

モデルによる補完を用いた ピアノ運指の効率的なラベル付けの検証

齋藤 康之^{1,a)} 中村 栄太^{2,b)} 饗庭 絵里子³ 金子 仁美⁴

概要: ピアノ運指データは、音楽教育や演奏解析、演奏支援などの研究における重要な資料であるが、研究に利用できる電子データは不足している。その背景には、全ての音符に対して運指番号が付与された電子データは収集コストが高いという問題がある。一方で、運指推定の研究が盛んに行われており、比較的高い精度での推定が可能な手法が提案されている。本研究では、運指推定のモデルを用いることで、一部の音符に付与された運指ラベルから、全ての音符の運指ラベルを高精度で補完する方法について調べる。5本の指の内、特に中指のラベルが補完する上で最も効率が良いことが分かった。また、モデルによる運指推定の不定性を用いてラベル付けの箇所を最適化すれば、約50%の音符に対するラベル付けから、全体の運指ラベルが約94%の精度で補完できることが明らかになった。この結果により、大規模ピアノ運指データ収集や動画を用いた効率的な運指自動検出技術や、運指の知識獲得の実現が示唆された。

1. はじめに

ピアノ演奏では、適切な運指の習得が基礎的な演奏技能と考えられている [1–4]。ピアノ運指の原理を情報学的に理解する目的で、自動運指推定が研究されている [5–21]。ピアノ運指分析は、演奏支援や学習システム [22–26] や編曲技術 [27] にも応用されている。

運指の定量分析や機械学習を用いた運指推定手法の研究には、電子化された大量の運指のデータが必要である。PIG データセット [19] は現在最大規模のピアノ運指の公開データであり、クラシック音楽の約300の演奏に対する運指が収められている。このデータは自動運指手法の機械学習に用いられ、約65%という高い推定精度の手法が実現された [18, 19]。また、このデータの分析により、異なる演奏者間のピアノ運指の一致度は平均約70%であることや、ピアノ運指には強い系列依存性があることが分かった [28]。

しかし、PIG データセットのデータ量は、深層学習を用いた機械学習や大規模データ分析などへの応用において十分とは言えない [20, 21]。大規模のピアノ運指データセットの構築が難しいのは、制作コストが高い楽譜などの記号化された音楽データ、演奏専門家による運指ラベル付

け、およびその打ち込み作業が必要だからである。効率的に運指データを収集するために、特殊なデバイスを用いる方法 [29] や動画解析による運指の自動認識 [23, 30–32] などが検討されているが、いずれの方法も認識精度に課題が残っている。また、出版楽譜にある運指情報を用いることも考えられるが、多くの楽譜では一部の音符のみに運指番号が記されているため、その他の音符に対する運指を補完する必要がある。

本研究では、運指のラベル付けおよび打ち込み作業のコストを低減させるために、自動運指推定モデルを用いる可能性について考える。ピアノ運指の強い系列依存性によって、一部の音符の運指が分かれば、他の音符の運指は高精度で補完できると考えられる。また、動画解析で得られる運指情報に対して、運指モデルを事前知識として用いることで、運指認識の精度を向上できる可能性もある。さらに、運指モデルを用いれば、与えられた曲の各音符に対する運指の不定性（個人性）の大きさを推定できるため、人が優先的にラベル付けすべき音符が理解できる可能性もある。

以下では、運指推定精度が高いことで知られる隠れマルコフモデル (HMM) に基づく運指モデルを用いて、ピアノ運指の効率的なラベル付けについて調べる。PIG データセットを用いて、一部の音符の運指ラベルが与えられた状況を仮想的に作り、その他の部分の運指をモデルで推定してその精度を分析する。この方法により、モデルによる補完に対して効果的な部分ラベル付けの方法について調べる。2章では、用いる運指モデルとデータ、および分析方

