce processus de réduction conduit à des séquences « mélodiques » de 16 mesures correspondant toutes à des successions de 64 notes. Chaque note est représentée par un vecteur de dimension 88 (correspondant aux 88 notes d'un clavier de piano). Lorsqu'une note est active, la dimension associée à cette note dans le vecteur est mise à 1 et toutes les autres à 0.

1.4. Protocole

Le corpus composé de 8 308 séquences est divisé en deux groupes *A* et *B* comprenant chacun 4 154 séquences. Nous définissons quatre scénarios pour chaque architecture (voir Table 1) :

- Apprentissage sur le groupe *A*, test sur le groupe *A*
- Apprentissage sur le groupe *A*, test sur le groupe *B*
- Apprentissage sur le groupe *B*, test sur le groupe *A*
- Apprentissage sur le groupe *B*, test sur le groupe *B*

Table 1. Protocoles d'apprentissage et de test pour mesurer les capacités de compression et de généralisation des architectures

Train	Test	Test
A	A	B
B	B	A

Source : Nathan Libermann, 2018

Lors du test, nous relevons pour chaque position de note l'erreur moyenne sur l'ensemble des exemples de test, ceci dans le cadre des trois architectures décrites dans la section 1.2.

Les mesures effectuées en utilisant le même ensemble de test que celui utilisé pour l'apprentissage permettent de caractériser les capacités de *compression* de l'information mélodique par les différentes architectures, en fonction de la position de la note dans le segment musical. Celles qui croisent les ensembles d'apprentissage et de test rendent compte de la capacité de *généralisation* des architectures à des données nouvelles.

1.5. Critère d'évaluation

Pour chaque instant t , nous calculons l'erreur entre le vecteur de sortie $_x_t$ et la note réelle x_t par la fonction d'erreur quadratique moyenne (*mean squared error*, ou MSE). On rappelle que $_x$ est un vecteur de dimension $n = 88$ correspondant à une distribution de probabilités et x un vecteur *one-hot* de même dimension, correspondant à la note effectivement active.

$$MSE = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2$$

C'est l'évolution de cette erreur que nous examinons pour chaque position de note et dans chaque scénario, afin d'observer la façon dont les différentes architectures encodent les dépendances structurelles. Nous analysons à la fois les motifs engendrés par la variation de l'erreur moyenne entre les différentes positions et le critère de compression/prédiction.

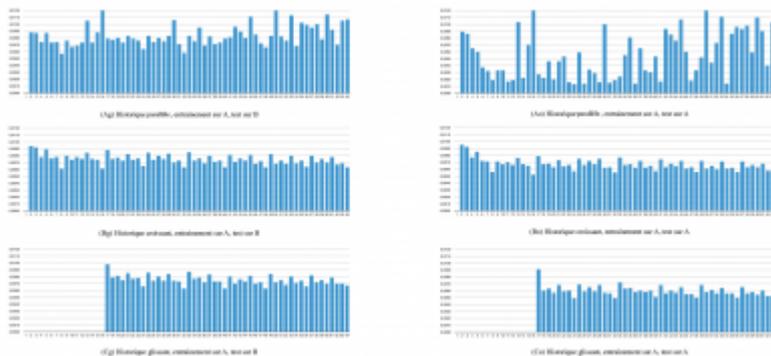
1.6. Détails complémentaires de mise en œuvre

Pour ces expériences, nous utilisons la bibliothèque d'apprentissage profond Pytorch (2). L'historique est un vecteur de dimension 100. Chaque exemple est présenté 40 fois au cours de l'apprentissage (40 epochs). L'optimiseur utilisé est Adagrad.

2. Résultats

Les figures 4 et 5 illustrent les résultats du protocole expérimental décrit dans la section précédente. La figure 4 correspond aux différentes architectures apprises à partir du corpus A et la figure 5 aux architectures apprises sur le corpus B.

Figure 4. Erreur de prédiction moyenne pour chaque position pour le corpus A



Source : Nathan Libermann, 2018

Figure 5. Erreur de prédiction moyenne pour chaque position pour le corpus B



Source : Nathan Libermann, 2018

Pour chacune de ces figures, les résultats de généralisation des architectures sont représentés sur les graphiques A_g , B_g , C_g et les résultats de compression sur les graphiques A_o , B_o et C_o :

- graphique A : architecture à historique parallèle ;
- graphique B : architecture à historique croissant ;
- graphique C : architecture à historique glissant.

