



# elektor **BONUS**

design > share > earn

ÉDITION

8H  
DEPUIS 1961

## TA s'invite à la rédaction

Articles pour les pros, les makers et les étudiants !

### Raspberry Pi AI Camera



### l'IA pour la conception de produits

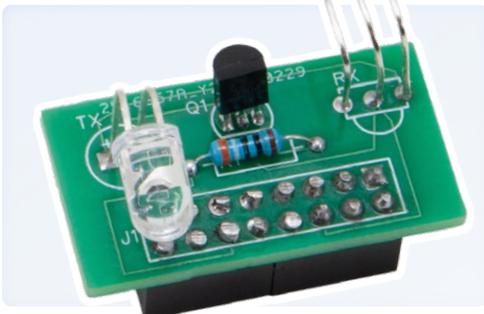
le monde des générateurs d'art IA

### 50 termes de l'IA pour les ingénieurs et les électroniciens

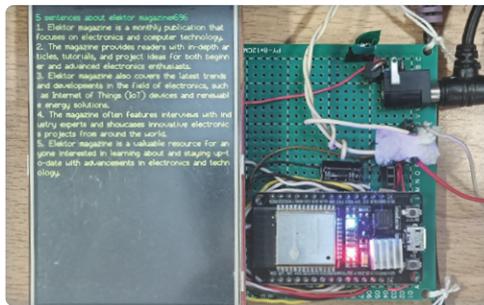


### Edge AI haute performance

le nouveau STM32N6



**télécommande universelle IR**  
contrôle gestuel avec MediaPipe et Raspberry Pi



**un terminal d'IA personnel**  
donner une voix à ChatGPT



**Hailo AI Kit avec Raspberry Pi 5**  
la détection d'objets en toute simplicité

# VOUS AVEZ DE LA CHANCE !



TÉLÉCHARGEZ  
GRATUITEMENT

Un abonné à l'e-zine ne manque jamais  
le mensuel «reverse project»

Vous n'êtes pas encore abonné ? Inscrivez-vous à  
notre e-zine gratuit à [elektormagazine.fr/ezine-24](http://elektormagazine.fr/ezine-24)





47<sup>ème</sup> année n° 510B  
Édition bonus spéciale IA  
ISSN 0181-7450

N° de TVA Intracommunautaire : FR90319937454

Dépôt légal : novembre 2024  
CPPAP 1125 T 83713

Directeur de la publication : Donatus Akkermans

Elektor Magazine est publié 8 fois par an par  
PUBLITRONIC SARL – c/o Regus Roissy CDG  
1, rue de la Haye – BP 12910  
FR - 95731 Roissy CDG Cedex  
www.elektor.fr | www.elektormagazine.fr

Directeur du contenu, Elektor: C. J. Abate

Pour toutes vos questions : service@elektor.fr

Devenez membre : www.elektormagazine.fr/abo

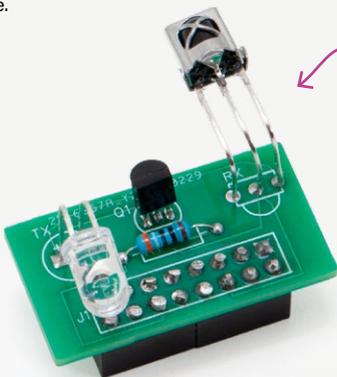
Publicité : Ouafae Hassani  
Tél. : +31 (0)6 41312932  
ouafae.hassani@elektor.com  
www.elektormagazine.fr/publicité

Tarifs Annuels :  
France 1 an 129,95 € (8 numéros)

Droits d'auteur  
© 2024 Elektor International Media B.V.

Toute reproduction ou représentation intégrale ou partielle, par quelque procédé que ce soit, des pages publiées dans la présente publication, faite sans l'autorisation de l'éditeur est illicite et constitue une contrefaçon. Seules sont autorisées, d'une part, les reproductions strictement réservées à l'usage privé du copiste et non destinées à une utilisation collective, et, d'autre part, les analyses et courtes citations justifiées par le caractère scientifique ou d'information de l'oeuvre dans laquelle elles sont incorporées (Loi du 11 mars 1957 - art. 40 et 41 et Code Pénal art. 425).

Certains circuits, dispositifs, composants, etc. décrits dans cette revue peuvent bénéficier de droits propres aux brevets; la Société éditrice n'accepte aucune responsabilité du fait de l'absence de mention à ce sujet. Conformément à l'art. 30 de la Loi sur les Brevets, les circuits et schémas publiés dans Elektor ne peuvent être réalisés que dans des buts privés ou scientifiques et non commerciaux. L'utilisation des schémas n'implique aucune responsabilité de la part de la Société éditrice. La Société éditrice n'est pas tenue de renvoyer des articles qui lui parviennent sans demande de sa part et qu'elle n'accepte pas pour publication. Si la Société éditrice accepte pour publication un article qui lui est envoyé, elle est en droit de l'amender et/ou de le faire amender à ses frais; la Société éditrice est de même en droit de traduire et/ou de faire traduire un article et de l'utiliser pour ses autres éditions et activités, contre la rémunération en usage chez elle.



## Plus de projets et articles sur l'IA

Pensiez-vous vraiment que notre exploration de l'IA s'arrêterait avec la publication de l'édition 2024 spéciale IA du magazine Elektor ? Bien au contraire ! Comme nos lecteurs assidus le savent bien, chez Elektor, nous développons continuellement de nouveaux projets, tutoriels et articles approfondis. Avec cette édition bonus, que nous révélerons progressivement sur quatre semaines, nous espérons vous inspirer à concevoir des solutions IA innovantes pour les semaines et les mois à venir.

Si vous êtes à la recherche d'un projet pour débiter avec l'IA, l'article « télécommande IR universelle basée sur l'IA » constitue un excellent point de départ ! En utilisant un Raspberry Pi 5, la plateforme MediaPipe Studio de Google et une petite carte d'interface, vous aurez l'opportunité de créer un système de reconnaissance gestuelle polyvalent qui vous permettra de contrôler votre téléviseur ou d'autres appareils télécommandés par infrarouge.

Est-il possible pour une réalisation moderne de capturer l'essence de l'expérience originale de Turing ? Découvrez-le dans l'article « Un terminal personnel d'IA ». Grâce à un module ESP32, un écran TFT, et un amplificateur I<sup>2</sup>S, cet appareil devient une interface moderne pour le test de Turing du 21<sup>e</sup> siècle, permettant une communication directe avec ChatGPT.