¹ 木更津工業高等専門学校 Chiba 292-0041, Japan

² 京都大学 Kyoto 606-8501, Japan

³ 電気通信大学 Tokyo 182-8585, Japan

⁴ 桐朋学園大学 Tokyo 182-0021, Japan

a) saito@j.kisarazu.ac.jp

b) eita.nakamura@i.kyoto-u.ac.jp

法について説明する。実験結果は3章で述べる。4章では本研究の結果の考察と今後の可能性について議論する。

2. 実験方法

2.1 運指モデル

本研究では、文献 [18, 19] の HMM に基づく運指モデルを用いる。このモデルは、整数で表される音高の系列 $\mathbf{p} = (p_n)_{n=1}^N$ に対して、1 (親指) から 5 (小指) の番号で表される運指番号の系列 $\mathbf{f} = (f_n)_{n=1}^N$ ($f_n = 1, \dots, 5$) の確率 $P(\mathbf{f}|\mathbf{p})$ を与える。曲を表す音高の系列は右手と左手の各々に対して与えられているものとし、確率モデルは片手ずつ別ものを考える。また、このモデルでは実際には各音符の発音時刻の情報も用いているが、ここでは簡単化のために音高のみを記すことにする。HMM では、この確率を運指番号系列の確率 $P(\mathbf{f})$ と、条件付き確率 $P(\mathbf{p}|\mathbf{f})$ に分解して考え、前者はマルコフモデル、後者は出力確率のモデルとして定式化する。文献 [18, 19] では3次の HMM までを比較しており、高次の HMM の方が推定精度が高いものの、2次と3次ではその差が小さいことが示された。そこで本研究では、高次のモデルのうち、パラメーター数がより小さく、過学習の危険が小さい、2次の HMM を用いる。

2.2 運指データ

本研究で用いる PIG データセット [19, 28] について述べる*1。PIG データセットには西洋クラシック作曲家のピアノ曲 150 曲が収められており、各楽曲には一つあるいは複数の運指が与えられている。運指付けされた部分の典型的な長さは、楽譜 1 ページ程度で、小節数は約 20、音符数は約 300 である。一部の楽曲には、個人性を調べるために最低 4 人の異なるピアノ演奏者による運指が与えられている。これらの楽曲には J. S. Bach と W. A. Mozart と F. Chopin の各 10 曲が含まれており、それぞれ「Bach セット」「Mozart セット」「Chopin セット」と呼ばれる。これら以外の 120 曲は様々な作曲家の曲が集められており、「Miscellaneous セット」と呼ばれる。Miscellaneous セットにも、Bach と Mozart, Chopin の楽曲は含まれるが、それらは上記の作曲家別サブセットに含まれるものとは異なる曲である。PIG データセットの詳しい記述およびこのデータを用いた運指の統計解析の結果は文献 [28] を参照されたい。

文献 [18, 19] と同様に、本研究では Miscellaneous セットを運指モデルの学習用に使い、分析には評価データ (Bach セット, Mozart セット, および Chopin セット) を用いる。特に、以下の分析では Miscellaneous セットを用いて得られた、学習済み HMM を用いる。

2.3 分析方法

部分的な運指ラベル付けをモデルで補完した場合の精度を調べるため、以下の方法で分析する。まず、PIG データセットの評価データの曲に対して、様々な条件でその一部の音符を選び、それらには運指ラベルが付いているものと見なし、その他の音符の運指は未知と見なす。次に、これら一部の音符の運指ラベルを用いて、HMM を用いてその他の音符の未知運指を推定する。この推定問題は、HMM の Viterbi アルゴリズムを用いて、ラベルが付いている音符に関しては出力確率を one-hot ベクトルとすることで、制約付き最適化問題として解ける。そして、推定結果を正解データと比較することで運指の正解率を計算し、これを復元の精度とする。

ラベル付けする音符を選ぶ条件として、以下に説明する3つの場合 (ランダム選択, 特定指選択, およびモデル推薦選択) を考える。

(1) ランダム選択: 曲全体の音符数に対して一定割合になるように音符をランダムに選択する。これは、ラベル付けする音符を無作為に選んだ状況に対応しており、以下の分析ではベースラインとして用いる。

(2) 特定指選択: 正解の運指を参照して、特定の指 (たとえば、親指と中指) が使われている音符を全て選択する。これは、たとえば、特定の指のみに認識精度が 100% のマーカーを取り付けて運指認識を行うような状況に対応する。

