

繰り返さない:

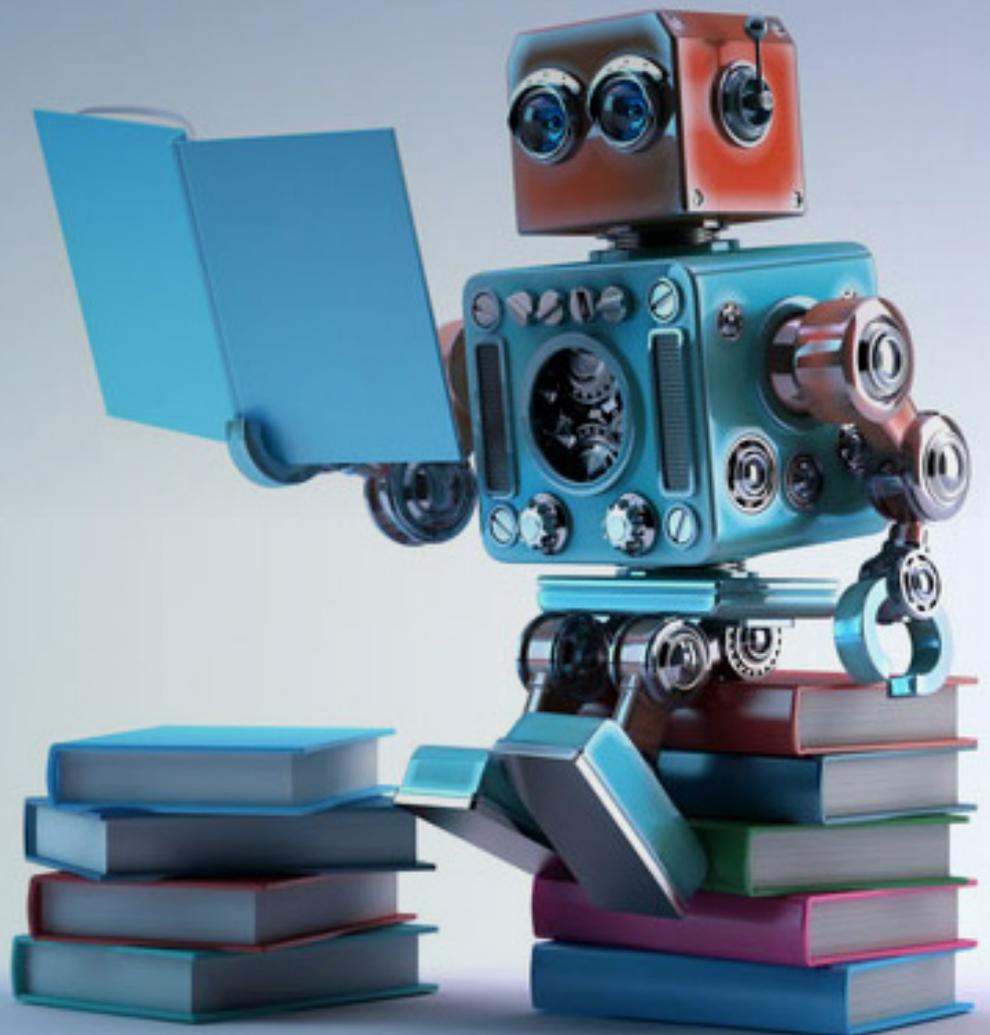
カスタマーエクスペリエンスにおけるテキスト分析の教訓と生成AI

2024年3月

著者

Fiona Moss

Rich Timpone, Ph.D.



IPSOS
VIEWS
AI SERIES

GAME CHANGERS





#IPSOSHiAi

イプソスは、ヒューマンインテリジェンス (HI) と人工知能 (AI) のユニークな融合を支持し、イノベーションを推進し、インパクトのある人間中心のインサイトをクライアントに提供しています。

当社のHIは、プロンプトエンジニアリング、データサイエンス、独自の高品質データセットの専門知識に由来しており、イプソスの生成AIプラットフォーム「Ipsos Facto」によって、創造性、好奇心、倫理観、厳密性をAIソリューションに組み込んでいます。

