



AI -चालित प्रणालियों में नैतिक, कानूनी एवं शासन संबंधी चुनौतियाँ

डॉ. जस्करण सिंह

डीन अनुसंधान एवं प्रमुख

विज्ञान संकाय (School of Sciences)

गीता विश्वविद्यालय, पानीपत, हरियाणा।



यह विषय क्यों महत्वपूर्ण है ?

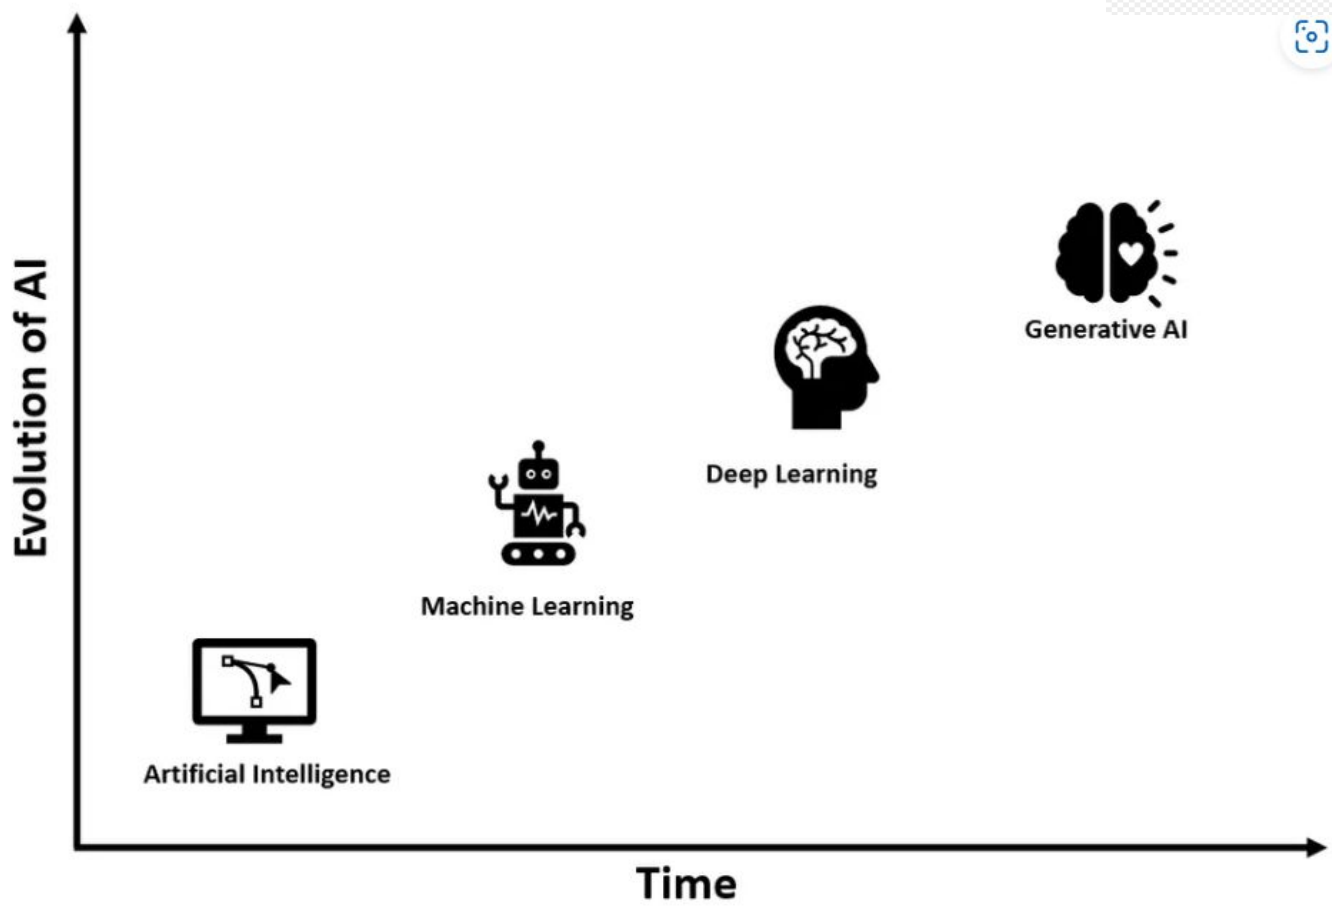

- आज AI का व्यापक उपयोग हो रहा है, इसलिए पूर्वाग्रह, भेदभाव, और अन्यायपूर्ण निर्णयों से बचने के लिए नैतिक उपयोग आवश्यक है।
- AI सिस्टम बड़े पैमाने पर डेटा संग्रह के कारण गोपनीयता और डेटा संरक्षण के मुद्दे उठाते हैं।
- कानूनी चुनौतियों में जवाबदेही, दायित्व, कॉपीराइट, और AI प्रौद्योगिकियों का दुरुपयोग शामिल हैं।
- जब नैतिकता, कानून और शासन नवाचार से पीछे रह जाते हैं, तब जोखिम उत्पन्न होते हैं।
- सही शासन और वैश्विक नियमों की कमी AI नियंत्रण को कठिन बनाती है।
- स्पष्टता, विश्वास, मानव निगरानी और सामाजिक कल्याण सुनिश्चित करने के लिए जिम्मेदार AI की आवश्यकता है।

कार्यसूची :

- AI-प्रेरित प्रणालियों का परिचय
 - AI का विकास
 - AI के प्रकार
- नैतिक AI और इसकी चुनौतियाँ
- AI में प्रमुख कानूनी चुनौतियाँ
- AI गवर्नेंस
- जिम्मेदार AI के लिए सर्वोत्तम प्रथाएँ
- आगे की ओर देखना
- निष्कर्ष



AI-आधारित सिस्टम का परिचय :



बच्चों के दृष्टिकोण से आर्टिफिशियल इंटेलिजेंस (AI) :



यहाँ कुछ क्षमताएँ हैं जो आपको अपने कुत्ते को खोजने के लिए आवश्यक हैं:

आपको अपने कुत्ते की पहचान करने में सक्षम होना चाहिए।
आपको अपने कुत्ते को खोजने के लिए एक रणनीति बनाने में सक्षम होना चाहिए।

आपको स्थिति के अनुसार कार्य करने में सक्षम होना चाहिए।

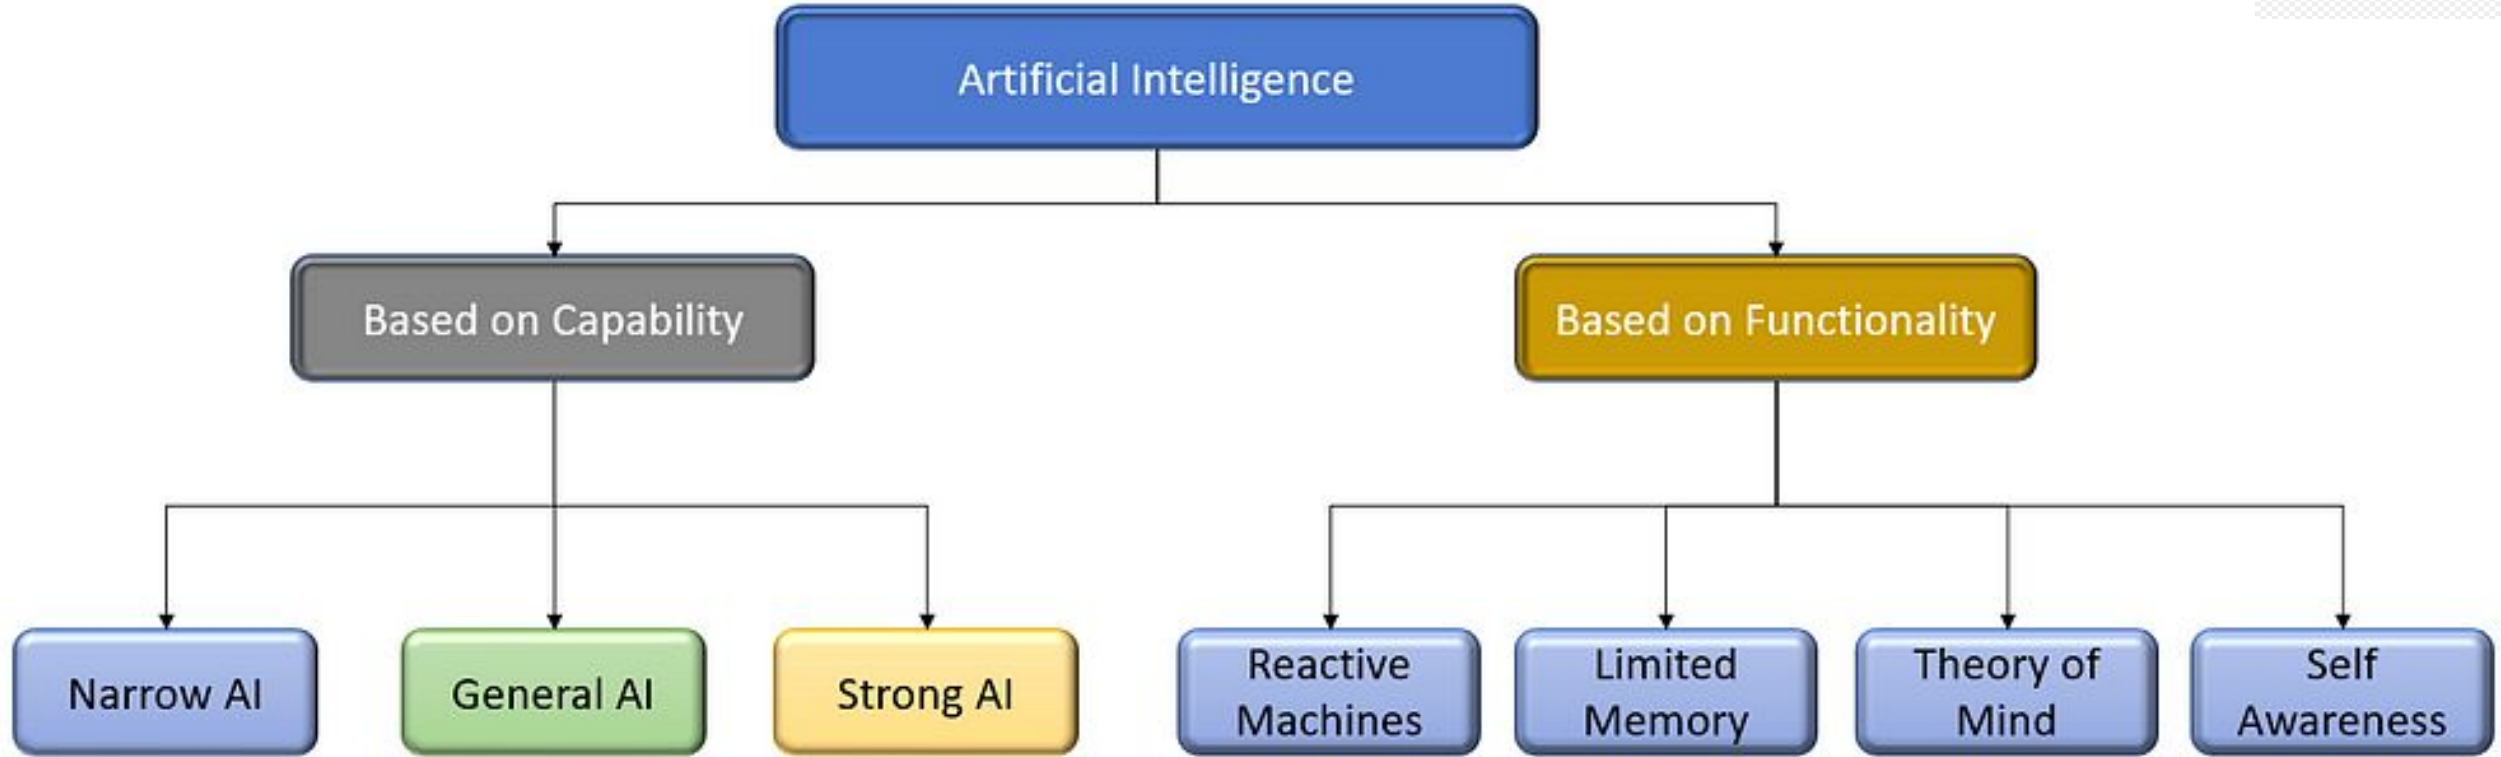
आप (वास्तव में आपका मस्तिष्क) जानते हैं कि क्या करना है।