(3) モデル推薦選択: 運指モデルを用いて推定した各音符に対する運指の不定性 (個人性) の大きさにより音符を選択する。HMM などの確率的運指モデルを用いれば、与えられた音符列 $\mathbf{p} = (p_n)_{n=1}^N$ に対して、各音符 n の運指の事後確率 $P(f_n|\mathbf{p})$ を計算できる。HMM の場合は、前向き・後ろ向きアルゴリズムによりこれを計算できる。一般的に、事後確率がスパースなほどモデルの予測が鋭いことを示しているため、この事後確率の Shannon エントロピーを運指の不定性の指標として用いることができる。モデル推薦選択では、不定性がより大きい音符を優先して、指定された個数の音符を選択する。他の方法を用いてラベル付けをする音符を選択した後、残りの音符からモデル推薦選択により追加で音符を選択することもできる。事後確率の値は運指ラベルが与えられた周辺の音符にも依存して変化するため、この場合には、既にラベルが付いている音符に関しては出力確率を one-hot ベクトルとして事後確率を計算してから、各音符の不定性を評価する。モデル推薦選択は、運指モデルにどの音符を優先的にラベル付けすべきか自体を推定させる状況を表している。本研究では、運指の不定性の評価には1次の HMM を用いる。

一般に、運指ラベルを付ける音符の割合が多くなるほど、モデルによる補完の精度が高くなる一方で、ラベル付けやデータ打ち込みの作業量は増加する。そこで、モデルによ

*1 <https://beam.kisarazu.ac.jp/research/PianoFingeringDataset/>




図 1 ランダム選択による音符に対する部分ラベル付けの効果. 参考のため, $R = 0$ と $R = 100\%$ の場合を線形内挿したもの (実直線) とモデルによる補完が無い場合 (点直線) も示している.

る補完の効率を調べるための尺度としては, ラベル付けする音符の割合 (ラベル付け割合と呼ぶ) とモデルによる補完後の運指の精度の両方を考える必要がある.

次章では, ラベル付けする音符の選択方法に対して, この 2 つの尺度がどのように変化するかを調べた結果を示す. 音符列や運指の特性, および運指推定の精度は右手と左手で差異が大きいことが知られているため, 各々の場合で分析する.

3. 実験結果

3.1 ランダム選択による部分ラベル付けの効果

ランダム選択により得られた音符に対してラベル付けを行う場合を調べる. ランダム選択の結果は毎回確率的に変化するため, 以下の結果では異なる 20 個の疑似乱数を用いて得られた精度の平均値を示す. 図 1 に, ラベル付け割合 R の変化に対するモデル補完後の運指の精度 A の変化を示す. 図中の実直線は, $R = 0$ の場合 (ラベル付けが無いデータに対するモデルの推定精度) と $R = 100\%$ の場合 (完全なラベル付けを行う場合) を線形内挿したものを示している. 以下, これを標準線と呼ぶことにすると, これはラベルが無い音符に対して常に一定の精度でモデルが運指推定をすると仮定した場合の精度を表す. 図 1 より, 部分的にラベル付けを行った後にモデルによる補完を行うことで, 標準線よりも高い精度で運指ラベルが推定できることが分かる. これは運指データに内在する強い系列依存性を反映しており, 補完による精度と線形内挿の標準線での精度の差は, 部分ラベル付けが補完に与える非線形な効果を表す数値と解釈できる (以下, これを精度向上幅と呼ぶ). 特に, $R = 40\%$ 付近でこの効果が最も高くなり, 左手で約 7 ポイント, 右手で約 10 ポイントの精度向上につながっている (図 2(c)(d) を参照すると分かりやすい). この場合のモデル補完後の精度は左手・右手ともに約 88% である.