私たちのクライアントは、より安全で、より速く、人間に根ざしたインサイトから利益を得ることができます。

HI+AIの可能性を解き放ちましょう！

ChatGPTを代表例とする生成AIは、テキストベースの人工知能の力を急速に民主化しました。基本的にインターネットにアクセスできる人なら誰でも、質問すると超高性能ボットから回答を得ることができます。また、これらのツールを使えば、テキスト分析を多くのユースケースに幅広く応用することがで

きます。私たちは新しい環境にいますが、テキスト分析の過去から学ぶことで、間違いを繰り返さず、新しいツールを最大限に活用することができるのです。こうして歴史から学び、新たなチャンスを探みながら過ちを繰り返す運命から逃れるのです。

本ペーパーではテキスト分析に焦点を当てているため、生成AIについて取り上げる際には、一般的に大規模言語モデル (LLM) に焦点を当てます。LLMは確率的テキスト生成ツールであり、簡単に言えば、プロンプトに回答して、その後続く最も可能性の高い単語やトークンのシーケンスを予測するように訓練されており、「人の」スピーチのような印象を与えることを意図しています¹。しかし、多くの実用的なテキスト分析のユースケースに活用することもできます。過去の現場での経験からの学びが特に役立つのはここですが、高いレベルでは、これらの学びは画像モデルやマルチモーダルモデルを含む、他のタイプの生成AIにも適用できます。

テキスト分析のためのLLMの民主化は、初期とは著しく対照的です。2009年、イプソスのカスタマーエクスペリエンス (CX) チームが初めてテキスト分析を提供し始めた

私たちは新しい環境にいますが、テキスト分析の過去から学ぶことで、間違いを繰り返さず、新しいツールを最大限に活用することができます。

き、それはニッチなサービスであり、膨大な量の非構造化データやテキストデータを理解する効率的な方法を探していた少数のクライアントによって利用されていました。それから10年以上が経過し、テキスト分析はほとんどの大規模または継続的なCXプログラムにおいて標準となり、アスキング型 (オ

過去を活かす

イプソスは、生成AIモデルの品質と責任ある利用を評価するために、「真実・美・正義」のフレームワークを適用しています²。このフレームワークは、社会的、行動的態度、プロセス、行動を理解するために、初期のAIモデルの時代に適応されたものですが、新世代のツールにも同様に、場合によってはより以上に有効なものです^{3,4}。

この枠組みでは：

- ・ **真実** モデルとそのアウトプットの精度に焦点を当てる
- ・ **美** アウトプットの説明性、そしてユースケースによっては、意表をつき、新たなインサイトを生み出す能力
- ・ **正義** AI倫理、バイアス、アルゴリズムの公平さ、データセキュリティ、プライバシー、そしてトレーニングに使用される

ープンエンドの質問など) およびリスニング型 (ソーシャルメディアなど) のフィードバックにおける主要なトピックとセンチメントの特定と定量化が可能になっています。

生成AIが驚きの速さで世の中に浸透していることを考えると、テキスト分析におけるその探求と利用は、過去のツールよりもはるかに速いスピードで進むでしょう。私たちは皆、生成AIの可能性やLLMそのものに大きな感銘を受けますが、過去のテキスト分析のテストと適用から学んだ教訓を活かすことで、今後、企業は収益性の高いサステナブルでポジティブなカスタマーエクスペリエンスを自信を持って設計し、提供することができます。

データの作成者とツールの使用者の権利と責任など、複数の重要な分野を包含している。

このフレームワークを念頭に置き、本ペーパーでは、LLMを搭載した生成AIツールをチームが適用する際に、関連する5つの重要な教訓について概説します：

1. 透明性を求める
2. データを忘れない
3. 正式な評価は依然として重要
4. 期待を管理することを忘れない
5. ビジネスニーズに合ったレポートイング/利用メカニズムを確立する



1. 透明性を求める

テキスト分析の黎明期、業界は専門用語と誇大広告で溢れていました。異質な専門用語を読み解き、クラス最高を謳う複数のプロバイダーの間のトリアージは、初回利用の障壁となることがよくありました。