Dans l'article « l'IA pour la conception de produits », nous examinons comment l'IA a révolutionné la création d'images. Les concepteurs ont désormais la capacité de transformer des esquisses et des idées en rendus photoréalistes simplement en utilisant des invites textuelles efficaces. Cet article plonge dans l'univers des outils de conception innovants alimentés par l'IA.

Curieux de connaître l'histoire de l'IA dans les pages d'Elektor ? Ce numéro spécial vous propose un voyage captivant à travers les archives d'Elektor, mettant en lumière l'évolution de l'intelligence artificielle au sein de notre communauté électronique. Immergez-vous dans les meilleures recommandations sélectionnées par nos rédacteurs, issues des éditions précédentes de votre magazine préféré.

Et bien plus encore vous attend dans cette édition bonus gratuite !

Une fois que vous aurez exploré ce numéro et démarré vos propres projets d'IA n'oubliez pas de partager vos expériences sur la plateforme en ligne Elektor Labs à l'adresse [www.elektormagazine.com/labs](http://www.elektormagazine.com/labs). Nous sommes impatients de découvrir vos innovations et créations !

C. J. Abate (Directeur du contenu, Elektor)

## DANS CE NUMÉRO

4 un terminal d'IA personnel  
donner une Voix à ChatGPT



8 High-Performance Edge AI : le nouveau STM32N6  
des performances et des capacités d'IA qui changent la donne



12 explorer l'IA

50 termes clés pour les ingénieurs et les électroniciens

16 Raspberry Pi AI Camera  
simplifier l'edge computing

22 l'intelligence artificielle dans Elektor

26 Hailo AI Kit avec Raspberry Pi 5

32 infographie :  
intelligence artificielle

34 télécommande IR basée sur l'IA  
contrôle gestuel avec MediaPipe  
et Raspberry Pi

42 L'IA pour la conception de produits  
le monde des générateurs d'art IA



L'édition 2024 spéciale IA du magazine Elektor est disponible en kiosque et sur l'e-shoppe Elektor.

[www.elektor.fr/20727](http://www.elektor.fr/20727)



# un terminal d'IA personnel

## Donner une Voix à ChatGPT

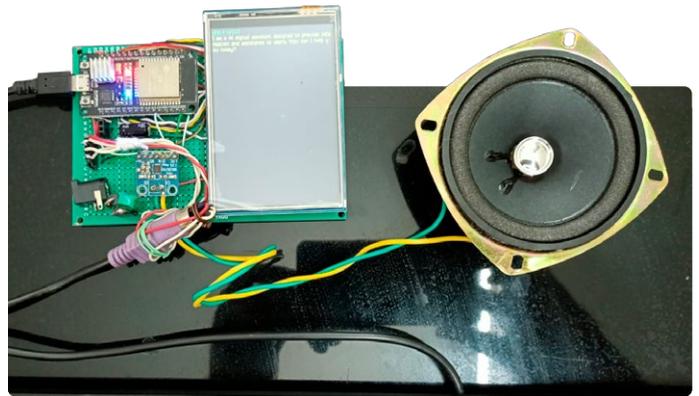
Somnath Bera (Inde)

La question de savoir si des solutions d'IA telles que ChatGPT peuvent réussir le test de Turing suscite toujours de vifs débats. À l'origine, Turing avait envisagé un test où un opérateur humain évaluerait les réponses à des questions transmises via un téléscripneur. Nous proposons une adaptation contemporaine de ce concept expérimental, en utilisant un ESP32 équipé d'un clavier et d'un écran TFT pour établir une communication exclusive avec ChatGPT via Internet. De plus, grâce à la synthèse vocale de Google, couplée à un petit module amplificateur I2S et à un haut-parleur, il est possible d'écouter la conversation. Toutefois, dans notre configuration, il est clair dès le départ que notre interlocuteur est une machine, n'est-ce pas ?

Il ne fait aucun doute que les outils d'IA tels que ChatGPT d'OpenAI et Gemini de Google ont le potentiel de révolutionner de nombreux domaines. J'utilise ChatGPT pour développer des solutions de contrôle assez complexes. Je commence par présenter l'idée initiale et, puis je fournis progressivement des informations supplémentaires, ce qui permet à l'outil d'affiner et d'améliorer le code à chaque itération. Il est même capable de convertir un code Python en MicroPython ou en un croquis Arduino. Il est crucial de diriger minutieusement le processus pour s'assurer qu'il ne dévie pas de l'objectif initial. Il arrive qu'il dévie et répète les mêmes erreurs, mais j'aime bien trouver ces bogues et réajuster les résultats de ChatGPT pour qu'ils correspondent mieux à mon objectif.

### Matériel

Le cœur de ce projet est le module de développement ESP32 d'Espressif. Grâce à son architecture à double cœur, ce module dispose d'une capacité de traitement suffisante pour gérer les communications Wifi, gérer l'entrée série d'un clavier PS2, envoyer des données à l'écran



TFT de 3,5 pouces et sortir des données audio numériques vers le module I2S. Le schéma complet du terminal ChatGPT est présenté dans la **figure 1**.

L'utilisation d'un clavier PS2 pourrait sembler surprenante ; la raison en est simplement que je n'ai pas réussi à implémenter un port USB à cet effet sur l'ESP32. Dans le temps limité dont je disposais, j'ai choisi une interface PS2 pour sa simplicité et sa faible consommation de ressources. Les connecteurs PS2 pour claviers sont disponibles chez plusieurs fournisseurs de composants électroniques en ligne. L'affectation des broches du clavier PS2 est indiquée dans le schéma du circuit. Il est probable que certains développeurs souhaitent évoluer vers une interface USB, et je suis impatient de lire leurs retours. L'écran tactile TFT de 3,5 pouces utilisé a une interface parallèle plutôt que la version SPI alternative. Cela nécessite plus de fils de connexion, mais dans cette application, nous avons suffisamment de GPIO de rechange et l'interface offre un temps de réponse significativement plus rapide. Les fonctionnalités tactiles de l'écran ne sont pas utilisées ici.

Un module amplificateur MAX98357A I2S (**figure 2**) convertit le signal audio numérique I2S généré par l'ESP32 en audio analogique. Un amplificateur intégré de classe D de 3 W amplifie le signal pour obtenir un bon niveau sonore. L'entrée de gain est liée à la masse, ce qui produit un volume maximal de l'ampli. La sortie de l'amplificateur de classe D peut alimenter un haut-parleur de 4 Ω.



Figure 2. Le module amplificateur audio convertit l'audio numérique I2S en 3 W.