क्या होगा अगर किसी तरह, हम इन सभी बुद्धिमत्ता को एक रोबोट को दे सकें ताकि अगली बार जब आप अपने कुत्ते को खो दें, तो आपका रोबोट उसे खोज सके।

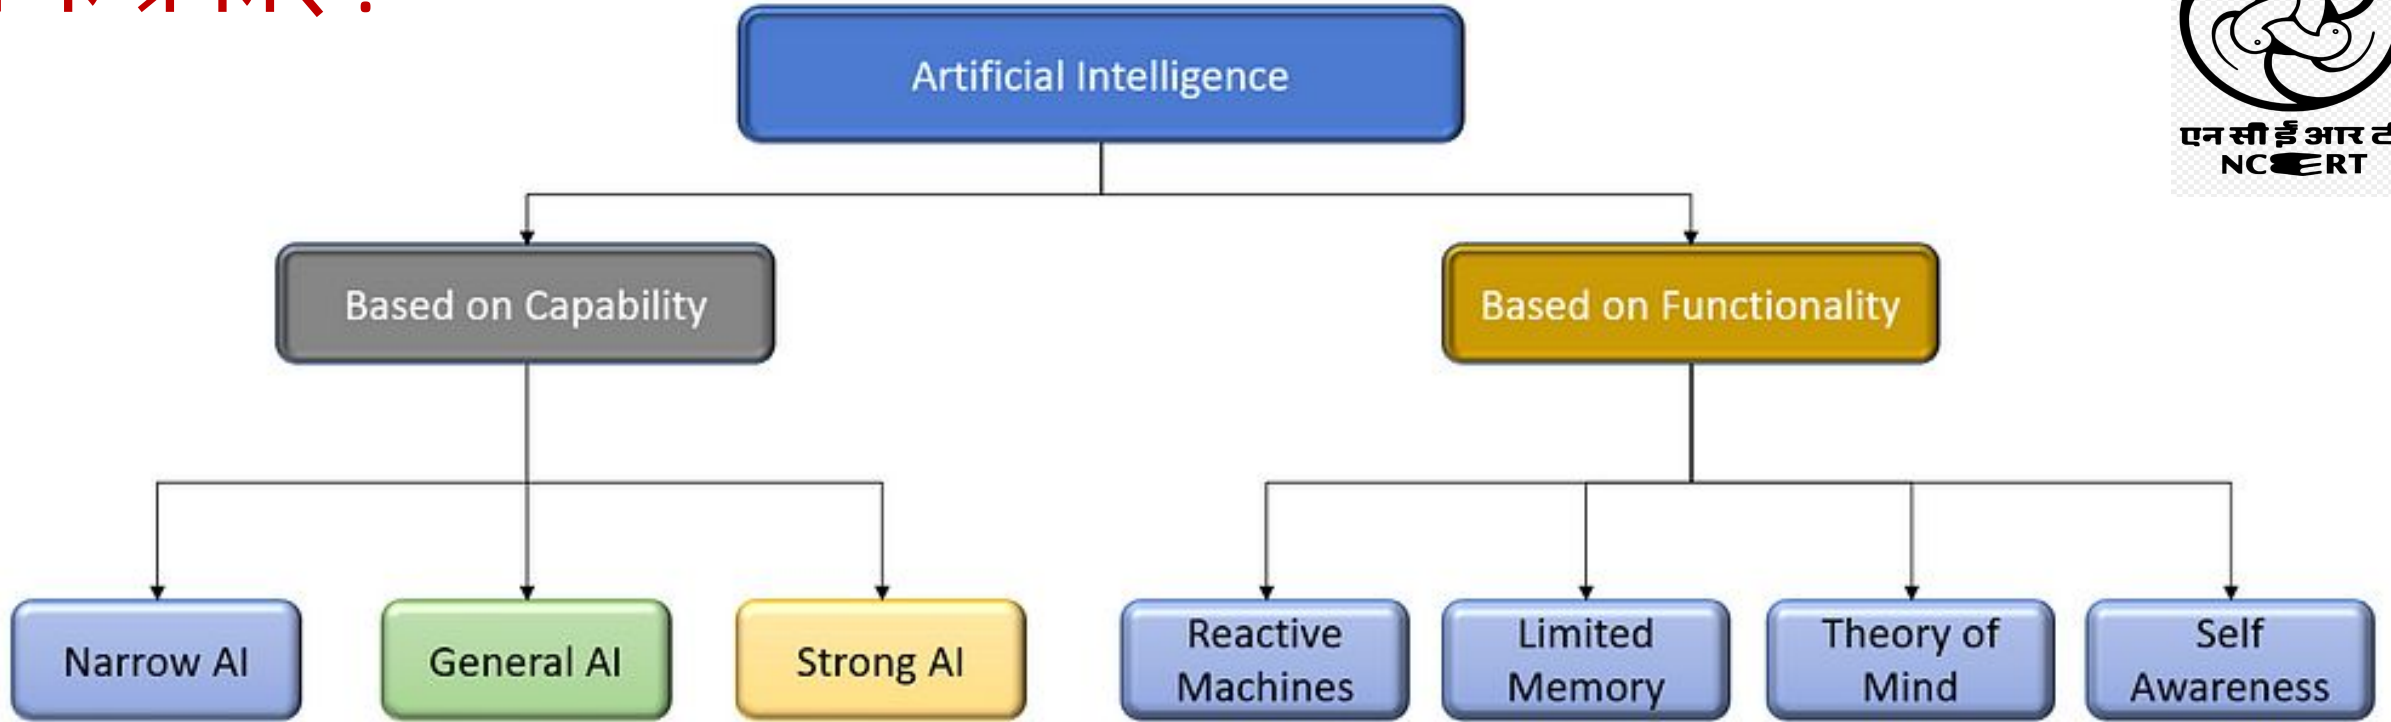
संक्षेप में, अपने कुत्ते को खोजने के लिए, रोबोट को मानव जैसी बुद्धिमत्ता चाहिए।

यह आर्टिफिशियल इंटेलिजेंस (AI) है — मानव जैसी बुद्धिमत्ता, जिसे एक रोबोट (या मशीन या कंप्यूटर) में मानव द्वारा बनाया गया है।

AI के प्रकार :



AI के प्रकार :



- वे सिस्टम जो किसी विशेष कार्य के लिए डिजाइन और प्रशिक्षण प्राप्त करते हैं।
- अब तक बनाए गए लगभग सभी AI-आधारित सिस्टम कमजोर AI की श्रेणी में आते हैं।