生成AIは、LLMの認知度を高めるだけでなく、独自の専門用語や誇大広告を生み出しましたが、無料でアクセスできるユーザーインターフェイスのテクノロジーを潜在的なユーザーの手に直接届けることで、いくつかの障壁を回避しました。インターフェイスやAIによって、LLMは従来よりもアクセスしやすく、敷居も低くなりましたが、すべてのユースケースに対応できるわけではなく、どのようにプロンプトを出すかによって、生成されるものの品質が左右されます。ここでも、確率的テキスト生成ツールとしてのその用途は、テキスト分析アプリケーションにとって潜在的な問題となります。

企業が企業ベースのアクセス、クリーンルーム/ウォールドガーデンなどの契約を導入

し、このテクノロジーを日常業務に組み込もうとする中で、イプソスが提言したのは、プロバイダーに対しそのメリットだけでなくアウトプットや制限についても明確に説明するよう求めることであり、今後もそれは変わりません。このような透明性は、美の重要な要素です。

LLMの場合、これらの留意事項には以下が含まれます：

- ・ モデルが何をしようトレーニングされているかについての明確なステートメント(LLMの精度はユースケースによって異なるため、プロバイダーからの主張にかかわらず、自分自身でテストするか、他者のバリデーションを見ることを強く推奨する)
- ・ コーパスからどのようなインサイトが直接構築され、どれがそれ以上のものかを識別するために、モデルのトレーニングに使用されるデータの性質と量(および制限事項)を理解すること。どちらも、実

際にはテクノロジーによって作り出された誤謬である「事実」のステートメントというハルシネーションの可能性があるが、リスクのレベルは異なる

- ・ モデルが新しいデータを経験するにつれて学習し適応し続けるのか、それとも固定されるのかを示す証拠(アップデートによって一部の領域で品質が低下した可能性があるため、アプリケーションを再テストして、以前テストしたとおりに動作することを確認する必要がある⁵⁾)
- ・ そのようなアップデートやモデルトレーニングに、データがどのようにフィードバックするかについての質問
- ・ LLMを既存のビジネスシステムでどのように活用できるか(APIアクセス、データエンジニアによるリンクの構築など、LLMを企業が意図する方法で実用的に使用できるようにする)。

多くのLLMは柔軟性があり、一見知性があるように見えますが、それでもビジネスと調査の目的を明確に定義し導入する必要があります。その結果、最初のモデルトレーニングから研究結果の提供まで、人間をそのループに関与させ続けることがカギとなり、このことは、人間によるフィードバック(人間による修正)から強化学習を受ける基礎(事前トレーニング済み)モデルであっても同様で

す。ハルシネーションは継続的なリスクであるため、「ループの中の人間」はその質を向上させます。

しかし、LLMにとって透明性が要求されるのは、モデルの能力や仕組みの面だけではありません。

企業から提供されたデータが、アウトプットの活性化のためにどこで使われるのかを理解することも重要です。このことを念頭に置いて、データプライバシーとセキュリティは、多くのオープンアクセスモデルにとって重要な懸念事項であり、その利用規約でも強調されています。私たちは顧客、従業員、専有データおよび機密情報が適切に保護されるよう、企業契約、ガバナンス、インフラを整備することをクライアントやチームに働きかけています。 Googleを含む多くの企業は現在、ChatGPTやBardのような公開チャットボットを機密データで使用しないようにチームに指示しています⁶⁾。検討されているソリューションのプライバシーとセキュリティ条項を理解することは、この新しいテクノロジーを自由に使用する際のリスク管理とビジネスの快適さの鍵となります。

多くのLLMは柔軟性があり、一見知性があるように見えますが、それでもビジネスと調査の目的を明確に定義し導入する必要があります。

2. データを忘れない

ガラクタを入れたらガラクタが出る/ゴミを入れたらゴミが出る

ガラクタを入れたらガラクタが出る (rubbish-in rubbish-out)のパラダイムは、テキストだけでなく、あらゆるタイプの分析に常に当てはまります。実際、すべてのテキスト分析は学習データの関数です。基本的に、関係するデータがビジネス上の疑問に対する代表的なものでなかったり、関連性がなかったり、その疑問に答えるのに十分な詳細が含まれていなかったりする場合、テキスト分析は目的に対して成果を上げることはできません⁷。しかし、これはデータそのものが原因であり、分析が原因ではないのです。