### Ne perdez pas la clé

ChatGPT, développé par OpenAI, est capable de générer des réponses textuelles à des requêtes ou questions fournies par les utilisateurs. Il fonctionne généralement via une interface de navigateur. L'API OpenAI a été conçue pour être utilisée par les développeurs et les entreprises afin qu'ils puissent intégrer des fonctions d'IA dans leurs propres applications, logiciels ou sites web. Il ne s'agit pas seulement d'une interface de chatbot, mais d'une interface de programmation flexible permettant aux entreprises d'intégrer les fonctionnalités de chatGPT dans leurs produits. Les développeurs envoient des données à l'API de manière programmatique et obtiennent des réponses en retour. Pour accéder à l'API OpenAI, une clé unique est nécessaire ; celle-ci est générée lors de votre inscription sur le site web d'OpenAI [1] où il faut cliquer sur *Sign up*.

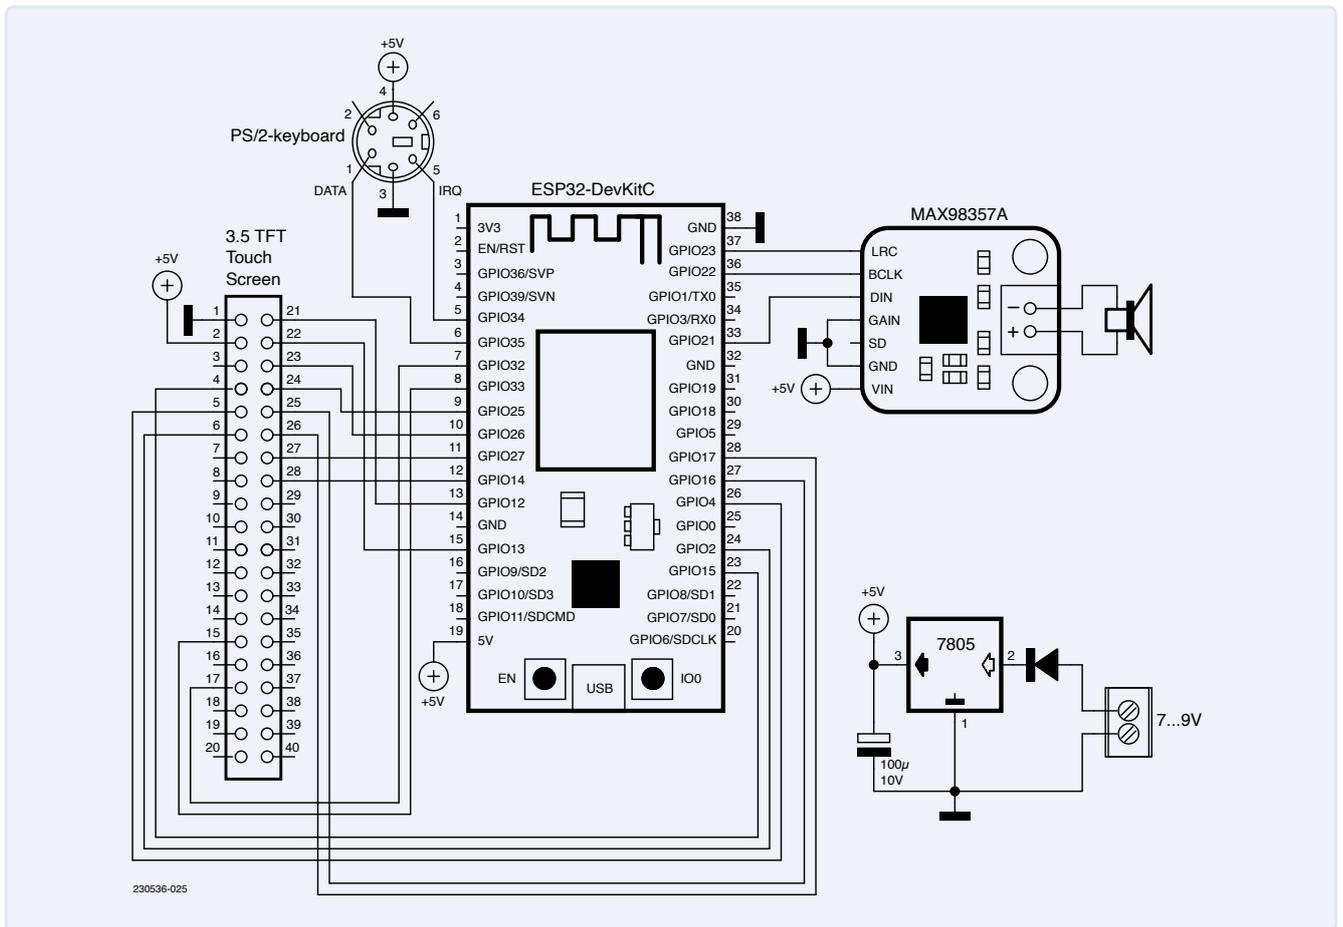


Figure 1. Schéma du terminal ChatGPT parlant.

Remplissez le formulaire d'inscription avec votre adresse électronique, votre mot de passe et d'autres informations requises. Une fois ces informations saisies, accédez au tableau de bord de votre compte OpenAI et cliquez sur le bouton **NEW PROJECT**. Donnez un nom et une description à votre projet (facultatif). Dans les paramètres de votre projet, cliquez sur l'onglet **API KEYS**. Vous verrez une liste des clés secrètes existantes (**figure 3**). Cliquez sur le bouton **Create a new secret Key** pour générer une nouvelle clé. Faites une copie de cette clé API générée et conservez-la en sécurité, car elle ne pourra plus être récupérée ultérieurement pour des raisons de sécurité. Vous aurez besoin de cette clé pour authentifier vos applications avec les services d'OpenAI. Le site propose également un tutoriel de démarrage rapide pour les développeurs qui vous guide dans le processus de génération d'une réponse via l'API en utilisant la clé générée pour autoriser votre accès.

Au moment de la rédaction de cet article, OpenAI fournit des crédits gratuits lors de la première inscription, qui permettent d'expérimenter avec l'API. Après avoir utilisé tous ces crédits, vous devrez payer en fonction de votre utilisation. Si vous n'avez pas encore mis en place une méthode de paiement pour la facturation, il sera nécessaire de le faire. Assurez-vous de lire attentivement les directives d'utilisation et les conditions de service d'OpenAI.

### Synthèse vocale

Une API de synthèse vocale (TTS) est utilisée pour convertir la réponse textuelle de OpenAI en un flux de données audio numériques. Il existe plusieurs API de synthèse vocale que nous pouvons utiliser à cette fin. OpenAI possède sa propre API TTS qui propose une variété de voix naturelles. Pour accéder à cette API, vous devez utiliser la même clé que celle qui vous a été attribuée pour utiliser l'API OpenAI.

