



近代公文書とは

- 明治から戦前期までの公文書
- 当時の史実を記録した歴史史料

なぜ近代公文書OCRが必要なのか

- くずし字や古語表現が多く、解読困難な文書
- 行政機関が保管する近代公文書は活用されず死蔵状態化
- 容易に読め、活用しやすくするためOCRが必要
- テキスト化できれば全文検索や翻訳が可能、近代史研究に寄与

【解説】 近代（明治から戦前期まで）の公文書は当時の史実が記録された歴史史料でもあります。しかし、近代公文書は近世の流れをくむ古文書であり、古語的語句・言い回しがあるほか、字体は新旧字体・異体字が混在し、くずし字、略字を使って書かれている場合も多いため、一般の行政職員には解読が容易でなく利活用できず、各行政機関が保管する近代公文書が死蔵状態となりつつあります。また、近代日本史の研究に着手する若手研究者や大学院生にとっても、原史料解読の障壁は高く、いかに容易に読めるようにするかが課題となっています。




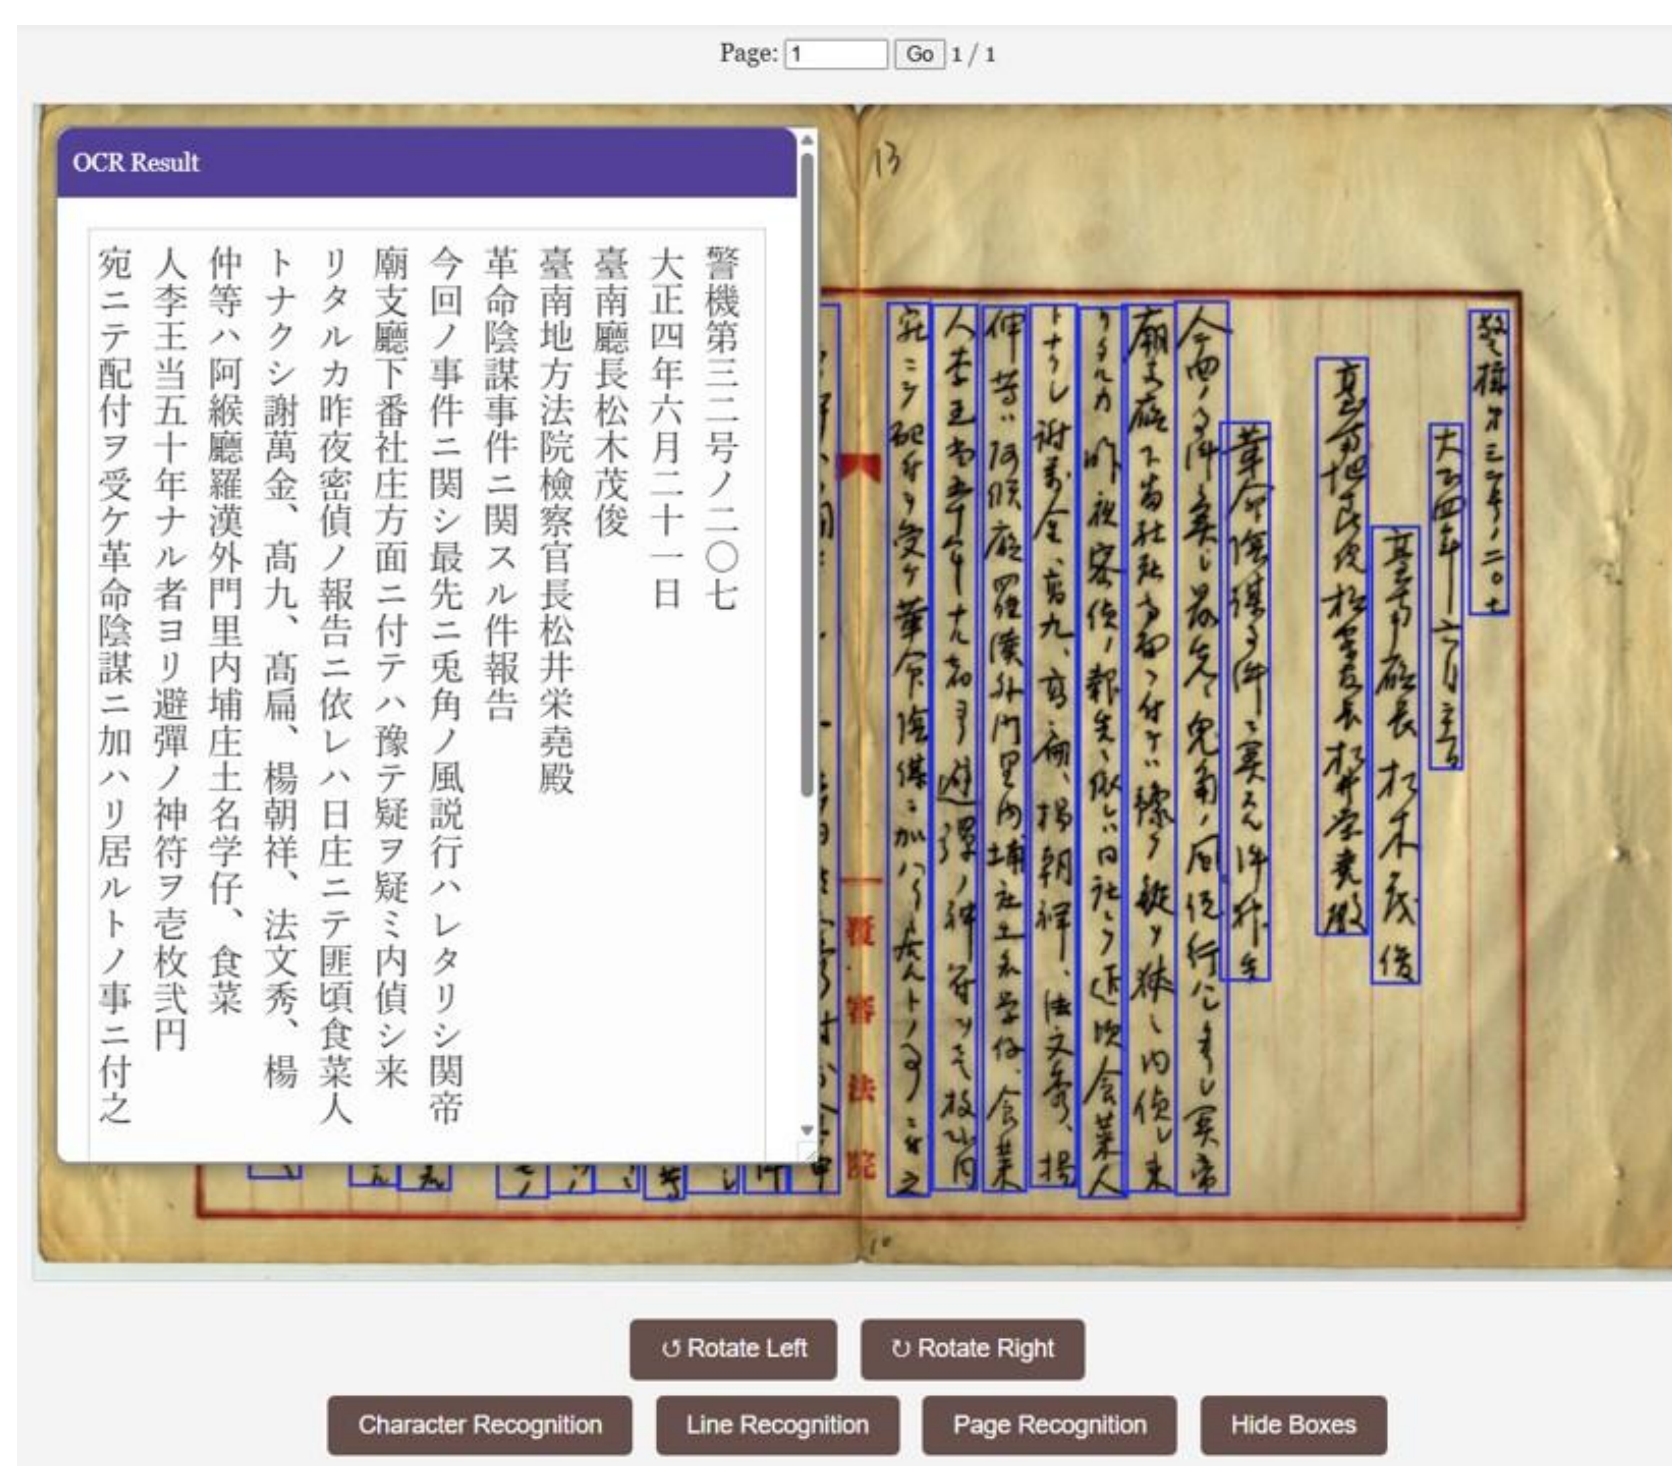

台湾総督府文書を題材とした大規模機械学習用データセット

- 「台湾総督府文書」からデータ収集
- 近代公文書を対象とした国内最大規模のデータセット
- 文字のバウンディングボックスが付与された高精度データセット