LLMにおいてもこのパラダイムは変わりません。実際、分析対象のテキストデータと、LLMの訓練に使われるテキストデータの両方が目的に合っていることを確認する必

要があります。一般的な原則にとどまらず、特にモデルのトレーニングや調整を行う場合、ツールは、基礎モデルのセットアップに使用されたデータを越える質問に対する答えを推定します。これらの答えは興味深い仮説を提供するかもしれませんが、真のインサイトではなく、誤解を招く可能性がより大きくなります。

トレーニングデータは、ビジネス上の意思決定に利用できる信頼できる結果をもたらすという暗黙の了解があります。しかし、基礎的なLLMにはインターネットを反映した文化的・集団的バイアスが存在することが分かっています。データの質と代表性の問題は、独自のモデルをトレーニングするチームにとっても重要です。

導入前に信頼度を高め、説明可能性を向上させるためには、LLMの訓練にどのようなデ

基本的に、関係するデータがビジネス上の疑問に対する代表的なものでなかったり、関連性がなかったり、その疑問に答えるのに十分な詳細が含まれていなかったりする場合、テキスト分析は目的に対して成果を上げることはできません。〃

ータが使用されたかを理解することが不可欠です。LLMが正しい回答を提供できるかどうかは、このデータの質と量にかかっています。データの不足、欠落、偏りは、不正確な、あるいは誤解を招くような結果をもたらす可能性があります。これは「真実」と「正義」を評価、考慮することの根本的な必要性と結びついています。

LLMを使用する場合（つまり、ユーザーと機械のテキストベースの対話が予想される場合）、プロバイダーから、テクノロジーから最適で最も正確な回答を引き出すプロンプトや質問を理解することも有用です。テキスト分析では、正確で詳細な回答を求める自由形式の質問や、関連性のある明確なコンテンツを提供する未承諾のデータソースを選択することが重要であると同様です。

母国語への配慮

複数の市場にまたがって事業を展開する企業にとって、テキスト分析において母国語は常に考慮する必要があります。重要なのは、

すべてのコメントに対して、1つの言語で一貫性のあるテキスト分析モデルを構築する（この場合、自動翻訳を使用しコメントを同じ言語にする）か、複数の母国語テキスト分析モデルを構築する（その過程で一貫性と比較性が失われてしまう）か、どちらかに決めることです。後者には、関係する市場に特化できるという利点があり、一方、前者はコスト節約と効率アップ、市場間の分析が容易になるという利点があります。Ipsosでは、Ipsos Emotion Frameworkで感情の基礎の異文化間のデータ化により、この問題に取り組んでいます⁸。

LLMでは言語も考慮の対象となります。トレーニングの過程で多数の、場合によっては数百の異なる言語のデータソースに触れてきました。しかし、各言語で同じレベルのパフォーマンスを提供できるわけではありません。母国語でのトレーニングの結果、同じプロンプトでも言語が異なれば、その質や回答は大きく異なります。



CXの世界では、LLMを搭載したツールを許可する前に、信頼関係を構築するために、透明性とデータに関する以下のすべてのデューデリジェンスが必要である：

- ・ 顧客データやビジネスデータへのアクセス
- ・ 顧客と直接対話（例：強化されたチャットボット）
- ・ スタッフが仕事をしやすいようにする（例：現場のスタッフに行動を推奨する、大量のデータから要約レベルのインサイトを提供しビジネス戦略に役立てる）

このようなデューデリジェンスを実施しなければ、顧客の信頼を損ねたり、誤った、あるいは標準以下の顧客体験を提供したりするリスクが高くなります。

イプソスの定性リサーチャーが行った、ビデオ音声トラックからの文字起こし、翻訳、センチメント、コンテンツのテーマ設定といったユースケースにおける生成AIツールの品質テストでは、異なるLLMやプロバイダーのパフォーマンスは、互いに、また言語間で大きく異なっていました⁹。そのため、LLMを評価する際には、ユースケースと言語ごとに品質チェックを行い、それぞれの相対的・絶対的な精度と、目的に合っているかどうかを判断する必要があります。

したがって、テキスト分析と同様に、LLMで使用したい言語を特定し、LLMが適切な方法でそれらをサポートしているかどうかを

チェックすることが不可欠です。場合によっては、LLMを最大限に活用するために、ユーザーに第二言語でLLMとやりとりしてもらう必要があるかもしれません。その結果、誰が、どのような形でLLMを利用するのか、また、プロンプト作成の重要性を考慮し、特に顧客がツールと直接やり取りする可能性がある場合は、潜在的に必要とされる言語スキルがあるかどうかを特定することも重要です。

