

インドコンピュータ関連発明審査ガイドラインの解説
～AI 関連発明の記載要件～

2025 年 8 月 8 日

河野特許事務所
所長弁理士 河野英仁

1. 概要

インド特許庁は 2025 年 7 月 29 日コンピュータ関連発明審査ガイドライン (Guidelines for Examination of Computer Related Inventions (CRIs2025)) を公表した。本ガイドラインはインド特許法第 3 条(k)の保護適格性に関する判断基準の他、AI(人工知能)、ブロックチェーン及び量子コンピューティング等の **Emerging Technologies** についての詳細なガイダンスを示している。

本稿では本ガイドラインの **Emerging Technologies** の一部である AI の部分にフォーカスし、さらに AI 関連発明の種類に応じて課される記載要件について具体例を挙げて解説する。

2. 保護適格性

インド特許法第 3 条(k)は保護適格性に関し、以下の通り規定している。

第 3 条 発明でないもの

次のものは、本法の趣旨に該当する発明とはしない。

...

(k) 数学的若しくは営業の方法又はコンピュータ・プログラムそれ自体若しくはアルゴリズム

本ガイドラインでは、3 条(k)の規定により、数式及び人工知能／機械学習／ディープラーニングの理論的構成といった抽象的なアイデアは、実用性(practical application)がないため特許を取得できないとしている。

しかしながら、AI／ML／DL のイノベーションによって抽象的な原理が現実世界で具体的な応用へと変換された場合、特許取得可能な主題となる可能性があるとしている。例えば、AI アルゴリズムを医療機器、自動運転または機器の異常検知に用いた場合、保護適格性を有することとなる。

5.2. AI/ML/DL 関連発明への対応

AI/ML 関連の発明には、一般的に、人工ニューラルネットワーク (ANN)、畳み込みニューラルネットワーク (CNN)、リカレントニューラルネットワーク

(RNN)、スパイクニューラルネットワーク (SNN)、敵対的生成ネットワーク (GAN)、トランスフォーマーといったディープラーニングの構成要素に加え、ランダムフォレスト、決定木、ベイジアンネットワーク、クラスタリングのための期待値最大化、次元削減のための t 分布確率的近傍埋め込み (tSNE) といった従来の機械学習 (ML) 手法が含まれる。バックプロパゲーション、勾配降下法最適化、アテンションメカニズムといったディープラーニング特有のメカニズムは、モデルが膨大なデータセットから複雑な表現を学習することを可能にする。

これらの計算システムとアルゴリズムは、教師あり学習、教師なし学習、強化学習のいずれのパラダイムを採用しているかに関わらず、本質的に抽象的な数学的実体であり、その論理構造によって定義される。したがって、その理論的根拠は経験的な学習プロセスとは独立したものである。数式及び人工知能／機械学習／ディープラーニングの理論的構成といった抽象的なアイデアは、実用性がないため特許を取得できない。しかし、AI／ML／DL のイノベーションによって抽象的な原理が現実世界で具体的な応用へと変換された場合、特許取得可能な主題となる可能性がある。

3. 発明者地位

インド特許法第 6 条では「真正かつ最初の発明者」が特許出願を行うことができる者として規定されており、インド特許法第 2 条(p)では「特許権者とは、特許権の被付与者又は所有者として現に登録簿に登録されている者をいう」と規定されていることから、現行法では AI マシン自体は発明者としての地位を有しないと解される。

ここで問題となるのが、人間の発明に対する貢献がほとんどなく、AI により発明がなされた場合の発明者地位である。本ガイドラインでは、AI 関連発明を AI 生成発明 (AI-generated inventions) と AI 支援発明 (AI-assisted inventions) との 2 つに分けている。国により定義の仕方が相違するため注意が必要である。

(1) AI 生成発明

AI 生成発明とは、AI システムが自律的に、または人間の介入が極めて限定的である状態で生み出した発明を指す。このような AI 生成発明は、インド特許法第 6 条に基づき、AI は発明の真正かつ最初の発明者であると主張する「人 Person」とみなされないため、特許を受けることができない。

(2) AI 支援発明

AI 支援発明とは、発明プロセスにおいて AI をツールとして用いて行われた発明で

ある。AI 支援発明は、特許性基準を満たし、具体的な発明的応用を通じて技術的効果を実証している限り、特許法第 3 条(k)に基づき、特許を受けることができないと分類されるものではない。