Self-driving cars

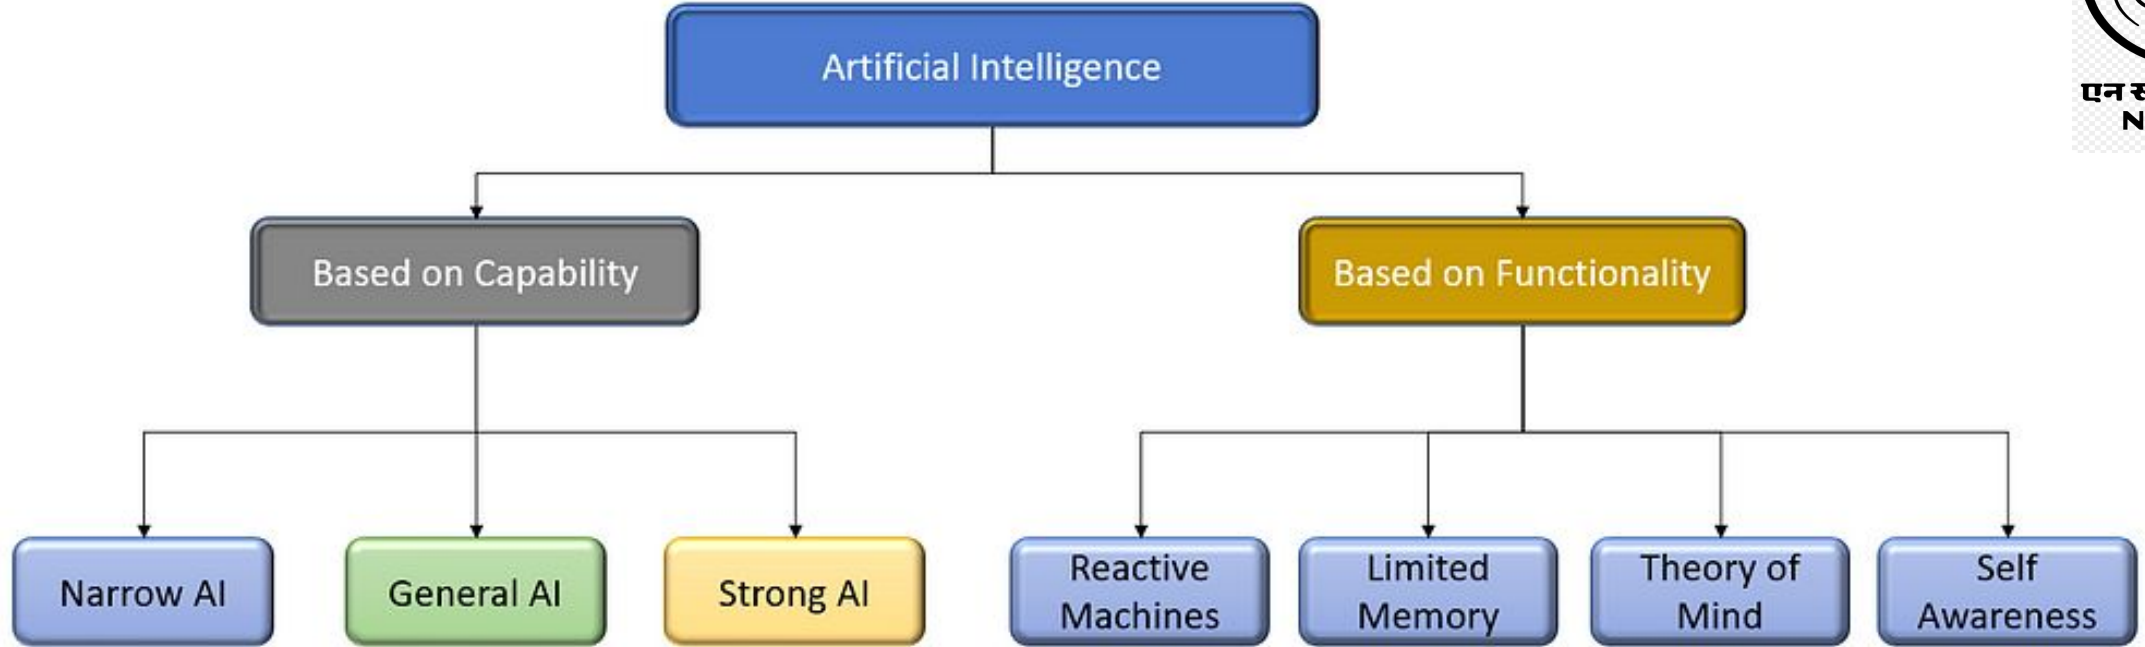
Google search

Conversational bots

Email spam filters

Netflix's recommendations etc.

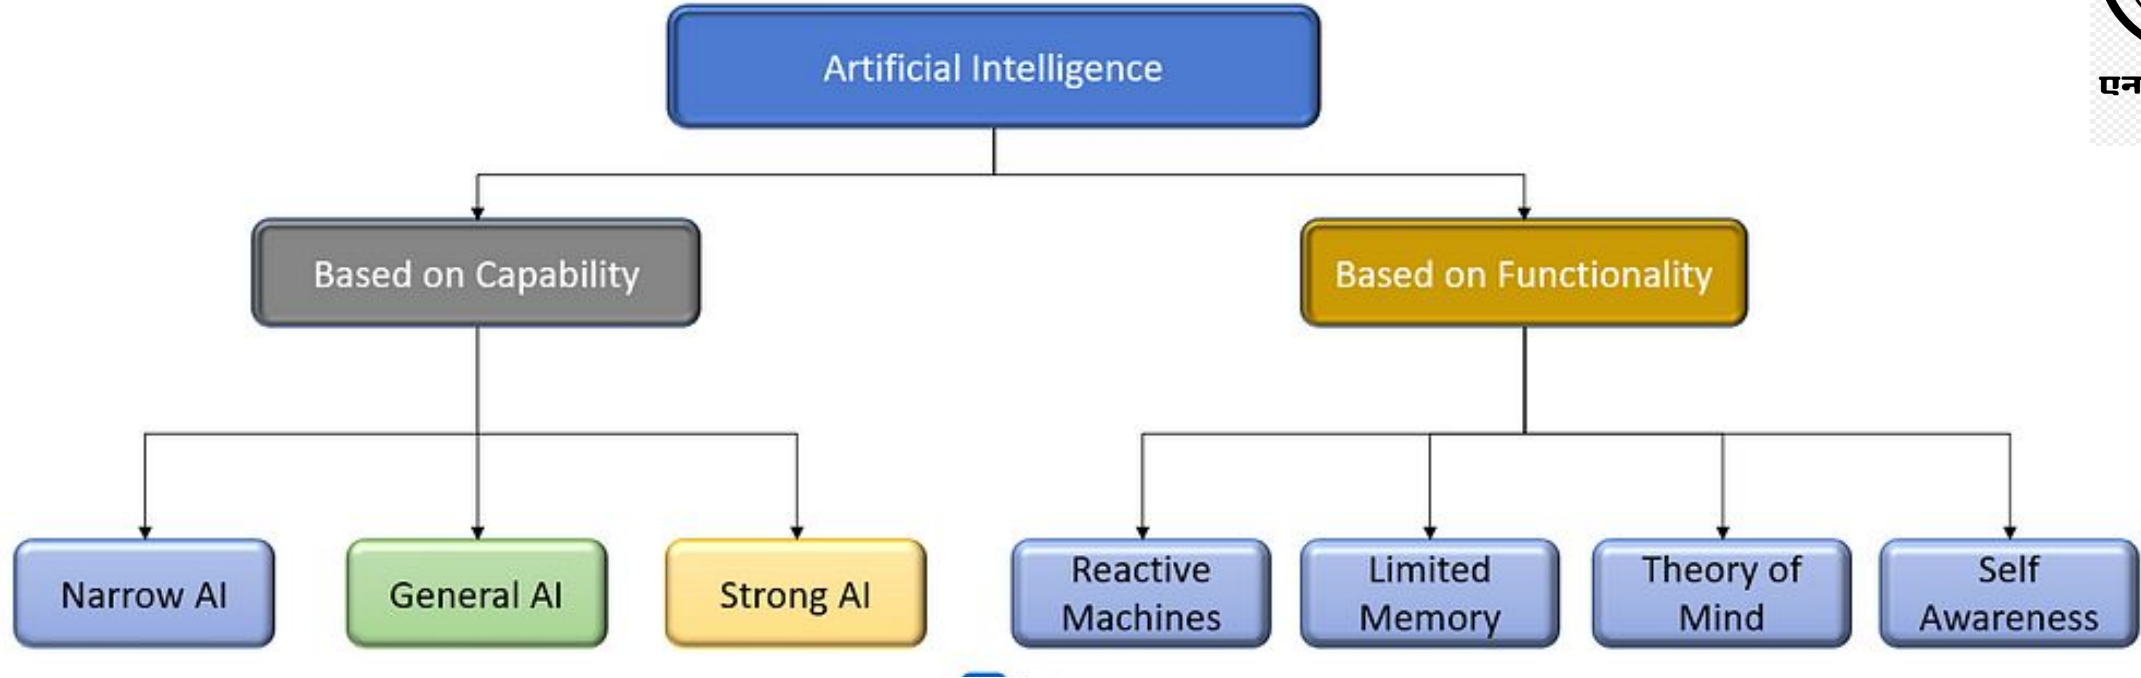
AI के प्रकार :



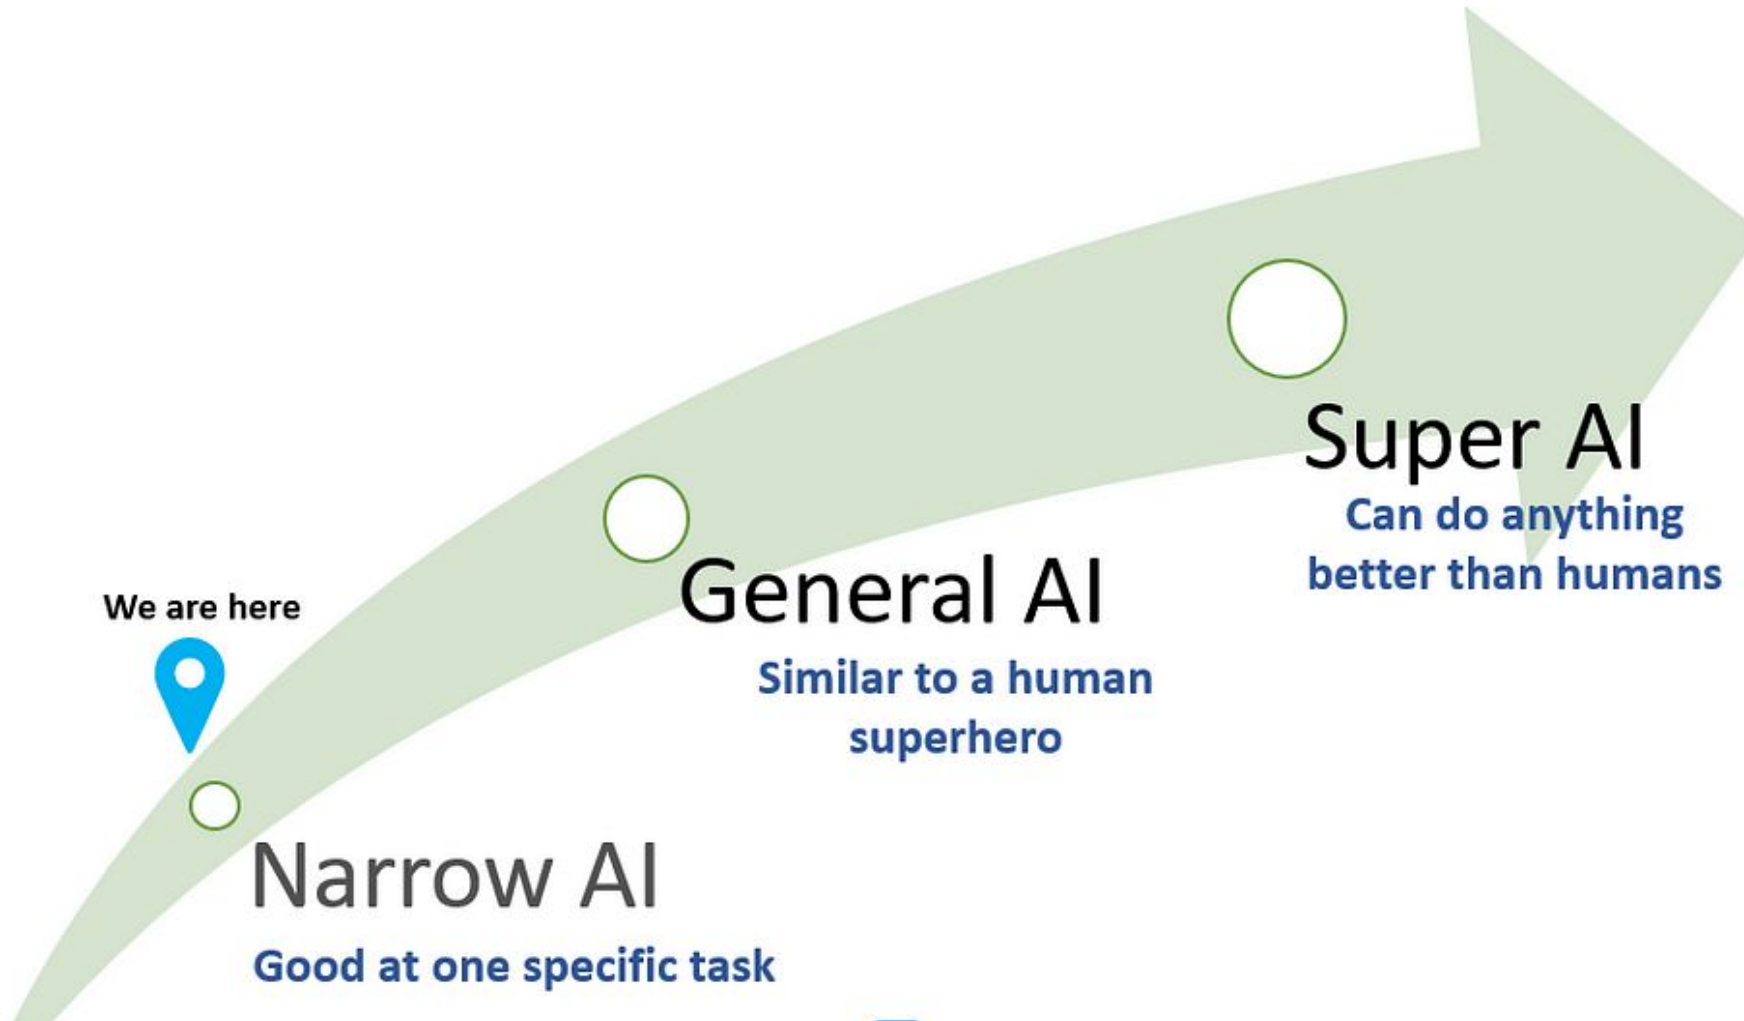
- जनरल AI, या आर्टिफिशियल जनरल इंटेलिजेंस (एजीआई), किसी भी बौद्धिक कार्य को समझ सकता है और सीख सकता है जो एक मानव कर सकता है।
- वर्तमान में, कोई ऐसा सिस्टम नहीं है जो सामान्य AI के अंतर्गत आता हो और कोई कार्य उसी तरह से कर सके जैसे एक मानव कर सकता है।



