

# 第15期第1回（通算4回目）「日本語処理解析性能評価」実施結果報告

## 1 評価結果の客観的評価指標

### (1) 「日本語処理解析性能評価」実施の目的（趣旨）と評価の実施について

近年、デジタル・フォレンジックやeディスカバリ用途で、多様な検索機能や解析機能を持つ多くのソフトウェアが開発され、利用されています。しかしながら、海外で開発されたものも多く、日本国内で使用する場合に、どこまで日本語に対応しているかが不明で、ユーザーが使用してみるまでわからないのが現状です。また、実際に性能を評価しようとしても、客観的かつ有効な評価基準や指標も存在しないため、比較自体が困難な状況です。IDF「日本語処理解析性能評価」分科会ではこの状況を改善するために、日本語処理解析性能を評価するための基準となる項目とそれに伴う検索クエリ、さらに実際の評価に使うための評価用データの作成と各種ツールの日本語処理解析性能の評価基準項目を準備しました。また、本評価を実現するために日本語処理解析性能評価委員会が設立され、2017年1月に第1回評価が実施されました。今期第15期第1回目（通算第4回目）の評価は、4月末より受検製品（企業）の募集を開始し、6月に1社（AOSリーガルテック（株））の「Nuix」の評価を実施致しましたので、結果を報告致します。

### (2) 評価基準と評価用データ作成について

#### ① 評価基準について

単一単語検索や簡単なブーリアン検索を中心とした「基本検索」だけでなく、全角半角の同一視検索、正規表現や近傍検索といった比較的高度な検索機能を含む各種の「応用検索」も評価基準に含めました。尚、単一単語検索の項目にも「数字・漢数字同一視検索」といったものも含まれているので、「基本検索」といっても難易度は高いと想定されます。さらにそれぞれの評価用データとしては日本語特有の文字コードが多数と日本特有のEメールソフト等も対象に含みますので、総じて難易度の低いものから非常に高いと思われるものまで幅広く評価が可能なものとなりました。

#### ② 評価用データ作成手順について

評価用データは、IDFコラムより319号、345号、360号のそれぞれのテキスト情報と、各種評価基準項目を検証する為に必要な追加修正を319号、345号に加えたものの合計5種類のテキスト情報をベースに、9種類の文字コードのテキストファイル、テキストファイルを添付した6種類のEメールアプリケーションデータ、Microsoft Office (Word/Excel/PowerPoint) を用いた各種保存形式の違いによる多数のファイル形式の評価用データを作成しました。

## 2 評価結果の客観的評価指標

各種評価基準項目ごとに実施しました評価用データに対する検索結果は、評価用データに「ヒットしたか」「ヒットしなかったか」、それはそれぞれ評価用データにおいて「正解としてヒットすべきものか」「正解としてヒットすべきでないか」という2つの軸が存在し、【表1】で表される4象限で表記できます。

【表1】 評価結果の4象限

|      |          | 評価用データにおける正解        |                     |
|------|----------|---------------------|---------------------|
|      |          | ヒットすべきもの            | ヒットすべきでないもの         |
| 検索結果 | ヒットした    | True Positive (TP)  | False Positive (FP) |
|      | ヒットしなかった | False Negative (FN) | True Negative (TN)  |

統計分析で良く使われる指標として、下記3つの指標がありますので、今回の評価結果を示す客観的数値として公表致します。

(1) Recall : 再現率

正解としてヒットすべきもののうち、検索で正しくヒットしたものの割合

$$\text{Recall : 再現率} = \frac{\text{TP}}{\text{TP+FN}}$$

(2) Precision : 適合率

検索でヒットしたもののうち、正解としてヒットすべきものの割合

$$\text{Precision : 適合率} = \frac{\text{TP}}{\text{TP+FP}}$$

(3) Accuracy : 正解 (答) 率

検索でヒットしたものとヒットしなかったもの (全体) がそれぞれ正解である割合

$$\text{Accuracy : 正解 (答) 率} = \frac{\text{TP+TN}}{\text{TP+FP+FN+TN}}$$

今回のAOSリーガルテック株式会社 (Nuix investigation&Response Ver. 7.4.5) 評価結果を【表2】に記載します。

【表2】AOSリーガルテック株式会社 (Nuix investigation&Response Ver. 7.4.5) 評価結果

| テキスト 基本検索 |          | 評価用データにおける正解 |           | 合計  | 適合率  |
|-----------|----------|--------------|-----------|-----|------|
|           |          | ヒットすべき       | ヒットすべきでない |     |      |
| 検索結果      | ヒットした    | 276          | 0         | 276 | 100% |
|           | ヒットしなかった | 0            | 294       |     |      |
| 合計        |          | 276          |           | 正解率 | 100% |
| 再現率       |          | 100%         |           |     |      |