3.2 特定指選択による部分ラベル付けの効果

特定指選択において, 1 本から 3 本までの指の各組み合わせに対してラベル付けを行った場合に対する結果を図 2

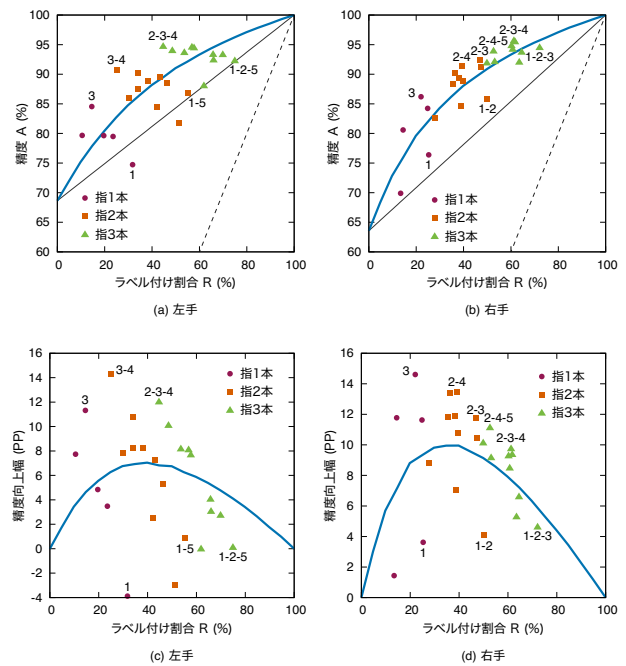


図 2 特定指選択による音符に対する部分ラベル付けの効果. (a)(b) の直線および曲線は図 1 と同じものを示している. (c)(d) は線形内挿の標準線からの精度向上幅を示している (曲線はランダム選択). 図中の数字は, 精度または精度向上幅を最大にする指の組み合わせ, またラベル付け割合を最大にする指の組み合わせを指番号で表している.

に示す. 効率的な音符の選択方法の基準として, モデルによる補正を行った後の精度と, 線形内挿の標準線の結果 (図 2(a)(b) の実直線) に対するその精度の増加幅 (精度向上幅) の両方が考えられる. 前者は図 2(a)(b) の縦軸, 後者は図 2(c)(d) の縦軸に示されている. 指 1 本を選択する場合は, 右手と左手の両方で, 中指のラベル付けをすると, 精度と精度向上幅の両方が最大となることがわかる. これは, 指番号の上下と音高の向きが基本的に一致するという運指の性質の下で, 手の中心にある中指の情報が前後の音符の運指を決定する上で最も有益な情報になることが理由だと考えられる. これとは対照的に, 親指のラベル付けをする場合は, ラベル付け割合は大きくなるが, 精度はランダム選択の曲線よりも低くなっている. したがって, 親指は部分ラベル付けをする際には効率的でないと言える.

指 2 本あるいは 3 本を選択する場合は, 左手と右手で異なる傾向を示している. 左手では, これらの場合で精度と精度向上幅を最大にする指の組み合わせは一致しており, それは指 2 本では「中指と薬指」, 指 3 本では「人差し指と中指, 薬指」であった. 右手では, 精度を最大にする指の組み合わせは指 2 本では「人差し指と中指」, 指 3 本では「人差し指と中指, 薬指」であり, 精度向上幅を最大にする指の組み合わせは指 2 本では「人差し指と薬指」, 指 3 本では「人差し指と薬指, 小指」であった. 全体的な傾向として, 中央の 3 本の指を含む組み合わせが効率的で, 特に精度基準では中指を含む組み合わせが良いことが分かる.

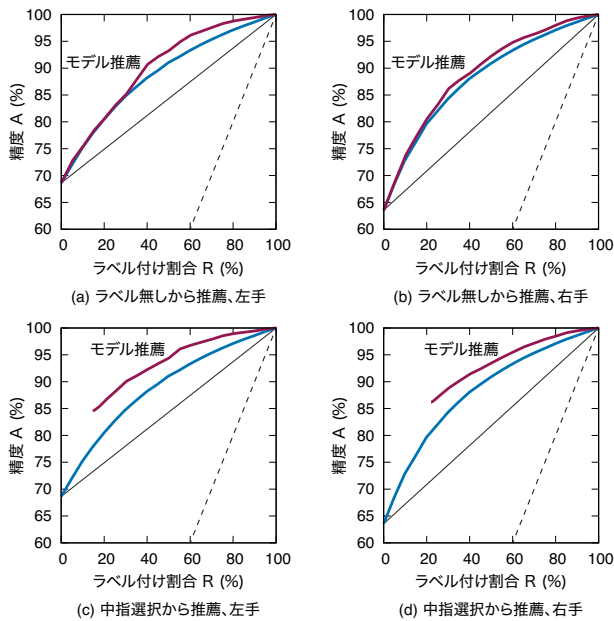


図 3 モデル推薦選択による音符に対する部分ラベル付けの効果. (a)(b) はラベル付け無しの音符列からモデル推薦によってラベル付けする音符を選択した場合を, (c)(d) は中指のラベル付けをした音符列からモデル推薦によってさらにラベル付けする音符を選択した場合を示している. 直線および青曲線は図 1 と同じものを示している.