【解説】 台湾総督府は日本が台湾を統治していた時代に台湾に設置した行政機関です。台湾総督府文書は明治8年(1895年)から昭和20年(1945年)までのあらゆる種類の公文書（上奏文、法令命令文、内閣文書、各省庁などの関連文書）が原型のままに残された、公文書の雛形的存在で、その量は13,146簿冊（1簿冊約500ページ）にのぼります。台湾総督府文書からサンプリングした5,000ページを日本史の専門家に翻刻してもらい、122万の文字について、個々の文字のバウンディングボックスおよび新旧字体・異体字を区別した字種ラベルを付与した高精度データセットを作成しました。

OCRシステム

- 文書から行ごとに切り出し、行単位で文字認識
- 行内の文字の字種とあわせ、文字のバウンディングボックスも予測することで、認識精度95%を達成



【解説】 OCRシステムは、まず文書画像から各行を検出し、それらを整列します。次に、文書画像から切り出した行画像を読み込み、行画像中に書かれている手書き文字を1文字目から順に、どのような文字か（字種）と文字のバウンディングボックスを予測します。予測したn文字目のバウンディングからは、n+1文字目が行画像中のどこから始まるのかがわかり、この情報をシステムに入力してn+1文字目の予測を高精度で行うことができます。この工夫により認識精度が95%まで向上しました。なお、認識精度はIoU0.5としたF1-scoreです。