選択したテクノロジーを最大限に活用するための作業は、2009年当時と変わらず現在においても重要なのです。

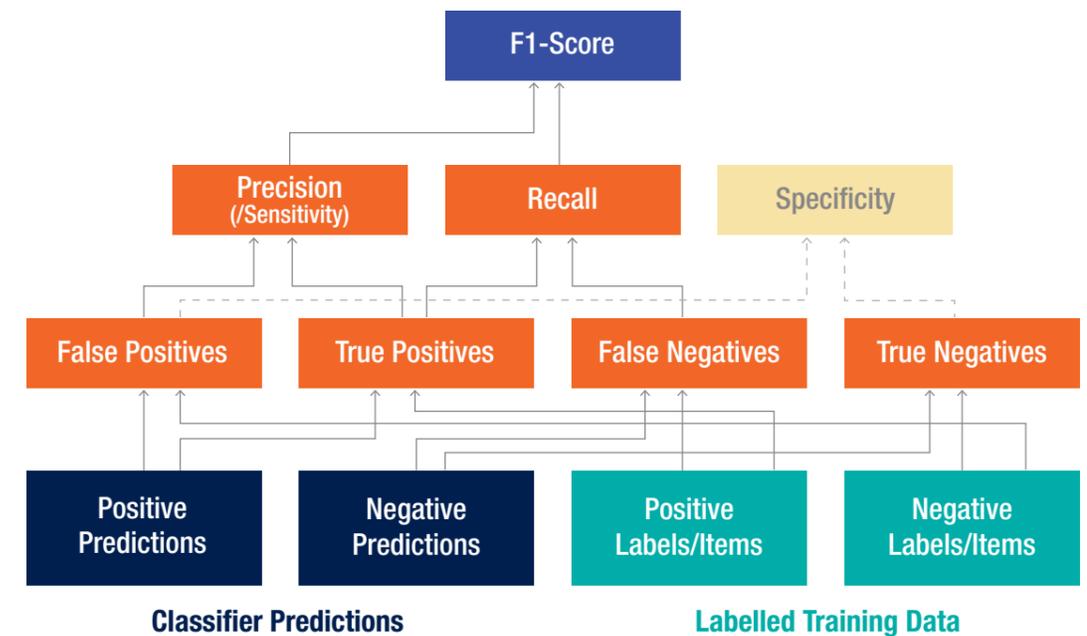
したがって、テキスト分析と同様に、LLMで使用したい言語を特定し、LLMが適切な方法でそれらをサポートしているかどうかをチェックすることが不可欠です。〃

3. 正式な評価は依然として重要

私たちのコア・メッセージのひとつであり、「真実」「美」「正義」の側面の根底にあるのは、生成AIは、テキスト分析が長年にわたり受けてきたのと同じ厳密さで評価される必要があるということです。LLMは、その定性的な構成と確率論的な構築から、形式的に精査されるよりも、アウトプットが合理的に見えるかどうかという表面的な妥当性によってレビューされることが多くあります。しかし私たちが過去から学んだ重要なことのひとつは、テキスト分析から最大の価値を得るためには、特定のユースケースに対する品質を体系的に評価する必要があるということです。

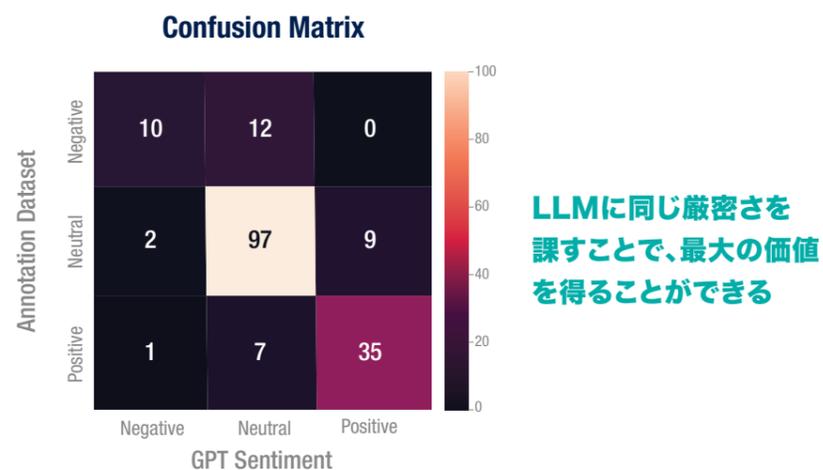
図1は、センチメントやその他のテキスト分類の品質を評価するために使用されるフレームワークです。これは、単純な正確さのパーセンテージの数値だけでなく、全体的な品質と、問題が起こりうる場所を体系的に解明します¹⁰。このようなテストを行うには、真実のベースラインに対する評価が必要です。以前はこれが標準的でしたが、LLMではあまり一般的ではありません。しかし、テキスト解析を含むユースケースの評価には、このような正式な評価を作成することが重要であると考えています。