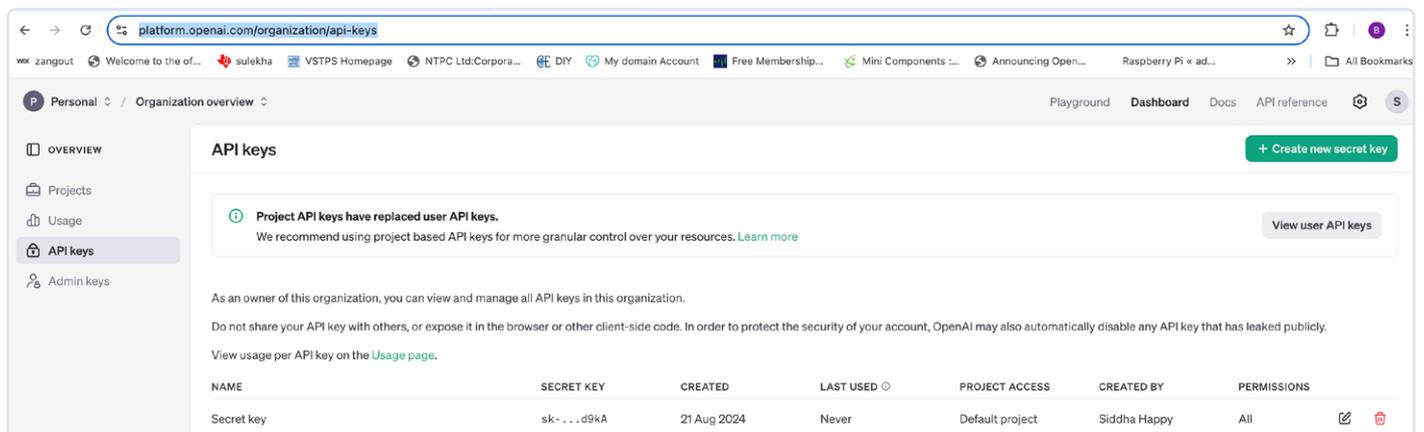


Figure 3. Page d'inscription à l'API de l'OpenAI.

Pour notre projet, nous utilisons l'API Google Cloud Text-to-Speech. Elle offre une gamme variée de voix disponibles en plusieurs langues et dialectes. Bien que les voix fournies par Google puissent parfois paraître légèrement plus mécaniques que celles d'OpenAI et que de longs textes puissent entraîner des interruptions dans l'audio, l'utilisation de l'API Google est gratuite pour le moment, contrairement à l'API TTS d'OpenAI qui est payante.

Pour démarrer avec Google TTS, nous devons d'abord créer le projet sur Google Cloud et activer l'API Google TTS pour obtenir notre clé API. Les chaînes de texte peuvent maintenant être envoyées à l'API à l'aide d'une requête HTTP POST accompagnée de la clé. Le flux audio numérique I<sup>2</sup>S résultant est ensuite stocké et lu pour produire un signal audio analogique via le MAX98357A.

## Logiciel : bibliothèques

Le croquis Arduino est fourni [2]. Vérifiez toutes les bibliothèques référencées dans l'en-tête du croquis pour vous assurer qu'elles sont installées dans votre environnement, si ce n'est pas le cas, installez-les en utilisant le gestionnaire de bibliothèques de l'EDI Arduino. En utilisant les méthodes disponibles dans la bibliothèque *Audio.h*, nous avons pu facilement produire une sortie audio pour accompagner les mots écrits sur l'écran TFT. Il a suffi d'ajouter quelques lignes dans la boucle pour générer l'audio (voir le croquis Arduino).

```
#include <PS2Keyboard.h>
#include <WiFi.h>
#include <HTTPClient.h>
#include <ArduinoJson.h>
#include <SPI.h>
#include <TFT_eSPI.h> // Hardware-specific library
#include "Audio.h" //Audio header file

// GPIO connections to I2S board
#define I2S_D0OUT 21
#define I2S_BCLK 22
#define I2S_LRC 23
```

```
Audio audio; //audio instance creation
```

Le fichier *ArduinoJSON.h* est utilisé pour analyser les données de réponse au format JSON de l'API OpenAI dans un format utilisable par le code Arduino.

## Logiciel : Requête de l'API ChatGPT

Le processus d'interaction avec l'API OpenAI est inclus dans la fonction `makeApiRequest(String prompt1)` :

1. Nous commençons par configurer un `HTTP client`:

```
HTTPClient http;
http.setTimeout(24000); // 24 seconds timeout
http.begin("https://api.openai.com/v1/chat/completions");
http.addHeader("Content-Type", "application/json");
http.addHeader("Authorization", "Bearer " +
                String(api_key));
```

2. Ensuite, nous préparons la charge utile qui sera au format JSON :

```
StaticJsonDocument<1024> jsonPayload;
// setting a maximum size of 1KB
jsonPayload["model"] = "gpt-3.5-turbo";
// model is gpt-3.5-turbo,
// change if you have access to 4 or 4.5
jsonPayload["temperature"] = 0.8;
// randomness of response, the higher
// the value, the higher the randomness
jsonPayload["max_tokens"] = 2000;
// maximum words & punctuations
// limit to be generated by response
```

3. Préparez le message (un tableau de messages imbriqués), utilisez le format JSON et envoyez la demande :

```
JSONArray messages = jsonPayload.
    createNestedArray("messages");
//put in a nested format not random
JsonObject userMessage = messages.createNestedObject();
userMessage["role"] = "user";
userMessage["content"] = prompt1;
String payloadString;
serializeJson(jsonPayload, payloadString);
```

4. Envoyez la demande et recevez la réponse :

```
int httpResponseCode = http.POST(payloadString);
//transfer to the open page
if (httpResponseCode == HTTP_CODE_OK) {
    String response = http.getString();
    // if everything goes OK get the
    // reply = output and put in a string
    ...
}
```

5. La page web comprendra généralement une jungle d'informations parasites (toutes dans le code HTML) qui ne sont pas utiles pour notre application et qui peuvent être supprimées. Ici, nous normalisons la réponse - en supprimant les balises JSON, etc. afin qu'elle puisse être lue sur l'écran TFT :

```
StaticJsonDocument<1024> jsonResponse;
//parse the tags etc of the response string.
deserializeJson(jsonResponse, response);
// and put in a simple stripped string & return
String assistantReply = jsonResponse
    ["choices"][0]["message"]["content"].
    as<String>();
// select the first part which contains our reply
return assistantReply;
```