| テキスト 応用検索 |          | 評価用データにおける正解 |           | 合計  | 適合率  |
|-----------|----------|--------------|-----------|-----|------|
|           |          | ヒットすべき       | ヒットすべきでない |     |      |
| 検索結果      | ヒットした    | 369          | 0         | 369 | 100% |
|           | ヒットしなかった | 0            | 441       |     |      |
| 合計        |          | 369          |           | 正解率 | 100% |
| 再現率       |          | 100%         |           |     |      |

| Eメール 基本検索 |          | 評価用データにおける正解 |           | 合計  | 適合率  |
|-----------|----------|--------------|-----------|-----|------|
|           |          | ヒットすべき       | ヒットすべきでない |     |      |
| 検索結果      | ヒットした    | 12           | 0         | 12  | 100% |
|           | ヒットしなかった | 0            | 12        |     |      |
| 合計        |          | 12           |           | 正解率 | 100% |
| 再現率       |          | 100%         |           |     |      |

| アプリケーション 基本検索 |          | 評価用データにおける正解 |           |     |      |
|---------------|----------|--------------|-----------|-----|------|
|               |          | ヒットすべき       | ヒットすべきでない | 合計  | 適合率  |
| 検索結果          | ヒットした    | 62           | 0         | 62  | 100% |
|               | ヒットしなかった | 2            | 2         |     |      |
|               | 合計       | 64           |           | 正解率 | 97%  |
|               | 再現率      | 97%          |           |     |      |

※各テーブル上でカウントされている数は評価用データにおける検索ヒット数ではなく、ヒットファイル数になります。

### 受検社AOSリーガルテック（株）のコメント、問い合わせ先等

| AOSリーガルテック<br>株式会社 | 受検製品<br>NuiX investigation&Response  | Ver. 7.4.5 |
|--------------------|--|------------|
| 製品特性               | <p>NuiX ソリューションは、特許取得済みの NuiX エンジンに支えられたスーパーチャージ型のデータ処理、検索、インテリジェンス活用のプラットフォームです。この NuiX エンジンにはコンピュータや他のデジタルデバイス上にデジタル化し保存されたほぼすべてのフォーマットの非構造化データ、半構造化データ、構造化データをすべてインデックス化し、ファイルや OS の操作に対してフォレンジックの正確性での理解を提供します。日本語処理解析性能のみならず、数千種類に及ぶファイルフォーマットをサポートしており、PC、サーバー、モバイルデバイス、クラウドからデータを収集し、ペタバイトを超える大容量データも NuiX エンジンの並列処理技術により高速かつ安定してインデックス化します。また、お客様の要件に合わせスタンドアローン、オンプレミス、クラウドなど多彩な実装方法を提供しています。</p> <p>世界中の有力な組織が、調査、サイバーセキュリティ、諜報活動、インサイダー脅威、訴訟、規制対応、データプライバシー、コンプライアンス、リスク管理など極めて重要な課題に対して迅速で正確な回答を必要とするとき、NuiX がサポートしています。</p> |            |
| 受検目的               | <p>当該製品の日本語処理解析性能を客観的に把握し、今後の改善点をメーカーと共有するため。</p>  |            |
| 評価結果へのコメント         | <p>当該製品の高い日本語処理解析性能を認めていただき、評価委員の皆さまに感謝申し上げます。8年以上に及ぶ日本市場での実績のもとお客様からの貴重なフィードバックへの迅速な対応が今回の高い評価に繋がったものと考えております。引き続きお客様の声を大切に日本語処理解析性能とユーザビリティの向上に向けてメーカーとともに努めてまいります。</p>  |            |
| 問い合わせ先             | <p>AOSリーガルテック株式会社<br/>〒105-0001 東京都港区虎ノ門5-1-5 メトロシティ神谷町4F<br/>TEL: 03-5733-5790 FAX: 03-5733-7012</p>  |            |
| 自社HP公開             | <p>WEBサイト ( <a href="https://www.aos.com">https://www.aos.com</a> ) にて、本評価結果に関する自社コメントの公開を予定しております。また、詳細結果等の確認をご希望の場合は、上記問い合わせ先にご連絡下さい。</p>  |            |