5.2.1 AI 関連発明における発明者地位：

AI 関連発明は、AI 生成発明 (AI-generated inventions) と AI 支援発明 (AI-assisted inventions) という 2 つの大まかなカテゴリーに分類できる。

AI 生成発明とは、AI システムが自律的に、または人間の介入が極めて限定的である状態で生み出した発明を指す。このような AI 生成発明は、1970 年特許法第 6 条に基づき、AI は発明の真正かつ最初の発明者であると主張する「人 Person」とみなされないため、特許を受けることができない。

AI 支援発明とは、発明プロセスにおいて AI をツールとして用いて行われた発明である。AI 支援発明は、特許性基準を満たし、具体的な発明的応用を通じて技術的効果を実証している限り、特許法第 3 条(k)に基づき、特許を受けることができないと分類されるものではない。

4. 記載要件

本ガイドラインでは記載要件の一つである開示の十分性 (Sufficiency of Disclosure) について述べている(インド特許法第 10 条(4))。AI 関連発明は、AI モデル自体の発明、既存モデルの利用に関する発明、前処理に特徴のある発明、アルゴリズムの技術的実装に特徴のある発明、強化学習の発明、及び、学習データに特徴のある発明等、様々存在し、発明内容に応じて当業者が過度の実験 (undue experimentation) なし実施することができるレベルまで記載することが重要である。

本ガイドラインでは、事例によっては検証結果または学習時の損失関数の記載まで要求する厳しい側面を有する一方で、トレーニングデータセットに対しては、膨大な量または機密性を要する可能性のある特定のデータセット自体ではなく、データの定義特性を記述するだけで十分と寛容な側面も有する。各事例を参考にケースバイケースで実施例を記載する必要があるといえる。

(1)シナリオ1 AI モデルの性能向上に関する発明の場合

Scenario-1:

AI システムでは、入力と出力は通常既知であるが、入力を出力に変換するロジックは複雑、抽象的、またはその場で導き出されたりすることがある。クレームされた発明が主にこの入出力変換に関する独占的権利の取得に焦点を当てている場合、明細書は、完全かつ有効な開示に関する法定要件に準拠して、既知のプロセスと変

数を、当業者が変換を再現できるほどの具体的かつ明瞭性をもって詳細に記述することにより、この変換を明確にすることを目指すべきである。

テスト結果またはその他の形式の証拠によってモデルの出力の正確さが検証される場合は、特に AI が、出力の一貫性に関する具体的で明確な証拠を提供すること（複数回の実行で同じ医療画像に対して同一の診断が出るなど）、変化するが予想される条件下での精度（さまざまな気象条件下で確実に機能する自動運転車ブレーキなど）、小さな入力の変動に対する堅牢性（小さなデータ形式の変更に影響されない不正検出など）、および重大なエラーの発生率が明らかに低いこと（重要な機械の障害検出において正確に定量化された偽陽性率と偽陰性率など）など、信頼性が不可欠な精密なアプリケーションに使用される場合は、これらを含める必要がある。

Example-9 (Hypothetical):

手書きの医療処方箋を、ディープラーニングを用いて構造化された電子医療記録に変換するシステム／方法に関する発明は、手書きの医療処方箋のスキャン画像を入力とし、患者への指示、薬剤名、投与量を含む JSON オブジェクトなどの構造化されたデジタル形式を出力するニューラルネットワークシステムを備える。CNN（例：ResNet）を用いて画像ピクセルから特徴を抽出し、Transformer ベースのシーケンスツリーデコーダを用いて画像埋め込みをテキストにマッピングし、前処理には画像の 2 値化、ノイズフィルタリング、およびサイズ正規化が含まれる。

本発明のトレーニングデータには、薬剤師によって注釈が付けられた 100 万件のラベル付き処方箋が含まれており、検証結果では、別の 10,000 枚の画像テストセットにおいて、より高いフィールドレベルの抽出精度が示されている。