図1. NLP評価指標のセット



出典: Kanstrén, T. (2020) "A Look at Precision, Recall, and F1 Score"

図2. LLMセンチメントコーディングのイプソス評価



	Precision	Recall	F1-Score	Support
Negative	0.77	0.45	0.57	22
Neutral	0.84	0.90	0.87	108
Positive	0.78	0.81	0.80	43
Weighted avg	0.81	0.82	0.81	174

Explainer: Precision – percent of correct positive predictions out of all positive prediction; recall – percent of positive predictions out of all true positive cases; f1-score – the harmonic mean of the two measures.

出典: Legg, J. and Bangia, A. Ipsos UU AI Quality Assessment.

前述の例では、様々なLLMやサードパーティサプライヤーをテストし、各言語の評価のためのベースラインを明確に作成しました。図2は、AIによって生成されたセンチメントコーディングが、真実を正確に予測していることを評価する混同行列を用いたある言語における1つのカテゴリテストの例です。この表は、図1の各テストをさらに詳しく説明し、品質の違いを示しています。テストや測定方法についての詳細な議論は本稿では取り上げませんが、この図解は、異なるツールを互いに比較し、客観的な基準に照らし合わせることで、ツールがいつ、どこで使用する

際に十分な品質を提供するとみなされるのか、どこが不十分なのかを判断する上で役立つことを示しています。

重要なのは、LLMや生成AIのツールを過去よりも高い基準で評価することではなく、感心するあまり低い基準で評価することを避けることです。過去からの教訓は、評価の厳密さが品質基準を作り出し、対策を比較する方法を生み出したということです。私たちは、この教訓が現在にも生かされるべきだと考えています。

4. 期待を管理することを忘れない

初期の頃、テキスト分析は誇大宣伝の犠牲者となり、非常に高い精度レベルという大きな約束に応えることができませんでした。

現在では、分類の精度と適用範囲のレベルつまり、利用可能なテキストデータのうち、どの程度がモデルに含まれているか)の両方について、主張がより緩やかになっています。実際、今日の世界では、100%の正確性やカバー率を約束するプロバイダーにはいくつかのフォローアップの質問をする価値があります。

長年のテキスト分析の経験から、精度とカバー率の間にはバランスがあることもわかっています。例えば、カテゴリの精度が高ければ高いほど、アナリストはノイズとともに関連するコメントを押し出す可能性が高くなります。その結果、精度は上がりますが、カバー率は下がります。対照的により幅広いカテゴリを構築し、関連するコメントとともにある程度のノイズを許容すると、精度は下がりますが、カバー率は上がります。このバランスがうまくいくかどうかは、アナリストのス

キルとエンドユーザーの期待にかかっています。私たちは、アンケート調査から大規模なソーシャルリスニング調査に至るまで、このことを目の当たりにしてきました。実際「ビッグデータ」の調査でも、精度を向上させるためには、特定のドメインに対する追加コーディングが必要になることが多いのです。

前節で見てきたように、LLMも精度に関する懸念から免れることはできません。確かに生成AIは、正しいかどうかにかかわらず、自信を持ってその答えを主張します。その答えは、与えられたプロンプトに対して特定の単語が互いに続く確率に「単純に」基づいていることを忘れてはなりません。

ハルシネーションや、正確さに関する問題などを考えると、この反応の確実性は、CXのチャットボットがよく使われる学習や探索にとって特に気になることです。CX担当者の仕事をスピードアップするには非常に有益ですが、事実を確認し、LLM応答の信頼性を額面通りに受け入れないことが重要です。ChatGPT¹¹によって作成された偽の判