対照的に, 親指を含む組み合わせは概して効率的でないことも分かった.

指 1 本から 3 本までの特定指選択の結果を総合すると, まず, 指の本数の増加に伴って推定精度が概ね右肩上がりに分布することが確かめられた. そして, 精度基準で最大となるのは, 両手ともに「人差し指と中指, 薬指」の組み合わせを選択する場合で, 左手ではラベル付け割合 $R = 44.7\%$ で精度 $A = 94.6\%$, 右手では $R = 61.3\%$ で $A = 95.6\%$ の運指の復元が可能である. 精度向上幅基準で最大となったのは, 左手では「中指と薬指」を選択したときであり, $R = 25.0\%$ で $A = 90.8\%$ の運指の復元ができ, 右手では中指のみを選択したときに $R = 22.0\%$ で $A = 86.2\%$ の運指の復元ができた.

3.3 モデル推薦選択を用いた部分ラベル付けの効果

モデル推薦選択を用いた場合に対する結果を図 3 に示す. 図 3(a)(b) が示すように, モデル推薦を用いることで, ランダム選択する場合よりもモデルによる復元後の精度が高くなるのが分かる. 両手ともに, ラベル付け割合 $R = 20 \sim 30\%$ 程度まではこの差は小さく, R がこれよりも高くなると差が大きくなっている. これは, R が小さい時には, モデル復元の足掛かりとなる運指ラベルを全体的に増やすことが効果的であるのに対して, R がある程度高くなると, 運指の系列依存性を考慮してなお不定性が残る部分がより明確になることを示唆している. また, モデル推薦の効果は右手に比べて左手においてより高いことが分

かる. 例として, オクターブが連続する曲において, オクターブを 1-5 で弾くか 1-4 で弾くかという選択には, 個人性が大きいので, このような箇所をラベル付けするようにモデルが優先していることが考えられる. オクターブ奏法は左手パートでより頻繁に用いられやすいことが, この結果に寄与している可能性がある.

モデル推薦選択は, 既に部分的にラベル付けされた曲に適用することも可能である. 例として, 図 3(c)(d) に, 中指のラベル付けがされた曲に対してモデル推薦選択を適用した際のラベル付け割合 R と精度 A の関係を示す. この場合, 左手では $R = 50.1\%$ で $A = 94.4\%$, 右手では $R = 50.1\%$ で $A = 93.5\%$ の運指の復元ができています. このように, 3.2 節の結果と組み合わせることで, 所望のラベル付け割合 R の値に対して, 精度 A を最大化するような特定指選択とモデル推薦選択の組み合わせを求めすることも可能である.

4. 議論

本研究の結果は, 運指データ収集の効率化や動画解析による運指認識の精度向上に適用できると考えられる. たとえば, 演奏家から与えられた手書きの運指番号データを打ち込みによって電子化する場合に, モデル推薦によって選ばれた 50% の音符に対して打ち込みを行えば, モデル復元により約 94% の精度で正解が復元できる. 正確な分析に使う運指データでは, さらに人手による修正によって正確なデータを作るが, 全ての音符を手で打ち込むよりも効率化できる. また, 機械学習の学習データとして運指データの収集を行う場合には, 多少のノイズが混ざっていてもなるべく多くのデータ量を確保することが優先されることがある. この様な場面では, 例えば, 1000 曲を 100% 人手でラベル付けするよりも, 2000 曲を 50% ずつ人手でラベル付けし, 残りはモデル復元する方が良いであろう.

動画解析では, 指ごとに異なる色のマーカーを用いる方法があるが [23,31], マーカーの認識精度は色により異なることも多い. 本研究の結果によれば, 中指などの手の中央部の指に認識精度の高いマーカーを用いることで, モデル復元によってより正確に運指認識ができると考えられる. また, 本研究では部分運指ラベル付けに対してモデルを用いた復元を調べたが, ノイズを含む運指認識結果に対して運指モデルを事前確率として用いることで, 統計的推論の枠組みで運指認識精度を向上させる可能性も考えられる.