開示要件の十分性：

- i. ニューラルネットワークアーキテクチャ（CNN および Transformer ベースのデコーダー）は、十分な構造的詳細（レイヤータイプ、深度、活性化関数）とともに開示されるべきである。
- ii. 使用されたデータセット（ラベル付き処方箋 100 万件）は、手書きのばらつき、デジタル出力の構造、処方箋のラベル付けまたは注釈付け方法など、適切に特徴付けられるべきである。
- iii. 前処理手順（画像クリーニング、サイズの正規化、画像フィルタリング、画像強調、ノイズ除去、セグメンテーションなど）は、実装ロジックとともに記述されるべきである。

- iv. トレーニングの詳細（損失関数、最適化設定、トレーニングエポック）が提供されるべきである。
- v. モデルの一般化が良好であることを裏付ける検証指標と実環境テスト結果（精度、再現率）は、開示されるべきである。

(2) シナリオ2 既存モデルを利用した AI 利用発明

Scenario - 2:

クレームされた発明が、既に学習済みの AI モデルを主にベースとしている場合、入力データと出力データの相関関係を明確に定義することが重要である。AI モデルの学習済み動作と意図された技術的機能との間の相関関係を明確に記述するには、以下の点を考慮する必要がある。

- ・ モデルに使用される学習データ（その性質、固有の特性など）を明示的に特定する必要がある。
- ・ 学習データの特性と発明が対処する特定の技術的課題との間に明確な関連性を確立し、そのデータが課題解決に適している理由を説明する必要がある。
- ・ 具体的な学習モデル（例：ニューラルネットワークアーキテクチャ、アルゴリズムの種類）と学習方法（例：ハイパーパラメータ、最適化手法、学習期間、前処理手順）を包括的に記述する必要がある。
- ・ 学習されたモデルは、予測可能で信頼性の高い結果（通常は検証指標と実世界におけるテスト結果によって裏付けられる）によって技術的課題に効果的に対処できることが示されなければならない。

Example-10 (Hypothetical):

産業機械の故障予測システムに関する発明。

履歴センサーデータでトレーニングされたリカレントニューラルネットワーク (RNN) を使用する。このシステムは、一定間隔で収集された多変量時系列センサーデータ（温度、振動、速度）を分析するために、長短期記憶 (LSTM) 層を使用する。LSTM ネットワークアーキテクチャは、ドロップアウトおよびバッチ正規化を備えた 3 つの積層層を含む。入力はタービンからのセンサーログ（風力タービン SCADA データセット：風速、風向、出力などのデータを含む公開ラベル付きデータセット、つまり Kaggle データセット）であり、出力は、一定期間内に故障が発生するかどうかを示すバイナリラベルである。トレーニング方法には、Adam オプティマイザー、学習率スケジューリング、バイナリクロスエントロピー損失が含まれる。トレーニングされたモデルは、5 つのクロスバリデーションフォールド全体で非常に高い予測精度を達成する。

開示要件の充足性：

- i. トレーニングデータセット（風力タービン SCADA）は、センサーの詳細（種類、頻度、収集期間）とデータラベル付け方法とともに明確に識別される必要がある。
- ii. データセットと技術的タスク（例：機械故障の時系列予測）との相関関係を説明する必要がある。時系列データセットの特徴がどのように処理されているかを定義する必要がある。定常性、季節性、傾向などのパラメータが適切にテストされているかどうか、またテストされている場合は、これらの手順に関する情報を説明する必要がある。
- iii. LSTM のアーキテクチャの詳細（レイヤー数、時間ウィンドウ、ドロップアウト率）を明確に提供する必要がある。
- iv. トレーニングプロセス（損失関数、学習率、正則化）を明確に説明する必要がある。
- v. モデルが技術的問題を予測通りに解決することを示すパフォーマンス結果を提供する必要がある。

(3)シナリオ3 前処理に特徴のある発明

Scenario - 3:

クレーム発明において、データの前処理が重要な役割を果たす場合、前処理のすべてのステップと機能、ならびにそれらが最終モデルとどのように相関関係にあるかが開示される必要がある。この相関関係が明確に記載されておらず、当業者が生データと処理済み学習データとの関連性を理解するのに苦労する場合、クレームに係る発明は実施可能要件を満たさないリスクがある。

Example-11 (Hypothetical):