## Logiciel : Setup et Loop

Dans la fonction `setup` nous initialisons la carte TFT, I<sup>2</sup>S, connectée à Internet avec nos identifiants Wifi.

```
void setup() {
```

```

delay(300);
...
audio.setPinout(I2S_BCLK, I2S_LRC, I2S_DOUT);
//I2S board initialised
audio.setVolume(50);

```

Dans la fonction `loop` nous envoyons des questions à ChatGPT. Lorsque la session est terminée, nous restons à l'intérieur de la boucle `loop` :

```

String response = makeApiRequest(msg);
// sent to Chatgpt
...
if (l1>200) {
  response = response.substring(0, 200);
  // truncate first 200 characters
}
audio.connecttospeech(response.c_str(), "en");
//speak up the 200 characters

```

Google TTS impose une restriction de 200 caractères, refusant de traiter des textes plus longs. Pour surmonter cette limite, la réponse est tronquée à 200 caractères spécifiquement pour la synthèse vocale. Ainsi, bien que la réponse intégrale soit visible à l'écran, seule la partie initiale est convertie en audio. Pour les textes excédant cette longueur, le contenu défile sur l'écran, mais cela peut être ajusté en apportant de légères modifications au croquis.

## Test du projet

Les délais que j'ai utilisés dans les boucles du logiciel sont assez spécifiques. Vous pouvez les ajuster, mais je vous recommande de commencer par les valeurs par défaut utilisées dans le code. Une fois que vous êtes à l'aise avec les réponses, n'hésitez pas à les modifier. J'ai commencé par des questions simples comme « Qui êtes-vous ? » ChatGPT a répondu de manière appropriée, en affichant l'introduction à l'écran, tandis que l'interlocuteur l'articulait clairement. J'ai ensuite testé le système en utilisant des questions telles que : « Écrivez 5 phrases à propos du magazine Elektor » (**figure 4**) et je lui ai même demandé d'écrire des croquis blink pour Arduino UNO, ESP32, et Raspberry Pi Pico.

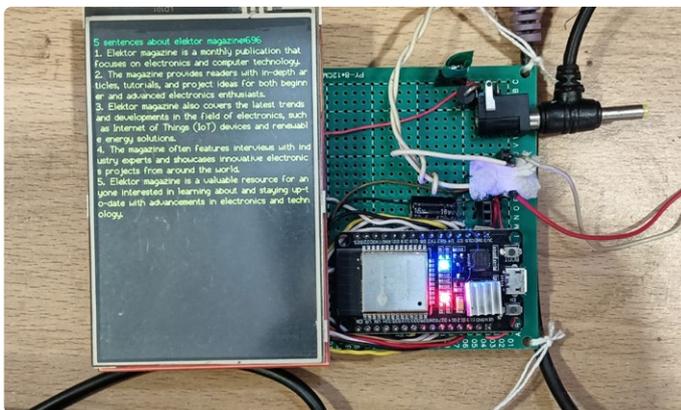


Figure 4. Test du système avec des requêtes demandant des croquis de clignotement pour Arduino UNO, ESP32 et Raspberry Pi Pico.

Dans tous les cas, ChatGPT s'est parfaitement comporté, a parfaitement compris le contexte et a répondu avec précision. La sortie vocale est haute et claire.

## Pour conclure

Tous les fichiers associés à ce projet se trouvent à l'adresse [2]. Internet et les navigateurs web tels que Google ont totalement révolutionné notre accès à l'information et remplacé ces encyclopédies encombrantes qui garnissaient nos étagères. Aujourd'hui, nous assistons à la montée en puissance de logiciels et de machines d'IA basés sur ChatGPT API, TensorFlow Lite Micro, Edge Impulse, OpenMV, TinyML, qui sont prêts à transformer les modèles commerciaux existants et les méthodes plus traditionnelles de résolution de problèmes. Nous nous trouvons à l'aube d'une ère intéressante. ◀

230536-04



## À propos de l'auteur

Somnath Bera, ingénieur en mécanique du Jalpaiguri Govt. Engg. College, en Inde, a travaillé comme directeur général chez NTPC, le plus grand producteur d'électricité du pays. Il a une profonde passion pour l'électronique, comme en témoignent ses plus de 60 projets innovants sur Elektor Labs, dont plus de 10 ont fait l'objet d'un article dans le magazine Elektor. Ses projets sont souvent axés sur la résolution de problèmes dans des domaines tels que la gestion des déchets et des ressources naturelles. Somnath aime utiliser des approches et des plateformes innovantes comme Arduino, Raspberry Pi et ESP32, associées à différents types de capteurs et de systèmes sans fil, pour créer des solutions efficaces et rentables.

## Questions ou commentaires ?

Envoyez un courriel à l'auteur (berasomnath@gmail.com), ou contactez Elektor (redaction@elektor.fr).



## Produits

➤ **Esspressif ESP32-DevKitC-32E**  
[www.elektor.fr/20518](http://www.elektor.fr/20518)

## LIENS

- [1] Site web d'OpenAI : <https://platform.openai.com>
- [2] Page web de cet article (téléchargements) : <https://www.elektormagazine.fr/230536-04>



# Edge AI haute performance : le nouveau STM32N6

Des performances et des capacités d'IA qui changent la donne

Contribué par STMicroelectronics

Le nouveau STM32N6 est conçu pour répondre à la demande croissante d'IA en périphérie, ou « edge AI », ouvrant la voie à de nouvelles applications dans des domaines tels que la vision par ordinateur, le traitement audio et d'autres technologies avancées. Il continue de repousser les limites des applications vidéo et multimédia, en améliorant l'expérience utilisateur grâce à ses capacités multimédias enrichies.

Les microcontrôleurs STM32, basés sur des processeurs Arm Cortex de M0 à M7, sont reconnus au sein de la communauté électronique pour leur riche ensemble de périphériques et bénéficient d'un écosystème étendu de cartes de développement, de bibliothèques et d'outils logiciels adaptés à une multitude d'applications. Le nouveau STM32N6 excelle dans le prétraitement de données en périphérie, grâce à l'intégration de l'IA au moyen d'une unité de traitement neuronal (NPU). Il ouvre de nouveaux horizons d'applications à base de microcontrôleurs (figure 1).