さらに, 音楽教育や演奏支援における運指知識の習得を効率化するため本研究の方法を応用できると考えられる. 従来のピアノ演奏教育では, 教育者が選択した課題曲を順番に練習する中で, 運指の知識を習得する方法が取られている. これに対して, 本研究の方法では運指モデルを用いて運指の不定性を定量的に分析できるため, どの練習曲を学ぶことでどれだけの運指の学習が可能かを推定できる.

これを応用して、幅広い曲に対応できる運指の知識を効率的に学習するために練習曲を最適化することも可能である。あるいは、与えられた曲を円滑に演奏する上で、運指番号を書き込むべき一部の音符を選択する際に、本研究の方法を応用することも考えられる。

5. まとめ

本研究では、運指のラベル付けおよび打ち込み作業のコストを低減させる方法について検討した。一部の音符の運指が分かれば、ピアノ運指の強い系列依存性によって他の音符の運指を高い精度で補完でき、効果的に自動運指推定モデルを用いることができることを示した。特に、中指など、手の中央部の指を含む組み合わせが補完精度を向上させることを明らかにした。これにより、手の中央部に認識精度の高いマーカーを用いることで、モデル復元によってより正確に運指認識ができると考えられる。

本研究の拡張として、近年、運指精度が向上している深層学習を用いた運指モデル [20, 21] を復元に用いることが考えられる。また、バイズ学習の枠組みを応用することで、運指の個人性や反復音形に対する運指の繰り返し構造などを取り入れたより高精度の運指復元も可能であろう。さらに、演奏音符の発音時刻や消音時刻、強弱の情報を取り入れたモデルにより、演奏表情と運指の関係性を捉えた復元を行う方向性も考えられる。

謝辞 本研究は、日本学術振興会科研費 21K02846, 21K12187, 22H03661, および 2021 年度京都大学リサーチ・ディベロップメントプログラム【いしずえ】から支援を受けた。