リモートセンシングおよび農業モニタリング、特に衛星画像とディープラーニングを用いた作物種別の分類に関する発明である。生の衛星データは分類前に複数の前処理段階を経る。前処理としては、Sen2Cor アルゴリズムを用いた大気補正、正規化植生指数（NDVI : Normalized Difference Vegetation Index）の算出、植生指数とテクスチャフィルタに基づく画像セグメンテーションなどである。処理後の画像は、作物種別の注釈が付与されたラベル付き区画で学習させた CNN

（EfficientNet）を用いて分類される。このモデルは X% の分類精度を達成し、前処理により生画像を用いた場合と比較して Y% のパフォーマンス向上が見込まれる。

開示要件の充足性：

- i. 大気補正（名前アルゴリズム）、NDVI 計算、セグメンテーションロジックなどの

- 詳細を含む、段階的な前処理パイプラインを記述する必要がある。
- ii. 前処理済みデータが未処理画像と比較してどのように分類性能を向上させるかを明確に説明する必要がある。
 - iii. 前述の CNN モデル構造 (EfficientNet) で使用される様々な実装パラメータとそれらの相互関係を開示する必要がある。
 - iv. トレーニングデータセットの特性 (特に前処理の課題に関連するもの) とラベリング手法を開示する必要がある。
 - v. 前処理の重要な効果を示す比較パフォーマンスベンチマークを開示する必要がある。

(4)シナリオ4 強化学習発明の場合

Scenario-4:

クレーム発明が強化学習に基づく場合、システムが環境とどのように相互作用するか、すなわちエージェントの相互作用、状態、行動、報酬などについて規定する必要がある。これには、エージェントの相互作用の詳細な記述が含まれ、学習エージェントが周囲をどのように観察し、影響を与えるかを明確に概説する必要がある。さらに、状態、行動、報酬は包括的に定義され、エージェントが知覚する環境の観察可能な特性、エージェントが実行可能な行動や決定の集合、そしてエージェントが学習を導くためのフィードバックを受け取るメカニズムと価値を詳細に規定する必要がある。これらの詳細を省略、または、当業者が推測できる方法で記述しない場合、発明が実施不可能となる可能性がある。

Example-12 (Hypothetical):

リアルタイム交通信号制御のための深層強化学習 (DRL) システムである「適応型都市交通最適化装置 (Adaptive Urban Traffic Optimizer、AUTO)」に関する発明である。AUTO は、畳み込みニューラルネットワークを用いた Deep Q-Network (DQN) を用いて交通カメラ映像を処理し、車両密度と渋滞長を状態として定義する。アクションには、信号タイミング (青/赤の点灯時間) の調整が含まれる。効果は、交通量に基づいて重み付けされた平均車両待ち時間の短縮として算出される。エージェント (中央サーバ) は、IoT プロトコルを介して交通信号と対話する。トレーニングにはシミュレートされた都市環境を使用し、実世界への展開のための転移学習を行う。AUTO は交通量を最適化し、渋滞と排出量を削減する。

開示要件の十分性:

- i. DQN アーキテクチャの開示は、入力処理 (例: 生のカメラ画像)、状態表現手法 (例: 車両密度、渋滞長、交通流率)、エージェントの行動空間 (例: 離散的または

連続的な信号タイミング調整)、および精密なアドバンテージ関数の計算 (例: 待ち時間短縮のための最適化) を含めて提供されるべきである。

ii. IoT ベースのエージェントと環境の相互作用は、環境観測のための具体的なセンサーの種類 (例: スマートカメラ、車両検知器) と、エージェントの影響のためのアクチュエータ機構 (例: スマート信号制御装置、道路標識) を含め、明確に記述されるべきである。

iii. トレーニング手法は、シミュレーション環境の設定とパラメータ (例: 使用する交通シミュレータ、規模)、および転移学習アプリケーションの詳細 (例: 使用する事前学習済みモデル、微調整戦略、ソースドメイン特性) を明確に開示する必要がある。

第 3 条(k)に基づく除外の対象から外れる可能性のある側面:

クレーム発明は、リアルタイムデータに基づいて信号タイミングを動的に調整することにより、車両の平均待ち時間を短縮し、都市交通の流れを最適化するものである。これにより、交通渋滞の緩和、燃料消費量の削減、そして CO2 排出量の削減が実現する。畳み込みニューラルネットワークを用いて複雑な交通パターンを処理することで、AUTO は多様な都市環境におけるスケーラビリティを実現し、輸送効率と環境の持続可能性を向上させる。