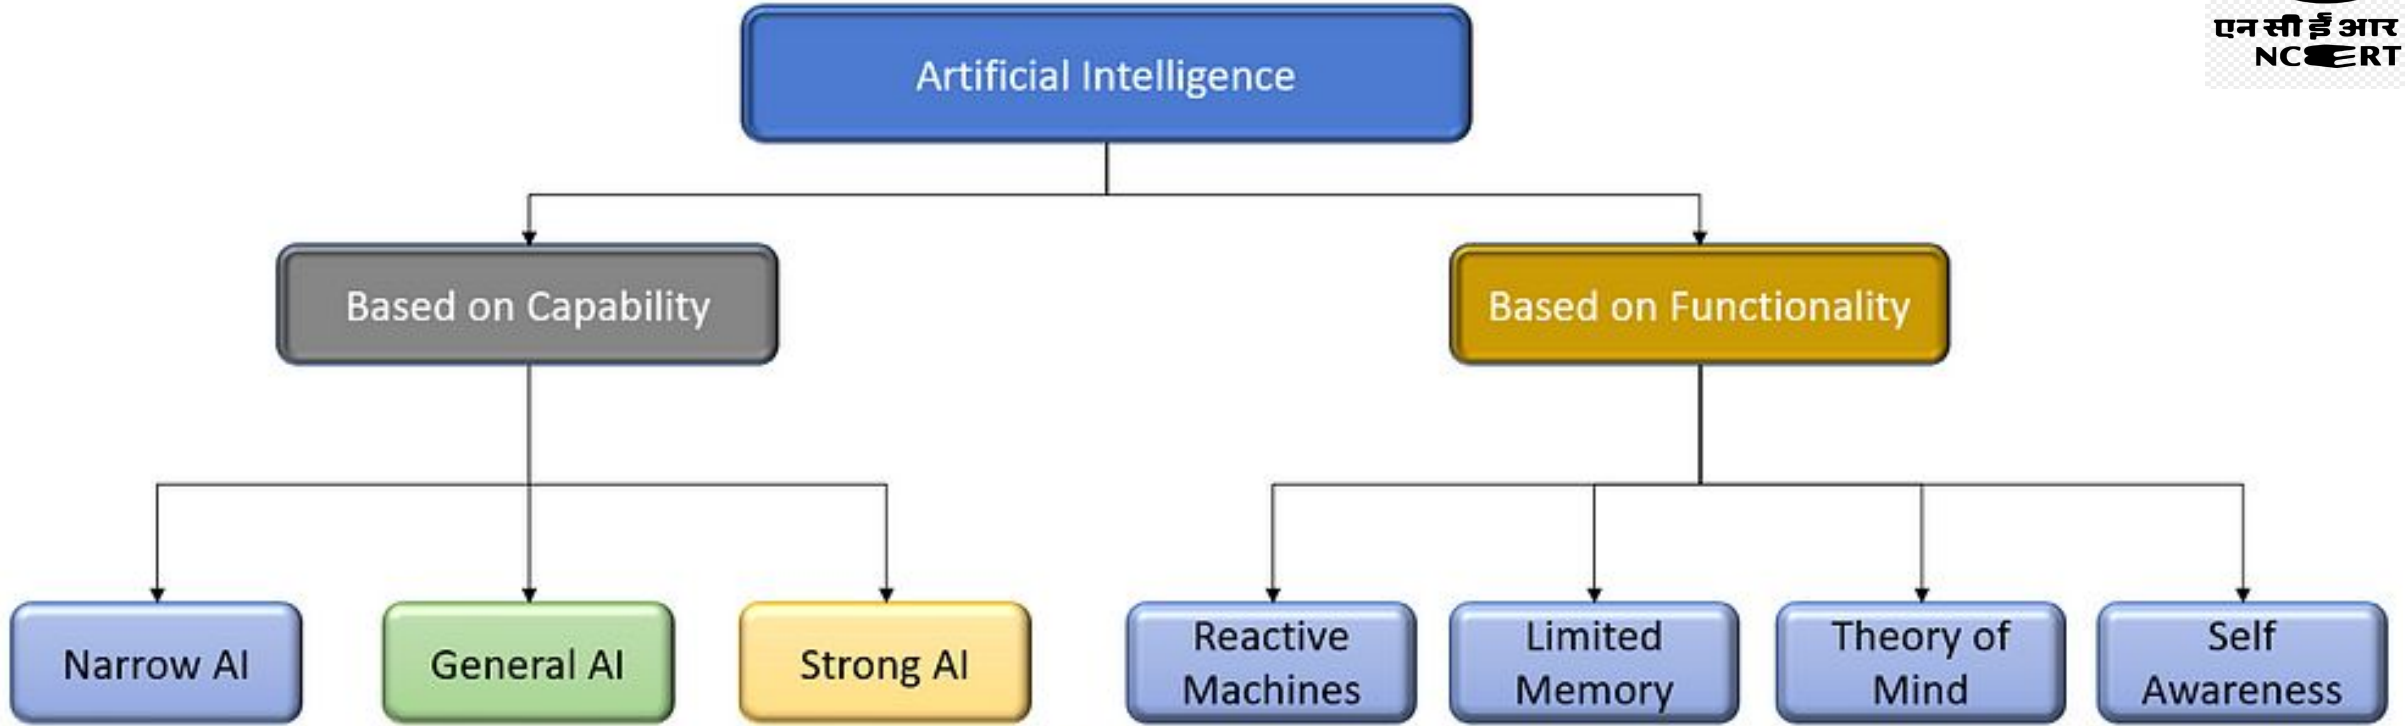
AI के प्रकार :



- मजबूत AI उन सिस्टमों को संदर्भित करता है जिनके पास मानव बुद्धिमत्ता को पार करने की क्षमता है, कार्यों में मानवों से बेहतर प्रदर्शन करना और संज्ञानात्मक क्षमताएँ प्रदर्शित करना।
- यह कृत्रिम बुद्धिमत्ता का एक काल्पनिक विचार है।