## STM32N6 – caractéristiques et

### avantages

- Le NPU intégré (Neural-ART Accelerator) constitue le cœur du nouveau STM32N6. Il offre une performance impressionnante de 600 GOPS pour une très faible consommation d'énergie. Ce NPU change la donne, en offrant des performances d'IA haut de gamme (figure 2) sur un microcontrôleur à faible encombrement, à faible consommation d'énergie et à faible coût.
- Avec son cœur Arm Cortex®-M55 cadencé à 800 MHz, le STM32N6 atteint 1280 DMIPS et 3360 CoreMark, marquant la plus haute performance pour un microcontrôleur STM32 à ce jour. Il est ainsi idéal pour les applications de vision et de graphisme avancées, supportées par un accélérateur Chrom-ART, un accélérateur NeoChrom, un encodeur H264 et un encodeur/décodeur JPEG.
- Le microcontrôleur est doté de 4,2 Mo de RAM intégrée, ce qui permet le traitement des données en temps réel, le multitâche et une exécution efficace sans nécessiter de mémoire externe dans la plupart des cas. En plus, il dispose d'un riche ensemble de périphériques, y compris deux interfaces USB, Ethernet Gbit, I3C, et sept interfaces

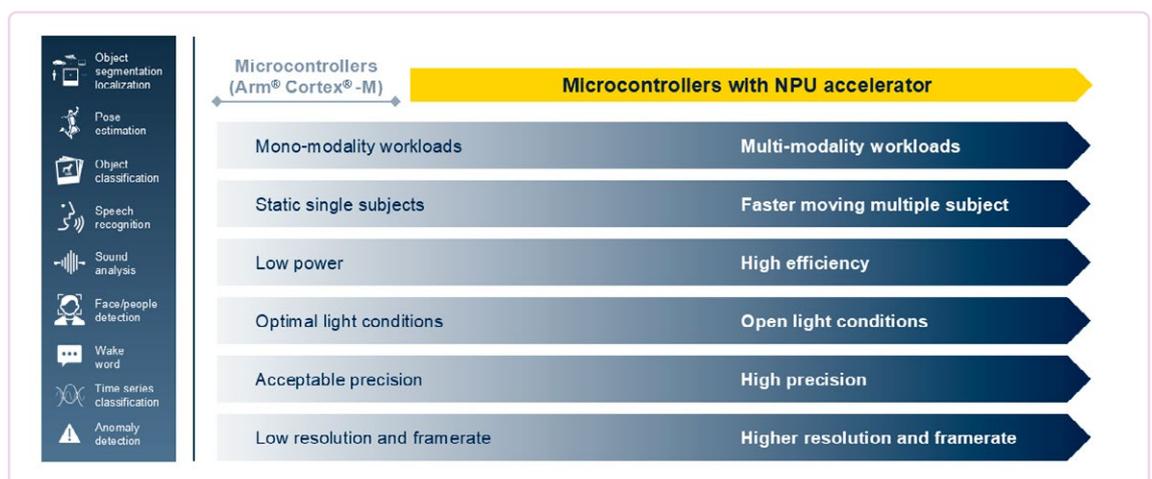


Figure 1. L'unité de traitement neuronal (NPU) offre de nouveaux champs d'application.

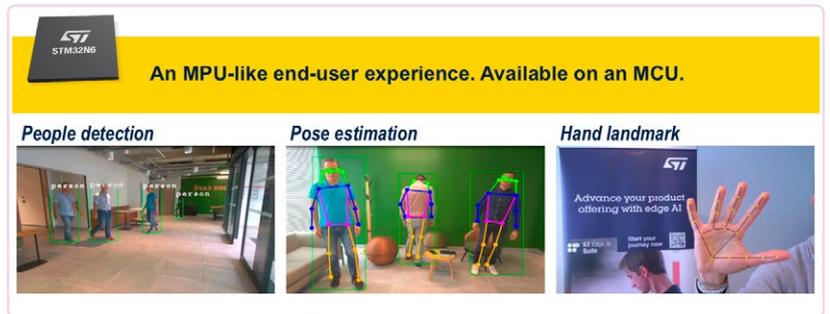
UART, offrant ainsi des options de connectivité polyvalentes pour diverses applications.

- Un processeur de signal d'image (ISP) dédié peut traiter le signal issu de module camera de 5 MP à 30 fps. Le micrologiciel intégré au processeur Arm Cortex permet la balance des blancs et l'exposition automatiques. Un outil logiciel gratuit permet un réglage fin de l'ISP (**figure 3**).
- Totalement intégré à l'écosystème STM32, le STM32N6 est soutenu par la ST Edge AI Suite, comprenant des outils tels que STM32Cube.AI, un ensemble de modèles IA prêts à l'emploi (AI model zoo), diverses ressources et des études de cas. Il est également soutenu par de nombreux partenaires, notamment Edge Impulse, Nota.AI et EmbedUR, offrant ainsi un environnement de développement complet.

### Un écosystème logiciel complet

STMicroelectronics est leader dans le domaine de l'Edge AI, offrant des solutions complètes qui répondent aux divers besoins des ingénieurs et des développeurs dans tous les secteurs. Grâce à sa suite Edge AI, ST propose une vaste gamme d'outils logiciels adaptés à différents profils d'utilisateurs et niveaux d'expertise, ainsi qu'une large collection d'études de cas pour inspirer les développeurs.

STM32Cube.AI et ST Edge AI Developer Cloud se distinguent par leur flexibilité et leur capacité à s'adapter aux besoins spécifiques des utilisateurs. Ces outils donnent accès à des ressources avancées pour optimiser et déployer des modèles personnalisés (**figure 4**). ST a également développé un « model zoo » complet accompagné de ressources supplémentaires telles que des scripts de réentraînement et des exemples de code d'application. C'est un point de départ idéal pour les développeurs qui souhaitent mettre en œuvre

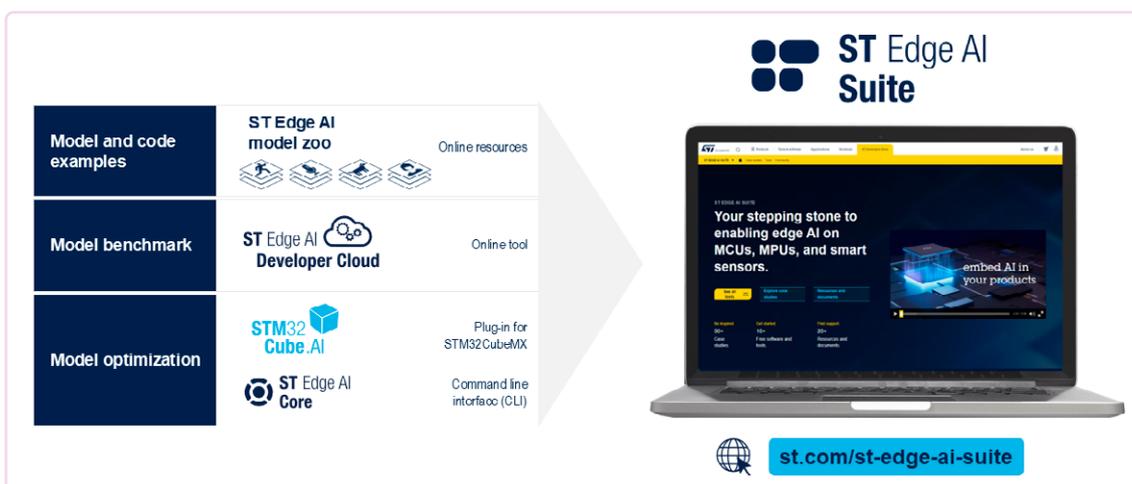


▲  
Figure 2. L'accélérateur ST Neural-ART permet l'exécution d'applications d'IA avancées.