例にまみれた準備書面を提出した弁護士を含め、これが実行されていない例はたくさんあります。これは彼らの事件をまったく解決しませんでした。

したがって、これまでのテキスト分析と同様に、LLMや生成AIが提供する解説に対するエンドユーザーの期待を管理する必要があります。それは自信に満ち有能に聞こえるかもしれませんが、魅力的なユーザーインターフェイスに表示されるかもしれませんが、そ

れはすべての答えが真実として受け入れられるべきだという意味ではありません。人工知能の世界は威圧的で、少なからず知的に聞こえますが、だからといって、人工知能が提供するアウトプットが何の疑問も持たれず、チェックもされないままでよいということにはなりません。特に、それらの答えが、受け取った情報の信憑性を疑う立場にないスタッフや顧客の意思決定や行動に情報を提供することを意図している場合はなおさらです。

5. ビジネスニーズを満たす報告/利用メカニズムを確立する

テキスト分析における最も大きな変化のひとつは、その使用方法にあります。テキスト分析が始まった当初は、単純なExcelシートやPowerPointスライドで、数百万件の逐語的コメントの内容を表示することができれば十分でした。

しかし今日では、テキスト分析は単に静的なPowerPointスライドではありません。例えばCXの世界では、より良い顧客体験を推進するためのダイナミックなツールです。これは、リアルタイムのテキスト分析がエンドユーザーの手に直接提供されることを意味しており、担当は問題が発生するのとほぼ同時に応答してループを閉じたり、または、KPIに対するフィードバックの影響を特定するためのポストテキスト分析の詳細な調査をしたりできます。

LLMと生成AIは、テキスト分析がすでにあるところ、つまりライブインタラクションのための既存の設定可能なインターフェイスでその役割を果たします。それは適切な機能性をサポートするモデルとともに、適切なユーザーの手に渡する必要があります：

- ・ 危険信号を解決するために働いているコンタクトセンターの担当者は、特定の問題に直面したときに最適な介入を提供するためのシステムを必要とする場合がある
- ・ インサイト専門家は、複数のデータソースからインサイトを迅速かつ効率的に合成するために、テキスト要約ツールを必要とする場合がある
- ・ アナリストは、コードを最適化したり、出力を自動化したりするための提案を提供するインターフェイスから恩恵を受ける場合がある

LLMは私たちの仕事を軽減し、人間が最も得意とすること、つまり既存の枠にとらわれない考え方や、他の人間との交流を可能にしてくれます。本質的には革新的な方法で顧客との強い関係を築くことを可能にしてくれます。



結論として

テキスト分析は成長しました。もはや注目されたくてたまらない小さな子供ではありません。それは、今日のビジネス上の意思決定を明確かつ確実に伝えることのできる、確立された大人です。

しかし、すべての大人がそうであるように、それを最大限に活用するためには公平に扱う必要もあります。つまり、ビジネス目標を明確にすること、テキスト分析が基礎データにないコンテンツを見つけることを期待しないこと、品質の評価に現実的な期待を持たせること、そして最終結果が分析され、可能な限り最良の方法でエンドユーザーに伝わるようにすることです。