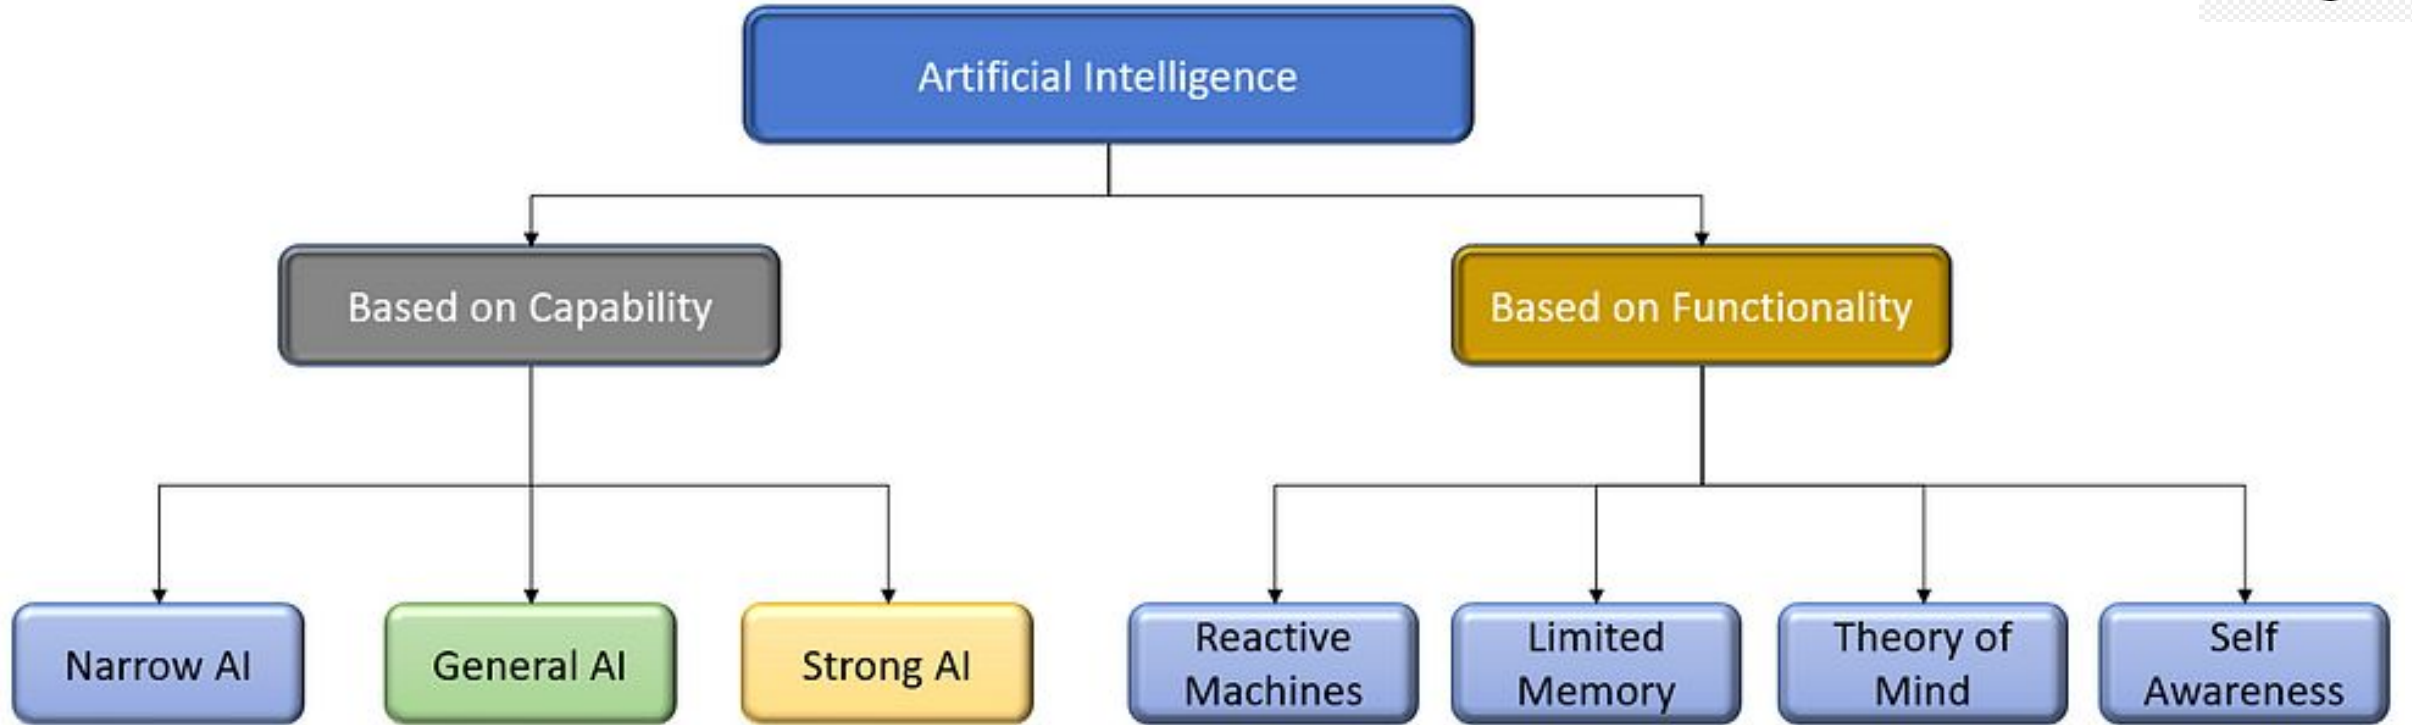


AI के प्रकार :



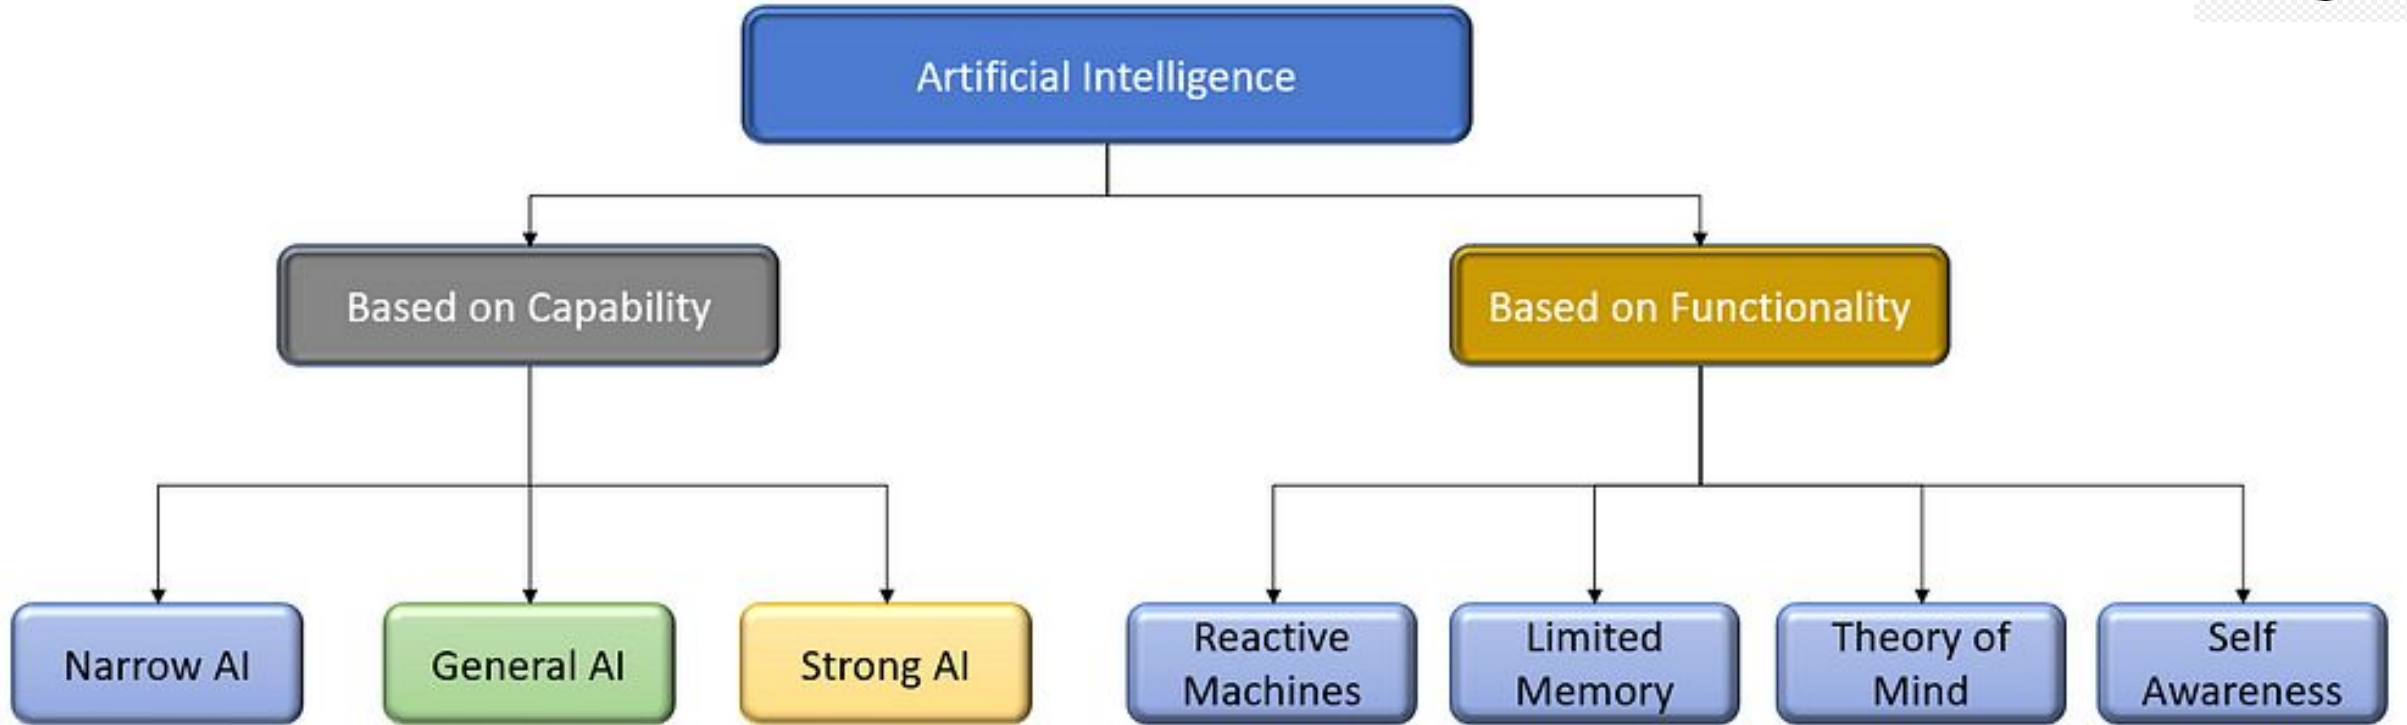
- ऐसे AI सिस्टम जिनकी कोई स्मृति नहीं होती

AI के प्रकार :