◀  
Figure 3. Un processeur de signal d'image (ISP) dédié est dimensionné pour un appareil photo de 5 MP à 30 fps et peut être réglé avec précision via un outil logiciel.

### Le concours STM32 Edge AI Contest

Souhaitez-vous exploiter les capacités du nouveau STM32N6 dans un projet personnel? Participez au concours **STM32 Edge AI Contest** organisé par STMicroelectronics et Elektor ! Que vous soyez un ingénieur chevronné, un maker ou un étudiant, vous avez l'opportunité de recevoir gratuitement une carte de développement STM32N6. Lancez-vous dans le développement d'une application d'intelligence artificielle avant la fin d'avril 2025. Pour plus de détails sur le concours, consultez la page [www.elektormagazine.com/stm32ai](http://www.elektormagazine.com/stm32ai) ou retrouvez les informations dans l'édition de janvier/février 2025 d'Elektor.



◀  
Figure 4. STM32Cube.AI et ST Edge AI Developer Cloud sont conçus pour les utilisateurs qui ont besoin d'une grande flexibilité. Le model zoo complet avec des exemples de code d'application constitue un excellent point de départ pour les développeurs qui souhaitent créer rapidement des solutions d'IA.



▲  
Figure 5. Le STM32N6 est livré avec un ensemble d'exemples de code pour démarrer votre projet.

rapidement des solutions d'IA sans partir de zéro. Le model zoo fournit des modèles pré-entraînés pour diverses applications, telles que la détection d'objets, la classification d'images et la reconnaissance de scènes audio, qui peuvent être affinés pour répondre à des besoins spécifiques. Les scripts de réentraînement et les exemples de code d'application permettent aux développeurs d'adapter plus facilement ces modèles selon leurs cas d'utilisation uniques, ce qui accélère le processus de développement et réduit les délais de mise sur le marché (figure 5).

### C'est un STM32 !

Les développeurs bénéficieront du formidable écosystème et de l'héritage des produits STM32 pour créer leur propre design. Le STM32N6 offre une multitude d'avantages aux développeurs, ouvrant de nouvelles possibilités et simplifiant le processus de développement :

### Intégration transparente de l'IA

Le STM32N6 s'intègre à l'écosystème STM32, facilitant ainsi le déploiement de l'IA. Les développeurs peuvent s'appuyer sur la suite ST Edge AI, notamment sur des outils tels que STM32Cube.AI, pour optimiser et déployer leurs modèles de réseaux neuronaux en toute simplicité. Cette intégration réduit la complexité

du développement de l'IA et accélère le lancement de nouveaux produits sur le marché.

### Coût et efficacité énergétique

En offrant une expérience utilisateur d'IA similaire à celle d'un MPU avec un encombrement réduit, une consommation énergétique plus basse et des coûts réduits, le STM32N6 permet aux développeurs de créer des applications IA innovantes sans subir les coûts élevés habituellement liés aux solutions MPU et GPU.

### Performances accrues

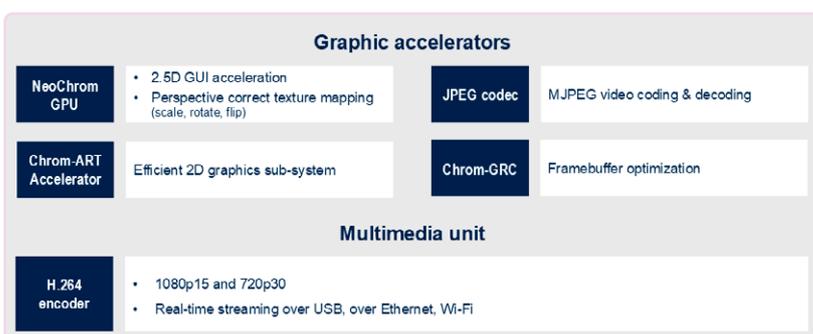
Le cœur Arm Cortex®-M55 haute performance, associé au NPU embarqué et à une RAM abondante, garantit aux développeurs l'exécution efficace d'algorithmes d'IA complexes et d'applications multimédias. Cela ouvre de nouvelles possibilités pour créer des applications de pointe qui se démarquent sur le marché compétitif. Les performances du STM32N6 permettent aux développeurs de repousser les limites de ce qui est réalisable avec les microcontrôleurs.

### Des capacités graphiques étendues

Le STM32N6 se distingue comme le MCU STM32 le plus puissant en termes de capacités graphiques. Il intègre l'accélérateur Chrom-ART™ pour l'accélération graphique 2D et l'accélérateur NeoChrom™ pour l'accélération 2,5D, notamment pour le dessin avancé, la correction de perspective et les mappages de texture (figure 6). En outre, le Chrom-GRC™ est très efficace en ressources graphiques pour les affichages non carrés. Avec 4,2 Mo de SRAM intégrée, le STM32N6 offre une mémoire suffisante pour gérer des ressources graphiques volumineuses et des animations complexes sans nécessiter de mémoire externe, ce qui permet de créer des interfaces utilisateur plus rapides et plus réactives.

### Environnement de développement complet

▼  
Figure 6. Le STM32N6 - qui est également disponible sans l'unité de traitement neuronal - est le microcontrôleur STM32 le plus puissant en termes de capacités graphiques.