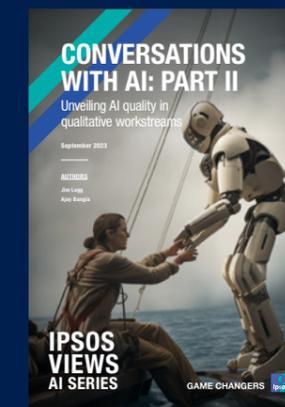
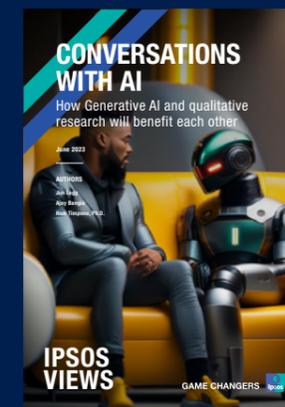
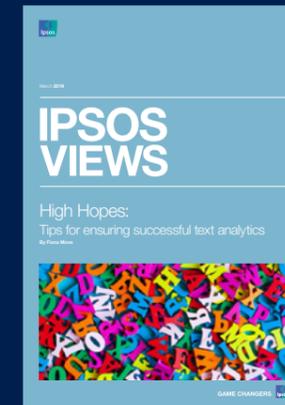
LLMや他の形式の生成AIツールは、従来のテキスト分析の洗練された（そして悪い）いこのようなものであり、同じように公平な扱いを期待し、いくつかの新しい条件を加えながら、現在私たちの多くを驚かせる結果を出しています。私たちはいずれこの高度な技術に順応し、現在のテキスト分析のように毎日検討するようになるのでしょうか？もちろんそうです。すでに多くの人がLLMを既存のツールや日常生活に組み込んでいるため、過去よりもさらに速いのです。そしてCXにとってこのプロセスは、より良い、より忠実な、より収益性の高い顧客関係にもつながるのでしょうか？LLMを尊重し、過去から学び、未来を受け入れるならば、ほぼ間違いなくそうなるでしょう。

参考文献

1. Wolfram, S. (2023). "What Is ChatGPT Doing ... and Why Does It Work?" 14 February, 2023. Stephen Wolfram Writings. <https://writings.stephenwolfram.com/2023/02/what-is-chatgpt-doing-and-why-does-it-work/>
2. Timpone, R. and Guidi, M. (2023) Exploring the Changing AI Landscape – From Analytical AI to Generative AI. Ipsos Views. <https://www.ipsos.com/en/chatgpt-and-rise-Generative-ai-navigatingchanging-landscape-ai>
3. Taber, C.S., and Timpone, R.J. (1996). Computational Modeling, Quantitative Applications in the Social Sciences #113, Sage Publications, Thousand Oaks, London and New Delhi.
4. Timpone, R. and Yang, Y. (2018). "Justice Rising: The Growing Ethical Importance of Big Data, Survey Data, Models and AI." Paper presented at the 2018 BigSurv Conference; Barcelona, Spain.
5. Zumbun, J. (2023) "AI Surprise: It's Unlearning Basic Math". The Wall Street Journal. August 5-6, 2023; p A2.
6. Dastin, J. and Tong, A. (2023) "Focus: Google, one of AI's biggest backers, warns own staff about chatbots". Reuters. June 15, 2023.
7. Ho, C. and Mu, J. (2023) Humanizing AI: Real human data to generate and predict real innovation success. Ipsos Views. <https://www.ipsos.com/en/humanizing-ai-real-human-data-generate-and-predict-real-innovation-success>
8. Garcia-Garcia, M., Baldo, D., and Timpone, R. (2023) Emotions Around the World: A Cross-Cultural Framework for Emotion Measurement. Ipsos Views. <https://www.ipsos.com/en/emotions-around-world>
9. Legg, J. and Bangia, A. (2023) Conversations with AI: Unveiling AI quality in qualitative workstreams. Ipsos Views. <https://www.ipsos.com/en/conversations-ai-part-ii-unveiling-ai-quality-qualitative-workstreams>
10. Kanstrén, T. (2020) "A Look at Precision, Recall, and F1 Score" Published in Towards Data Science. <https://towardsdatascience.com/a-look-at-precision-recall-and-f1-score-36b5fd0dd3ec>
11. Neumeister, L. (2023) "Lawyers blame ChatGPT for tricking them into citing bogus case law." Associate Press. June 8, 2023. <https://apnews.com/article/artificial-intelligence-chatgpt-courts-e15023d7e6fdf4f099aa122437dbb59b>

さらに読む

1. <https://www.ipsos.com/en-uk/high-hopes-tips-ensuring-successful-text-analytics>
2. [変化するAI事情を探る](#)
3. [AIとの対話：パートI](#)
4. [AIとの対話：パートII](#)
5. [AIとの対話：パートIII](#)



繰り返さない:

カスタマーエクスペリエンスにおける
テキスト分析の教訓と生成AI

著者

Fiona Moss, Head of CX Global Analytics Team, Ipsos

Rich Timpone, Ph.D., Head of Global Science Organization, Ipsos

The **Ipsos Views** white papers are produced by the **Ipsos Knowledge Centre**.

www.ipsos.com
@Ipsos

GAME CHANGERS