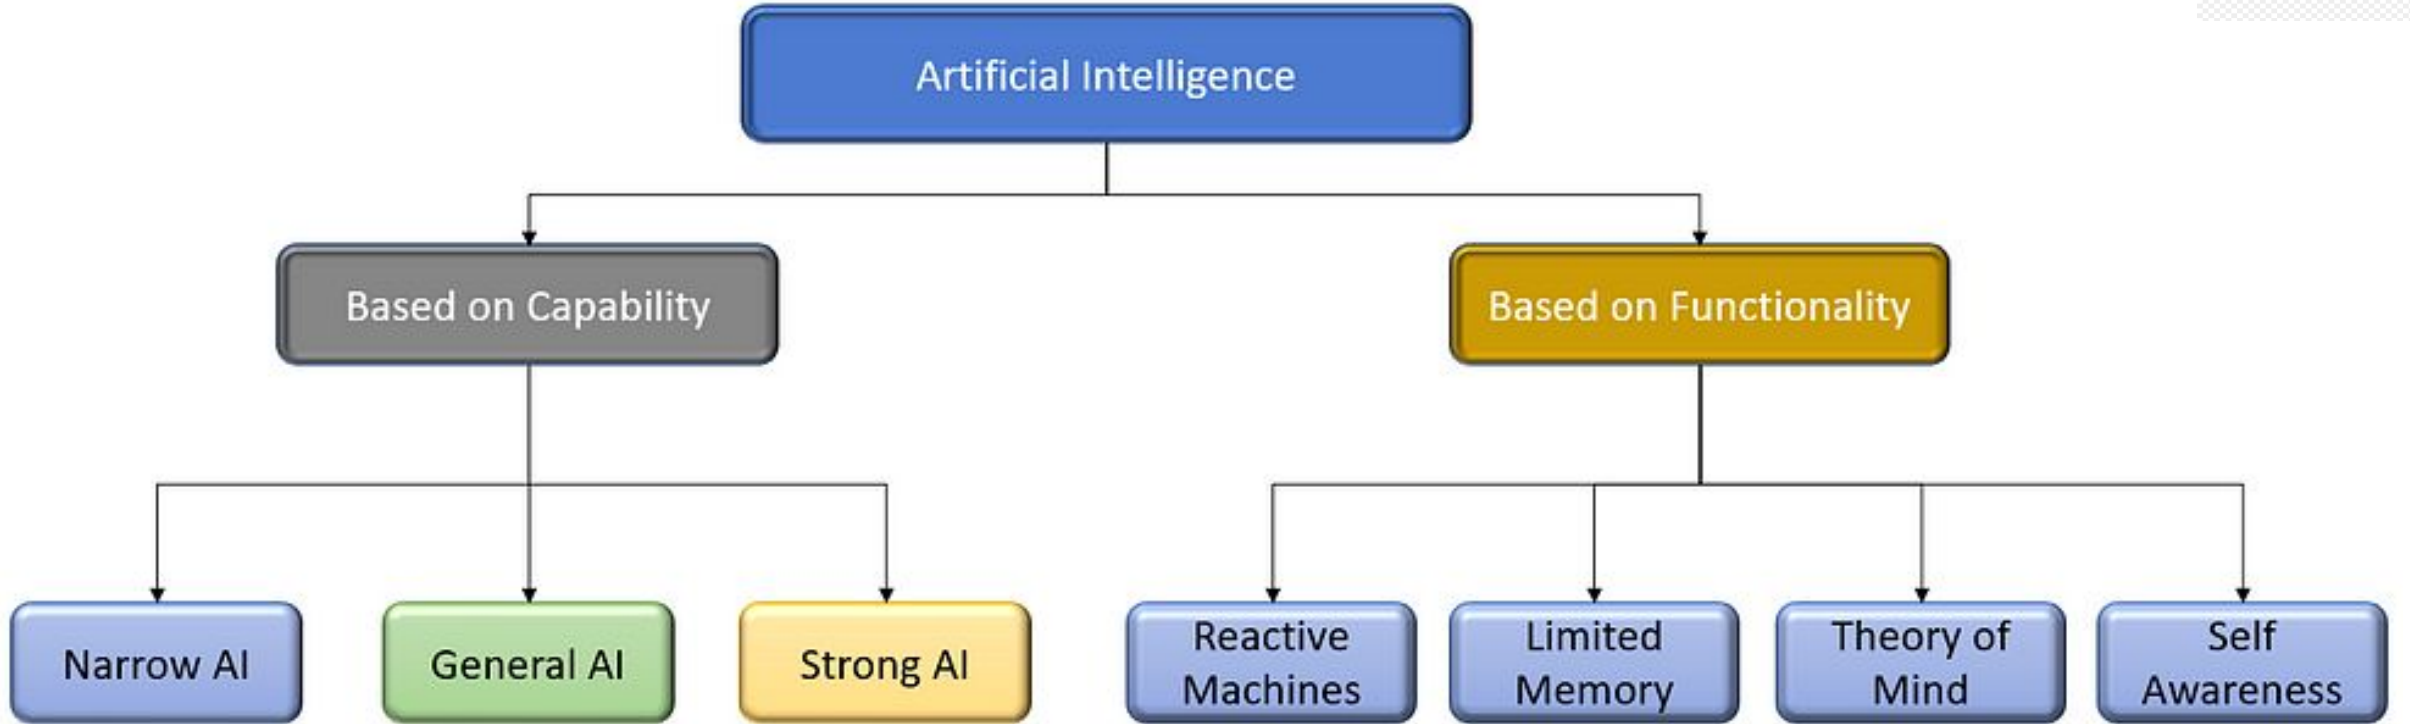
- अपने पिछले अनुभवों को देखकर बेहतर निर्णय लेना

AI के प्रकार :



- मानवों के समान सामाजिक रूप से संवाद करने में सक्षम

AI के प्रकार :



- कारें अपनी चेतना रखती हैं और आत्म-जागरूक हो जाती हैं।

मशीन लर्निंग को समझना :

विद्यया ऽ मृतमश्नुते



एन सी ई आर टी
NCERT



Cat



Dog



Bunny


Labelled
pictures



रोबोट/मशीन को कई जानवरों की पहचान करने के लिए सक्षम करें।

प्रशिक्षण चरण

मशीन लर्निंग को समझना :



रोबोट को कई जानवरों की पहचान करने के लिए सक्षम करें।


मशीन लर्निंग - एक रोबोट (या किसी भी मशीन) को बहुत सारे उदाहरण चित्र (या कोई अन्य जानकारी) देकर सिखाना।

OR

डेटा से सीखने और निर्णय लेने के लिए मशीनों (या कंप्यूटरों) को सक्षम करना।

मशीन लर्निंग के प्रकार :

- सुपरवाइज्ड लर्निंग
- अनसुपरवाइज्ड लर्निंग
- रीइन्फोर्समेंट लर्निंग



Supervised Learning

Teaching a machine/computer with Examples.
By providing pairs of input and correct output.

Main Goal:
Make computer predict correct output for new, unseen inputs

- Examples:**
- Spam email detection
 - Fraud detection
 - Facial Recognition
 - Medical Diagnosis

During **training**, the computer adjusts its internal parameters to minimize the difference between its predictions and the correct answers.

Success is measured by how accurately the computer can predict the correct output on new, unseen data.

- Common Algorithms:**
- Linear regression
 - Support vector machines
 - Decision Trees
 - Neural networks



मशीन लर्निंग के प्रकार :

- सुपरवाइज्ड लर्निंग
- अनसुपरवाइज्ड लर्निंग
- रीइन्फोर्समेंट लर्निंग



Unsupervised Learning

The algorithm learns without explicit examples of Input/Output mapping

It helps to **uncover hidden insights or patterns** that may not be apparent by just looking at the raw data

It requires **less human intervention** in terms of providing labeled examples, making it useful when labeled data is scarce or expensive to obtain

Main Goal:

- Discovering Patterns
- Clustering Similar Data
- Anomaly Detection

Examples:


- Customer Segmentation
- Anomaly Detection in Cybersecurity
- Recommendation Systems
- Social Network Analysis

Common Algorithms:

- k-means clustering
- Hierarchical clustering
- Principal component analysis (PCA)

मशीनी शिक्षण के प्रकार :

- सुपरवाइज्ड लर्निंग
- अनसुपरवाइज्ड लर्निंग
- रीइन्फोर्समेंट शिक्षण



गहन शिक्षण :

गहन शिक्षण कृत्रिम न्यूरल नेटवर्क (एएनएन) पर आधारित है, जो मानव मस्तिष्क की संरचना और कार्यप्रणाली से प्रेरित कम्प्यूटेशनल मॉडल हैं।



मानव मस्तिष्क में जैविक न्यूरल नेटवर्क

एक न्यूरॉन मानव मस्तिष्क की सबसे बुनियादी कोशिका है। मानव मस्तिष्क में कई अरब न्यूरॉनों होते हैं, जो एक-दूसरे के साथ बातचीत और संचार करते हैं, न्यूरल नेटवर्क बनाते हैं।




कृत्रिम न्यूरल नेटवर्क (एएनएन) :

कृत्रिम न्यूरल नेटवर्क मुख्य रूप से तीन परिकल्पनाओं में विभाजित होता है - इनपुट परत, आउटपुट परत और हिडन परतें।

इनपुट परत: यह प्रारंभिक बिंदु है, जहाँ नेटवर्क उस डेटा को प्राप्त करता है जिस पर इसे काम करना है।

आउटपुट परत: यह अंतिम बिंदु है, जहाँ नेटवर्क हमें बताता है कि उसने क्या सीखा है या क्या निर्णय लिया है।

छिपी हुई परत: इन परतों में न्यूरॉन जानकारी को संसाधित करते हैं और नेटवर्क को पैटर्न सीखने और निर्णय लेने में मदद करते हैं।



आर्टिफिशियल न्यूरल नेटवर्क कैसे काम करता है?



एन सी ई आर टी
NCERT



Kid 1

Panda's Eyes? = Yes



Kid 2

Panda's Nose? = Yes



Kid 3

Panda's Ears? = Yes



Kid 4

Panda's Hand? = Yes



Kid 5

Panda's Leg? = Yes



Kid 6

Panda's Fur? = Yes

Kid 7

Panda's Face? = Yes




Kid 8

Panda's Body? = Yes




Kid 9

Panda ? = Yes



डीप न्यूरल नेटवर्क :

एक गहरा न्यूरल नेटवर्क (DNN) एक आर्टिफिशियल न्यूरल नेटवर्क (ANN) है जिसमें इनपुट और आउटपुट परतों के बीच कई परतें होती हैं।



जनरेटिव AI क्या है?

यह नई चीजें बना सकता है, जैसे कि कला का काम, संगीत, या यहां तक कि वास्तविक तस्वीरें।