(5)シナリオ 5 ハードウェアの性能改善に関する AI 発明

Scenario-5:

クレーム発明がコンピュータの内部構造または動作の (主張される) 改良に基づく場合、基礎となるアルゴリズムがハードウェアまたはシステムアーキテクチャとどのように相互作用するかを説明する必要がある。これには、モデルがデータストレージ、スケジューリング、処理速度といった内部パフォーマンス指標をどのように最適化するかを具体的に示し、必要な技術的背景を提供することが含まれる。

Example-13 (Hypothetical):

オペレーティングシステム (OS) カーネルの最適化、より具体的にはニューラルネットワークを用いたタスクスケジューリング方法に関する発明である。本発明は、軽量ニューラルネットワークモデルを OS カーネルに統合し、入力特性 (スレッド優先度、キャッシュヒット率、CPU 使用率) に基づいて、タスク実行に最も効率的な CPU コアを予測する。2 層多層パーセプトロンモデルアーキテクチャは、プロファイリングデータを用いて学習される。このモデルは、Linux Completely Fair Scheduler (CFS) のデフォルトのヒューリスティックに代わるものである。評価では、ベンチマークテスト全体で平均レイテンシが X%削減され、スループットが

Y%向上することが示された。

開示要件の充足度：

- i. 入力特徴（スレッド優先度、コア統計）の正確な定義と選択根拠を提供し、モデルが関連するシステム状態をどのように認識し、最適化の決定に活用するかを説明する必要がある。
- ii. ニューラルネットワークのアーキテクチャ（レイヤー、アクティベーション、学習方法）を説明する必要がある。
- iii. Linux CFS との統合については、システムコールまたはカーネルフックレベルで、CPU 構成および OS との互換性範囲とともに説明する必要がある。
- iv. 学習データソース（該当する場合）と前処理手法を公開する必要がある。
- v. パフォーマンス結果（レイテンシとスループット）を検証する必要がある。

(6)シナリオ 6 トレーニングデータセットに特徴のある発明

Scenario-6:

クレームされた発明の発明性が学習データセットの特定の特性に依存する場合、当業者が過度の実験（undue experimentation）なしにそれらの特性を特定できる場合を除き、これらの特性を開示する必要がある。これは、これらのデータ特性がモデルの機能や解決する問題に不可欠であるためである。データが特定のドメインからのものであるかどうか、その多様性、正確なラベル付け手法、あるいは固有の特性などの詳細を含める必要がある。ほとんどの場合、膨大な量や機密性を要する可能性のある特定のデータセット自体ではなく、データの定義特性を記述するだけで十分である。

Example-14 (Hypothetical):

高齢者の顔認識精度の問題に対処するための発明である。特に医療および安全監視アプリケーションにおいて、しわ、たるみ、一般的な咬合など、様々な老化の特徴を含む 65~90 歳の個人で構成されるデータセットを用いて、顔認識モデルを特別にトレーニングする。データセットの属性は、照明、ポーズ、アクセサリー（例：眼鏡）の多様性である。顔認識には、年齢を考慮した埋め込み損失を備えた、事前トレーニング済みの深層畳み込みニューラルネットワークモデルである修正 FaceNet アーキテクチャを使用する。このモデルは、一般的なデータセットでトレーニングされたベースラインモデルの Y% ($X > Y$) と比較して、高齢者の被験者に対して X% の認識精度を達成する（データセットの特定の特性/特徴が重要なイノベーションである）。

開示要件の十分性：

- i. 効果に重要なデータセット特性（年齢分布、高齢者の顔の特徴、遮蔽）の説明を開示する必要がある。
- ii. 一般的な顔データセットでは不十分な理由と、特定のデータセット特性がモデル性能にどのように影響するかを説明する必要がある。
- iii. ニューラルネットワークアーキテクチャ（FaceNet バリエント）を示し、修正点（年齢加重損失）を説明する必要がある。
- iv. データセットの選択による大幅な改善を示す、ベースラインモデルとの定量的な比較を提供する必要がある。