En premier lieu, on constate une similarité de comportement entre courbes homologues sur la figure 4 et la figure 5. Cela permet de penser que les tendances observées sont relativement peu influencées par les spécificités des deux demi-corpus.

On remarque ensuite que pour les architectures à historique glissant et croissant, les valeurs des capacités de généralisation (B_g et C_g) présentent un niveau d'erreur à peine plus élevé que les valeurs des capacités de compression (B_o et C_o). À l'inverse, les capacités de compression et de généralisation de l'architecture parallèle se comportent très différemment l'une de l'autre. En effet, l'architecture parallèle possède beaucoup plus de paramètres libres, ce qui crée une capacité bien plus forte du réseau à comprimer les données d'apprentissage, mais entraîne un phénomène d'*over-fitting* (surapprentissage) qui altère la capacité de généralisation sur de nouvelles données. Ce phénomène est bien moins saillant sur les deux autres architectures.

Un examen plus précis des motifs observés sur les courbes d'erreur apporte également des observations intéressantes.

Les courbes pour les historiques glissant et croissant présentent une pseudo-périodicité marquée à l'échelle de huit notes et des oscillations secondaires aux échelles 4 et 2, suggérant fortement une « synchronisation » des capacités de modélisation des architectures correspondantes sur des cycles de deux mesures.

Les courbes A_o (que ce soit pour la figure 4 ou la figure 5) présentent pour leur part un comportement plus contrasté : on remarque tout d'abord une décroissance très nette sur le premier quart du segment, puis des variations plus erratiques sur la partie centrale (2^e et 3^e quart) et enfin une remontée globale de l'erreur sur le dernier quart. On peut opérer un rapprochement entre ces observations expérimentales et différentes considérations musicologiques sur la structure des segments musicaux, notamment que l'on constate souvent la réalisation de formules musicales conventionnelles en fin de segment. Ces dernières sont donc finalement moins prédictibles en fonction du contexte, puisqu'elles sont plus ou moins prédéterminées d'avance indépendamment de celui-ci.

Par ailleurs, selon le modèle cognitif d'Implication-Réalisation d'Eugene Narmour (1990) et son extension récente par Frédéric Bimbot, Emmanuel Deruty, Gabriel Sargent et Emmanuel Vincent (2016), les fins de segments structurels constituent fréquemment des dénis d'implication par rapport aux progressions musicales établies dans les portions antérieures, ce qui peut également constituer une hypothèse expliquant le comportement observé sur les courbes A_o . Toutefois, ce comportement étant moins net sur les courbes A_g , des expériences complémentaires sont requises pour mieux asseoir ces hypothèses.

Conclusions

Dans ce travail d'exploration, nous avons considéré trois architectures de réseaux de neurones récurrents et nous avons analysé leur comportement en termes d'erreur de modélisation de schémas mélodiques simplifiés.

Ces expériences nous ont permis d'observer que la prise en compte de la non-invariance dans le temps de la structure musicale dans une architecture de réseau de neurones récurrents permet de rendre compte de façon plus fine de la structure globale des mélodies apprises par le réseau.

Dans le cadre de nos expériences actuelles, cette conclusion demeure partielle, du fait d'un volume de

données d'apprentissage limité, qui entraîne une capacité insuffisante de généralisation du réseau appris. Toutefois, cette première exploration de l'hypothèse de non-invariance dans le temps de la structure musicale, par des réseaux de neurones récurrents, nous conforte dans l'idée de poursuivre nos recherches dans cette voie.

Plusieurs pistes sont prévues pour compléter ces travaux à court terme, permettant ainsi d'enrichir ces premières investigations par des expériences supplémentaires et les résultats correspondants.

Remerciements

Cette étude a reçu le support de l'Agence nationale de la recherche, dans le cadre du projet Dynamiques créatives de l'interaction improvisée (DYCI2, ANR-14-CE24-0002-01), et de la région Bretagne.

1. <https://magenta.tensorflow.org/2016/07/15/lookback-rnn-attention-rnn> [consulté le 30/11/2020]

2. <http://www.pytorch.org> [consulté le 30/11/2020]

Pour citer ce document:

Nathan Libermann, « Exploration de dépendances structurelles mélodiques par réseaux de neurones récurrents », *RFIM* [En ligne], Numéros, n° 7-8 - Culture du code, Mis à jour le 21/12/2020

URL: <http://revues.mshparisnord.org/rfim/index.php?id=642>

Cet article est mis à disposition sous [contrat Creative Commons](#)