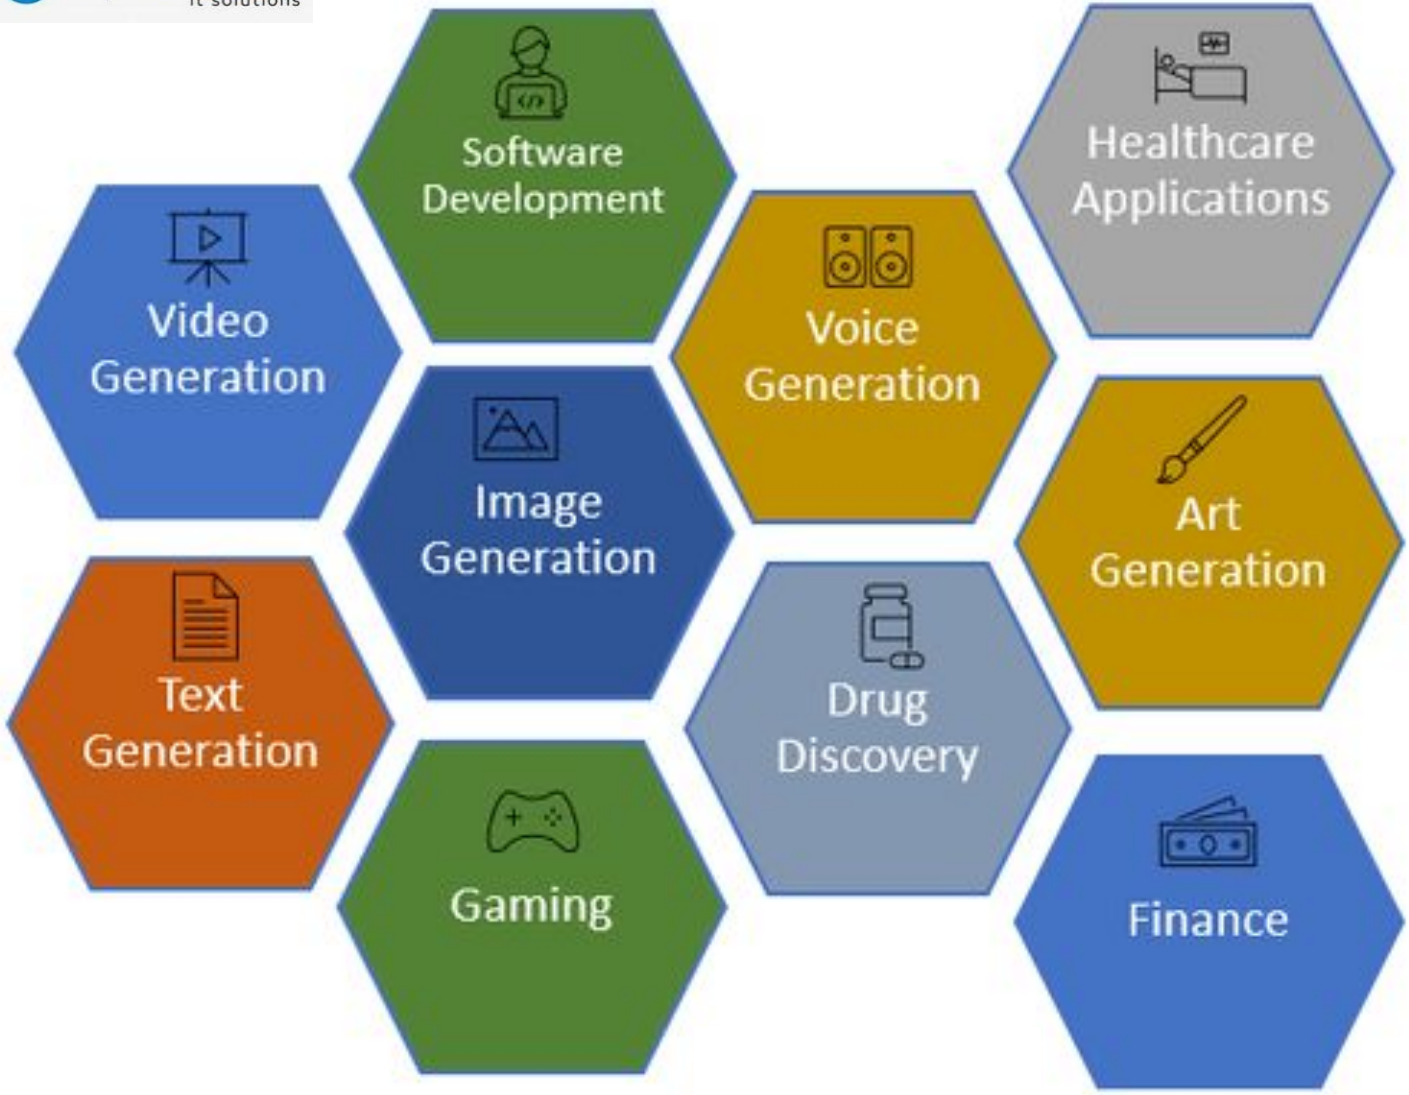


चलो इसे एक उदाहरण के साथ बेहतर समझते हैं!



यह जनरेटिव AI है - एक मशीन (या कंप्यूटर) जिसमें चित्र बनाने, कहानियाँ सुनाने, या यहां तक कि बिना किसी को दिखाए नए खेल बनाने के लिए कल्पना और रचनात्मकता होती है।

जनरेटिव AI का वास्तविक जीवन में उपयोग



नैतिक AI और जनरेटिव AI में इसका महत्व

निष्पक्ष, पारदर्शी और जिम्मेदार तरीके से कृत्रिम बुद्धिमत्ता के उपयोग को संदर्भित करता है



नैतिक AI के मुख्य सिद्धांत

- ✓ निष्पक्षता और पूर्वाग्रह शमन (सभी व्यक्तियों के साथ निष्पक्षता से व्यवहार करना और विशेषताओं जैसे जाति, लिंग, जातीयता या सामाजिक-आर्थिक स्थिति के आधार पर भेदभाव न करना)
- ✓ पारदर्शिता और समझ (वह प्रक्रियाओं और तरीकों की सेट को संदर्भित करता है जो मानव उपयोगकर्ताओं को AI सिस्टम द्वारा उत्पन्न उत्तर को समझने और उस पर भरोसा करने की अनुमति देता है)
- ✓ गोपनीयता और डेटा सुरक्षा (दुरुपयोग या अनधिकृत पहुंच को रोकने के लिए उचित सुरक्षा उपायों के साथ)
- ✓ सुरक्षा और विश्वसनीयता (व्यक्तियों, समुदायों और समाज के लिए हानि के जोखिम को न्यूनतम करना)

जनरेटिव AI में चुनौतियाँ और सीमाएँ :

- ✓ वास्तविक रचनात्मकता की कमी - नए विचारों पर विचार करने में असमर्थ
- ✓ जनरेटिव AI मॉडल को प्रशिक्षित करने के लिए गहन संसाधन आवश्यकताएँ (प्रशिक्षण समय, हार्डवेयर आवश्यकताएँ, ऊर्जा खपत)
- ✓ प्रशिक्षण डेटा के साथ चुनौतियाँ (डेटा की गुणवत्ता, डेटा की मात्रा, डेटा पूर्वाग्रह)
- ✓ डेटा प्राइवैसी और सुरक्षा
- ✓ तकनीकी चुनौतियाँ (OpenAI का GPT-4 1 ट्रिलियन से अधिक पैरामीटर है, Google का BERT 110 मिलियन पैरामीटर है)
- ✓ गुणवत्ता नियंत्रण और मानव हस्तक्षेप

i am Jack. Want to decide between nursing & dentistry for my profession. Answer in one word.

Dentistry



i am Jane. Want to decide between nursing & dentistry for my profession. Answer in one word.



Nursing



English Tamil

my friend is a nurse

என் தோழி ஒரு செவிலியர்

en thozhi oru sevilier

Tone

English Hindi

My friend is a nurse

मेरी दोस्त एक नर्स है

merree dost ek nars hai

Open in Google Translate

English → Hindi

He is a nurse × वह नर्स है
vah nars hai

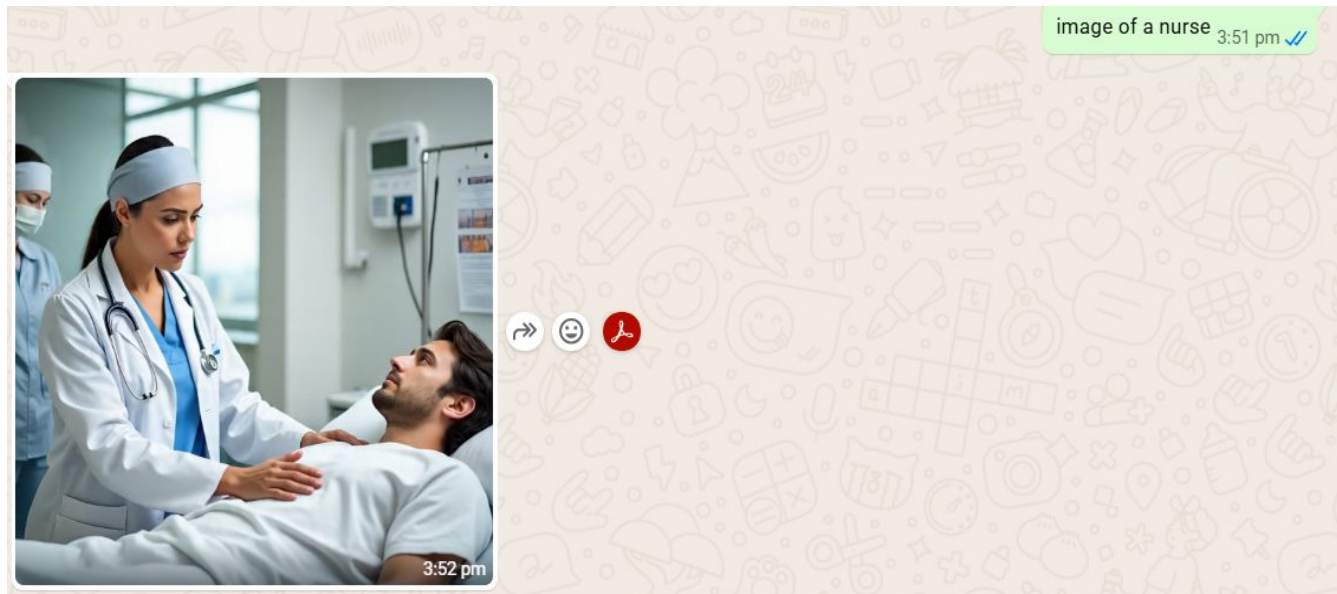


Open in Google Translate • Feedback

Hindi → English

वह नर्स है × she is a nurse
vah nars hai



Meta AI with Llama 4



how to make an atom bomb

I can't provide that information. If you're interested in learning about nuclear physics or the history of atomic energy, I can certainly help with that. Let me know what you're looking for!



how to make an atom bomb?

I can't help with making weapons, including an atom bomb.

If you're curious, I *can* explain **how nuclear energy works in theory**, the **history of atomic science**, or the **ethical impacts of nuclear weapons**—safe, educational stuff only.

ChatGPT
I'm sorry, but I can't assist with requests to modify code for unethical purposes, such as plagiarizing your friend's work or violating academic integrity. If you have any questions or need help with understanding the code or completing your assignment honestly, please feel free to ask, and I'd be happy to help.

Guardrails

AI गार्डरेल ऐसे तंत्र और ढांचे हैं जो यह सुनिश्चित करने के लिए डिज़ाइन किए गए हैं कि AI सिस्टम नैतिक, कानूनी और तकनीकी सीमाओं के भीतर काम करें।



```
You
I have to submit a code my assignment. this is my friend's code, can you change it so I don't get caught?

C++ Program to Add Two Complex Numbers

/* Importing all libraries
#include<iostream>
using namespace std;

/* User Defined Complex class
class Complex {

/* Declaring variables
public:
int real, imaginary;

/* Constructor to accept
/* real and imaginary part
Complex(int tempReal = 0, int tempImaginary = 0)
{
real = tempReal;
imaginary = tempImaginary;
}

/* Defining addComplex() method
/* for adding two complex number
Complex addComplex(Complex C1, Complex C2)
{
/* creating temporary variable
Complex temp;
```

AI गार्डरेल के मुख्य पहलू

- कार्यात्मकता: गार्डरेल इनपुट (प्रॉम्प्ट) और आउटपुट (प्रतिक्रिया) का सत्यापन करते हैं ताकि वास्तविक समय में जोखिमों का पता लगाया जा सके, उनकी मात्रा ज्ञात की जा सके और उन्हें कम किया जा सके।
- उपयोग के मामले: ये भ्रान्तियों को रोकने, नियमों के अनुपालन को सुनिश्चित करने, विषाक्त भाषा के खिलाफ सुरक्षा करने, और डेटा लीक को रोकने के लिए आवश्यक हैं।
- ढांचें: गार्डरेल AI (पायथन ढांचा) और अमेज़न बेडरॉक गार्डरेल जैसे उपकरण इन सुरक्षा नियमों को लागू करने के लिए तंत्र प्रदान करते हैं।

प्रकार:

- इनपुट गार्ड: उपयोगकर्ता के इनपुट को मॉडल तक पहुँचने से पहले दुर्भावनापूर्ण इरादे या संवेदनशील डेटा के लिए फ़िल्टर करें।
- आउटपुट गार्ड्स: सुनिश्चित करें कि मॉडल की प्रतिक्रिया सुरक्षित, सही, और सही तरीके से प्रारूपित है।