(7)シナリオ7 アルゴリズムに特徴のある発明と、アルゴリズムではなく用いるデータまたは新たな利用方法に特徴のある発明との記載要件の対比

シナリオ 7(a): 発明が、アルゴリズム学習の技術的実装である場合。

シナリオ 7 (b): 発明が、データエンジニアリングとその使用法の場合。

Scenario-7:

クレーム発明の発明性が新しい学習アルゴリズムの実装にある場合、その特定のアルゴリズムの包括的な説明（その独自の要素、数学的基礎、および動作手順を含む）は、開示の十分性にとって絶対に不可欠である。しかし、発明の核心がアルゴリズムの実装自体ではなく、標準的または既知のアルゴリズムであっても画期的な結果を達成できるデータセットを作成、キュレーション、または具体的に利用する新しい方法にある場合、開示の焦点は革新的なデータ中心のプロセスの詳細に移り、共通アルゴリズムは、発明的に準備されたデータを活用するためのツールとしてのみ機能する。

Scenario-7(a):

Example-15 (Hypothetical):

クレーム発明は、作物分類のための新たなディープラーニングアルゴリズムの機能に革新性があることを開示している。これには、追加のアテンション機構（例：Squeeze-and-Excitation ブロック、または Spatial Attention モジュール）を備えた改良型 EfficientNet などのカスタムニューラルネットワークアーキテクチャが含まれる。この新しいニューラルアーキテクチャは、衛星データからの時間パターン学習（例：季節変化をモデル化するために時間的畳み込みまたは Transformer レイヤーを組み込む）の改善をもたらす。モデルは、収束性、汎化性、またはノイズ耐性を向上させる最適化手法（例：カスタム損失関数またはトレーニングスケジュール）を採用している。クレームは、マルチスペクトル画像から季節を跨いで高解像

度の作物種別特徴を、このレベルの精度または効率で効果的に抽出できる従来のモデルは存在しないというものである。

開示要件の充足性：

クレーム発明は、実現要件を満たすために、アルゴリズム／アーキテクチャの以下の技術的詳細を開示する必要がある。

- i. 完全なアーキテクチャレイアウト：層ごとの図、入力次元と出力構造、パラメータ数、具体的な関数（例：ReLU、GELU）など。
- ii. 学習プロトコル：損失関数、最適化装置、バッチサイズ、エポック数、データ拡張戦略。
- iii. ベンチマーク：既知のデータセットにおける性能比較。

Scenario – 7 (b):

Example-16 (Hypothetical):

本発明は、作物の種類分類のために、高忠実度、高一貫性、かつ独自に調和された、複数季節・複数ソースの衛星画像データセットを生成する自動化システムである。本システムは、動的なクロスセンサーキャリブレーション、インテリジェントな時間スタッキングおよびギャップフィリングアルゴリズム、そして AI 支援による革新的なラベル検証および競合解決技術を含む独創的なパイプラインを実装することにより、複雑な衛星データと一貫性のない地上ラベルに内在する課題に対処する。この独自のデータ作成およびキュレーションプロセスは、後続の分類アルゴリズムではなく、多様な農業地域において前例のない高精度な作物分類を直接的に可能にし、農業監視および意思決定システムを大幅に改善する。

開示要件の十分性：

- i. クレーム発明は、データ処理操作のシーケンス、および発明が展開される特定の環境またはアプリケーションを含むデータパイプラインと使用コンテキストを開示する必要がある。ただし、アルゴリズムは一般的な記述または簡潔な記述にとどめることができる。
- ii. これらの特定の手順と手法が革新的であり、望ましいデータ品質と特性を達成するために必要である理由に関する技術的な根拠を詳細に提供する必要がある。
- iii. 検証方法（例：従来の方法で処理されたデータでトレーニングされたモデルとの比較）の実証を提供する必要がある。

7a および 7b で議論された発明が、第 3 条(k)に基づく除外の対象から外れる可能

性のある側面：

クレーム発明は、マルチスペクトル衛星画像から季節を跨いで高解像度の作物種別特徴を高精度かつ効率的に抽出することを可能にする。これにより、農業モニタリング、資源管理、および意思決定システムの技術的性能が直接的に向上し、より正確な土地利用マッピング、収量推定、および最適化された農業慣行が可能になる。