参考文献

- [1] F. Couperin (transl. by M. Halford). *The Art of Playing the Harpsichord*. Alfred Pub. Co. (Original work in French published 1717), 1974.
- [2] C. P. E. Bach (transl. by W. J. Mitchell). *Essay on the True Art of Playing Keyboard Instruments*. W. W. Norton and Company, NY, USA (Original work in German published 1753), 1949.
- [3] D. G. Türk. *Klavierschule, oder Anweisung zum Klavierspielen für Lehrer und Lehrende, mit kritischen Anmerkungen*. Bärenreiter, Kassel (Original work published 1789), 1962.
- [4] J. Musafia. *The Art of Fingering in Piano Playing*. MCA Music, 1971.
- [5] 野口賢治, 野池賢二, 乾伸雄, 野瀬隆, 小谷善行, 西村恕彦. n グラムの手法を用いたピアノ運指の推論. 情処学会全国大会講演論文集, 2-101, 1996.
- [6] R. Parncutt, J. A. Sloboda, E. F. Clarke, M. Raekallio, and P. Desain. An ergonomic model of keyboard fingering for melodic fragments. *Music Perception*, 14(4), pp. 341–382, 1997.
- [7] 関口博之, 英保茂. 計算機によるピアノ演奏動作の生成と表示. 情処学会論文誌, 40(6), pp. 167–177, 1999.
- [8] M. Hart, R. Bosch, and E. Tsai. Finding optimal piano fingerings. *The UMAP Journal*, 21(2), pp. 167–177, 2000.
- [9] J. P. Jacobs. Refinements to the ergonomic model for keyboard fingering of Parncutt, Sloboda, Clarke, Raekallio, and Desain. *Music Perception*, 18(4), pp. 505–511, 2001.
- [10] 林田教裕, 水谷哲也. 楽曲構造に基づくピアノ運指ルールの論理表現. 情処学会全国大会講演論文集, 2, pp. 203–204, 2003.
- [11] Y. Yonebayashi, H. Kameoka, and S. Sagayama. Automatic decision of piano fingering based on hidden Markov models. *Proc. IJCAI*, pp. 2915–2921, 2007.
- [12] 米林裕一郎, 亀岡弘和, 嵯峨山茂樹. 手の自然な動きを考慮した隠れ変数付き隠れマルコフモデルに基づくピアノ運指決定. 情報処理学会音楽情報科学研究報告, 2007-MUS-71(29), pp. 1–6, 2007.
- [13] A. Al Kasimi, E. Nichols, and C. Raphael. A simple algorithm for automatic generation of polyphonic piano fingerings. *Proc. ISMIR*, pp. 355–356, 2007.
- [14] 春原雅彦, 松原正樹, 前田俊太郎, 斎藤博昭. 左手と和音に対応したピアノ運指の自動推定システム. 情処学会全国大会講演論文集, 2-147, 2010.
- [15] 若松万紗子, 松井知己. 和音に対するピアノ運指決定法. 京都大学数理解析研究所数理解析研究所講究録, 1773, pp. 87–95, 2012.
- [16] E. Nakamura, N. Ono, and S. Sagayama. Merged-output HMM for piano fingering of both hands. *Proc. ISMIR*, pp. 531–536, 2014.
- [17] M. Balliauw, D. Herremans, D. P. Cuervo, and K. Sörensen. A variable neighborhood search algorithm to generate piano fingerings for polyphonic sheet music. *International Transactions in Operational Research*, 24(3), pp. 509–535, 2017.
- [18] 中村栄太, 齋藤康之, 吉井和佳. ピアノ運指データを用いた統計学習手法による運指推定と演奏難易度の定式化. 第124回情報処理学会音楽情報科学研究報告, 2019-MUS-124(12), pp. 1–16, 2019.
- [19] E. Nakamura, Y. Saito, K. Yoshii. Statistical learning and estimation of piano fingering. *Information Sciences*, 517, pp. 68–85, 2020.
- [20] H. Guan, Z. Yan, and T. Hsu. Automatic piano fingerings estimations using recurrent neural networks. *Proc. Nordic Sound and Music Conference*, online, 2021.
- [21] H. Zhao, X. Guan, and Q. Li. Estimation of playable piano fingering by pitch-difference fingering match model. *EURASIP Journal on Audio, Speech, and Music Processing*, 2022(1), pp. 1–13, 2022.
- [22] C.-C. Lin and D. S.-M. Liu. An intelligent virtual piano tutor. *Proc. ACM International Conference on Virtual Reality Continuum and Its Applications*, pp. 353–356, 2006.
- [23] Y. Takegawa, T. Terada, and S. Nishio. Design and implementation of a real-time fingering detection system for piano performance. *Proc. ICMC*, pp. 67–74, 2006.
- [24] V. Sébastien, H. Ralambondrainy, O. Sébastien, and N. Conruyt. Score analyzer: Automatically determining scores difficulty level for instrumental e-learning. *Proc. ISMIR*, pp. 571–576, 2012.
- [25] Y. Saito, E. Nakamura, R. Sato, S. Agata, Y. Igarashi, and S. Sagayama. Conversion from standard MIDI files to vertical line notation scores and automatic decision of piano fingering for beginners. *Proc. International Conference on Technologies for Music Notation and Representation*, pp. 200–211, 2016.
- [26] P. Ramoneda, N. C. Tamer, V. Eremenko, M. Miron, and

- X. Serra. Score difficulty analysis for piano performance education. *Proc. ICASSP*, pp. 201–205, 2022.
- [27] E. Nakamura and K. Yoshii. Statistical piano reduction controlling performance difficulty. *APSIPA Transactions on Signal and Information Processing*, 7(e13), pp. 1–12, 2018.
- [28] 中村栄太, 齋藤康之, 吉井和佳. ピアノ運指データを用いた運指の個人性の解析. 第123回情報処理学会音楽情報科学研究報告, 2019-MUS-123(42), pp. 1–6, 2019.
- [29] D. A. Randolph and B. Di Eugenio. Dactylize: Automatically collecting piano fingering data from performance. *Proc. Late-Breaking Demo Session ISMIR*, pp. 1–3, 2016.
- [30] A. Oka and M. Hashimoto. Marker-less piano fingering recognition using sequential depth images. *Proc. Korea-Japan Joint Workshop on Frontiers of Computer Vision*, pp. 1–4, 2013.
- [31] J. MacRitchie and N. J. Bailey. Efficient tracking of pianists’ finger movements. *J. New Music Res.*, 42(1), pp. 79–95, 2013.
- [32] A. Moryossef, Y. Elazar, and Y. Goldberg. At Your Fingertips: Automatic Piano Fingering Detection. *preprint OpenReview.net*, H1MOqeHYvB, 2019.