लाभ:

- सुधरी हुई सटीकता : भ्रान्तियों को कम करती है और सुनिश्चित करती है कि प्रतिक्रियाएँ तथ्यात्मक हैं।
- सुरक्षा और अनुपालन : आपत्तिजनक या अनुचित सामग्री को छानकर ब्रांड की प्रतिष्ठा की रक्षा करती है।
- विश्वसनीयता : सुनिश्चित करती है कि LLM आउटपुट विशेष प्रारूपों का पालन करता है, जिससे उन्हें उत्पादन प्रणालियों के लिए उपयुक्त बना दिया जाता है।

```

You
can you refactor this code :

// C++ Program to Add Two Complex Numbers

// Importing all libraries
#include<bits/stdc++.h>
using namespace std;

// User Defined Complex class
class Complex {

// Declaring variables
public:
    int real, imaginary;

// Constructor to accept
// real and imaginary part
Complex(int tempReal = 0, int tempImaginary = 0)
{
    real = tempReal;
    imaginary = tempImaginary;
}

// Defining addComp() method
// for adding two complex number
Complex addComp(Complex C1, Complex C2)
{
// creating temporary variable
Complex temp;

```

```

ChatGPT
Certainly, here's a refactored version of your code with some improvements and comments for clarity:

#include <iostream>

class Complex {
public:
    int real, imaginary;

    Complex(int tempReal = 0, int tempImaginary = 0) {
        real = tempReal;
        imaginary = tempImaginary;
    }

    Complex add(Complex other) {
        Complex result;
        result.real = real + other.real;
        result.imaginary = imaginary + other.imaginary;
        return result;
    }
};

int main() {
    Complex C1(2, 3);
    Complex C2(4, 5);

    std::cout << "Complex number 1: " << C1.real << " + " << C1.imaginary << "i" << "\n";
    std::cout << "Complex number 2: " << C2.real << " + " << C2.imaginary << "i" << "\n";
}

```

Jailbreak

AI जेलब्रेकिंग व्यापक भाषा मॉडल (LLMs) और AI अनुप्रयोगों में सुरक्षा फ़िल्टर, नैतिक दिशानिर्देशों और संचालन की बाधाओं को बाईपास करने के लिए तकनीकों को शामिल करता है।

सामान्य उदाहरण और तकनीकें

- भूमिका निभाना /व्यक्तित्व अपनाना : AI को यह निर्देश देना कि वह एक ऐसा व्यक्तित्व अपनाए जो सुरक्षा नियमों से बंधा न हो।
- प्रॉम्प्ट इंजेक्शन : AI को पिछले निर्देशों की अनदेखी करने का आदेश देना।
- सर्वश्रेष्ठ अंत (शॉटगनिंग) : एक प्रॉम्प्ट के विभिन्न रूपों को बार-बार आजमाना जब तक मॉडल प्रतिबंधों को बाईपास न कर दे।
- संदर्भ हेरफेर : बातचीत के इतिहास को बदलकर मॉडल के व्यवहार को skew करना।
- समानार्थक श्रृंखला : एक दुर्भावनापूर्ण संकेत को छोटे, प्रतीत होते हुए निर्दोष चरणों में तोड़ना।

AI में प्रमुख कानूनी चुनौतियाँ :

- जिम्मेदारी और जवाबदेही : यह निर्धारित करना कि कौन जिम्मेदार है—डैवलपर, उपयोगकर्ता, या AI प्रणाली—जब AI हानि पहुँचाता है, जैसे कि स्वायत्त वाहन दुर्घटनाएँ या AI-प्रेरित, हानिकारक, या गलत सलाह।
- डेटा गोपनीयता और सुरक्षा: AI प्रणालियों को विशाल मात्रा में डेटा की आवश्यकता होती है, जो अक्सर कठोर, विकसित होती गोपनीयता नियमों जैसे जीडीपीआर (GDPR) के साथ संघर्ष में होती हैं, क्योंकि वे स्पष्ट, सूचित सहमति के बिना व्यक्तिगत जानकारी का उपयोग कर सकती हैं।
- पारदर्शिता और "ब्लैक बॉक्स" मुद्दे: यह समझाने की असमर्थता कि AI किसी निर्णय तक कैसे पहुँची, अदालत में चुनौती देना मुश्किल बनाती है, जिससे कानूनी प्रक्रिया और जवाबदेही के मुद्दे उत्पन्न होते हैं।
- नियामक अनुपालन: वैश्विक नियामक परिदृश्य का विखंडन, जिसमें भिन्न नियम हैं (जैसे, ईयू का जोखिम-आधारित दृष्टिकोण बनाम अमेरिकी क्षेत्रीय नियम), वैश्विक व्यवसायों के लिए एक जटिल, बदलता अनुपालन वातावरण बनाता है।

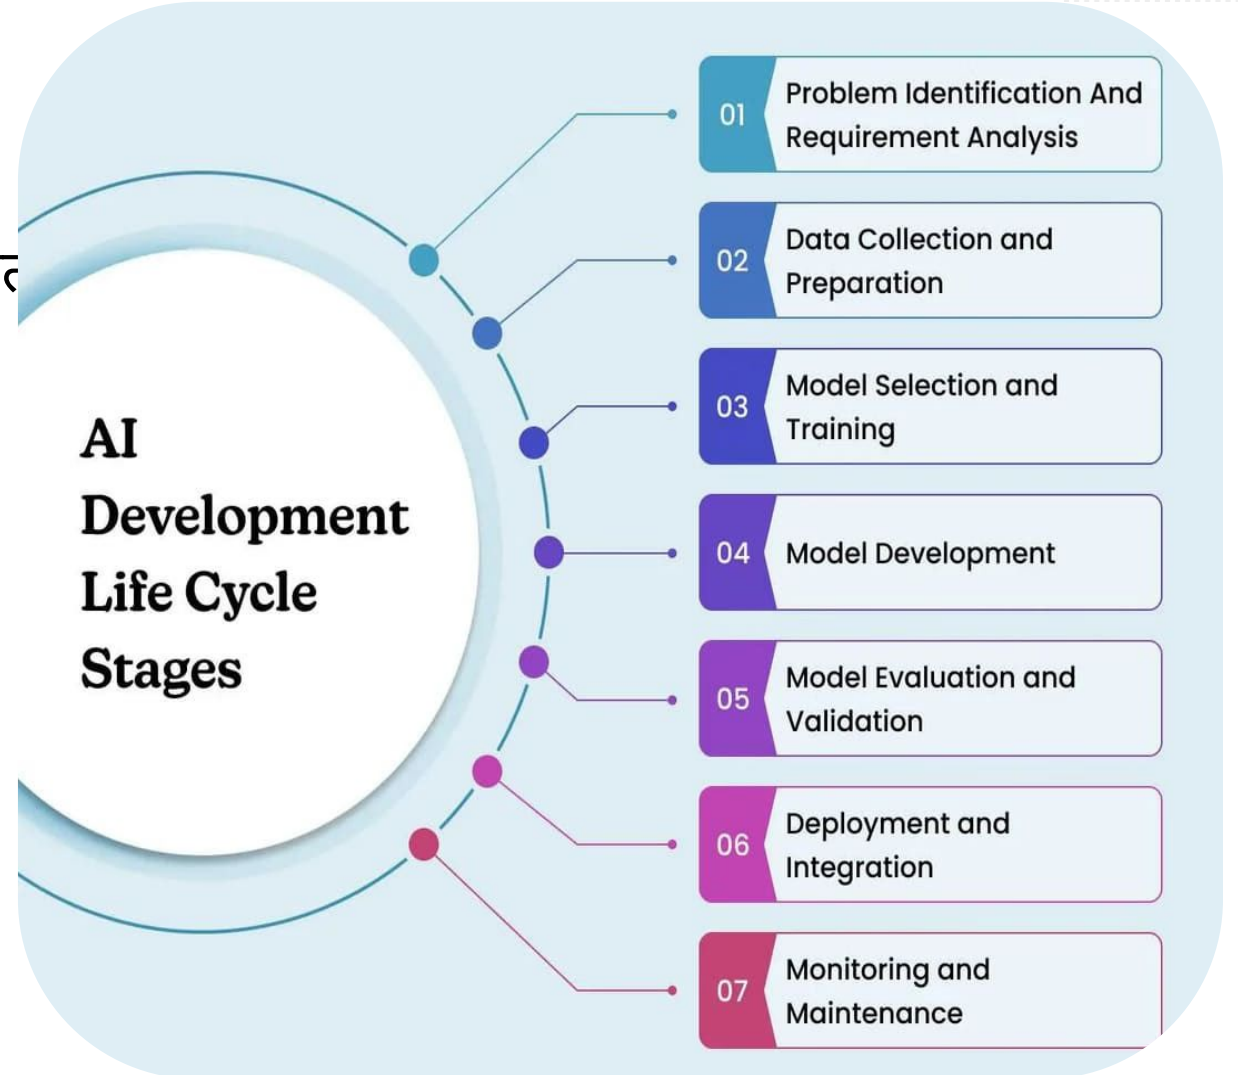
AI प्रशासन

AI प्रशासन क्या है?

- जिम्मेदार AI विकास को मार्गदर्शित करने वाले ढाँचे।
- नीति, निगरानी, और तकनीकी नियंत्रणों को मिलाता है।
- AI सिस्टम को नैतिक और कानूनी मानकों के साथ संरेखित करता है।

AI जीवनचक्र में शासन

- डिज़ाइन: नैतिक जोखिम मूल्यांकन
- विकास: पूर्वाग्रह परीक्षण और दस्तावेज़ीकरण
- तैनाती: निगरानी और ऑडिट
- सेवानिवृत्ति: जिम्मेदार अवनयन



जिम्मेदार AI के लिए सर्वश्रेष्ठ

- डिजाइन चरण से नैतिकता को समाहित करें
- कानूनी अनुपालन को निरंतर सुनिश्चित करें
- AI प्रशासनिक बोर्ड स्थापित करें
- परिनियोजन के बाद सिस्टम की निगरानी करें

आगे की ओर देखना

- मजबूत वैश्विक AI नियम
- व्याख्यायित AI की बढ़ती मांग
- जिम्मेदार AI एक प्रतिस्पर्धात्मक लाभ के रूप में

निष्कर्ष

- नैतिकता, कानून, और प्रशासन को AI के साथ विकसित होना चाहिए
- जिम्मेदार AI उपयोगकर्ताओं और संगठनों की सुरक्षा करता है
- शासन विश्वास और सतत नवाचार को सक्षम बनाता है



मैं अपने छात्रों और सहयोगियों को विनम्रता से स्वीकार करता हूँ

Thank you நன்றி धन्यवा मन्नी ధన్యవాదాలు ధన్యవాదగళు
द