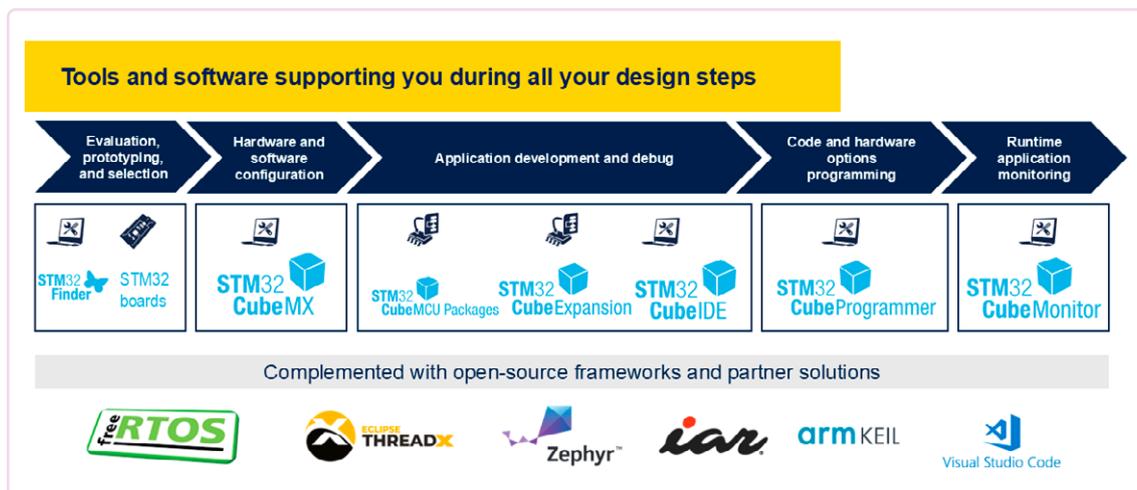


Figure 7. Le STM32N6 est soutenu par un écosystème solide et de nombreux partenaires.

Le STM32N6 est soutenu par un écosystème robuste et de nombreux partenaires, offrant aux développeurs un environnement de développement complet. S'appuyant sur la suite logicielle STM32Cube, il offre une gamme d'outils logiciels pour la configuration, le développement, la programmation et la surveillance. Pour les logiciels embarqués, il inclut des packages, des intergiciels et la prise en charge des pilotes, enrichis par des options RTOS telles que FreeRTOS, Zephyr et Eclipse ThreadX (figure 7).

Dans le domaine de l'IA, les développeurs ont accès à des outils, des ressources, des études de cas et un support de partenaires comme Edge Impulse, Nota.AI et EmbedUR. Pour le développement graphique, le STM32N6 est pris en charge par TouchGFX, ce qui simplifie la création d'interfaces graphiques sophistiquées. Ce vaste réseau de support garantit aux développeurs l'assistance dont ils ont besoin à chaque étape du processus de développement, ce qui permet de créer des applications visuellement impressionnantes et très réactives.

### Flexibilité et polyvalence

Doté d'un riche ensemble de périphériques et d'options de connectivité avancées, le STM32N6 offre aux développeurs la flexibilité nécessaire pour concevoir une large gamme d'applications. Qu'il s'agisse de vision par ordinateur, de traitement audio ou de multimédia avancé, le STM32N6 fournit les outils et les capacités nécessaires pour transformer des concepts innovants en réalité. En outre, le STM32N6 sera également proposée dans une version sans NPU répondre aux besoins des applications exigeant de hautes performances en calcul, graphisme et multimédia, sans intégrer de fonctionnalités d'IA. Cette polyvalence garantit que les développeurs peuvent choisir la configuration adaptée à leurs besoins spécifiques, rendant le STM32N6 adapté à une multitude de secteurs tels que l'automobile, la santé, l'électronique grand public, et l'automatisation industrielle.

### développeurs

Le STM32N6 révolutionne l'IA embarquées, en offrant des performances d'IA de pointe inégalées sur un microcontrôleur. Son faible encombrement, sa consommation d'énergie réduite et ses coûts réduits en font un choix idéal pour une large gamme d'applications, du traitement audio à la vision par ordinateur. Le STM32N6 permet aux développeurs de créer des appareils plus intelligents, plus efficaces et plus sûrs, capables de fonctionner en périphérie.

Les développeurs peuvent s'appuyer sur le STM32N6 pour créer des systèmes domotiques intelligents capables de reconnaître et de réagir à diverses commandes et situations, améliorant ainsi le confort et la sécurité. Dans le domaine de la santé, ce STM32 peut être utilisé pour développer des dispositifs médicaux avancés qui suivent l'état de santé des patients en temps réel, offrant des diagnostics précis et des alertes rapides. Dans le secteur de l'automatisation industrielle, le STM32N6 permet de concevoir des systèmes robustes qui exécutent des tâches complexes avec une précision et une efficacité élevées, améliorant ainsi la productivité et la sécurité. Dans le domaine de l'électronique grand public, ce microcontrôleur permettra de créer de nouveaux appareils innovants, enrichissant les expériences multimédias, de la vidéo haute définition aux jeux immersifs.

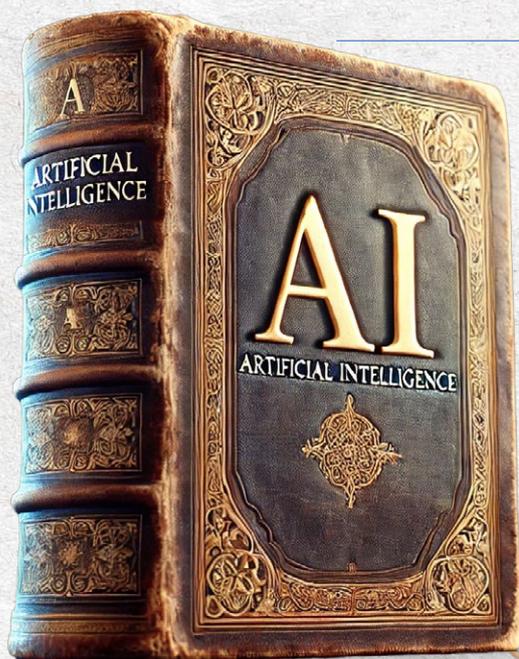
Le STM32N6 témoigne de l'engagement de STMicroelectronics envers l'innovation et de l'excellence. En redéfinissant les performances des microcontrôleurs et en intégrant des capacités d'IA avancées, le STM32N6 permet aux développeurs de créer des applications de pointe qui se distinguent dans un marché compétitif. Grâce à son intégration transparente dans l'écosystème STM32 et au soutien de nombreux partenaires, le STM32N6 est prêt à révolutionner le monde des microcontrôleurs et de l'IA embarquée.

Pour plus d'informations, visitez le site

[www.st.com/stm32n6](http://www.st.com/stm32n6). ◀

240676-04

Des possibilités passionnantes pour les



# explorer l'IA

## 50 termes pour les ingénieurs et les électroniciens

L'équipe Elektor

L'intelligence artificielle révolutionne le domaine de l'électrotechnique et des projets DIY. Mais quels sont les termes indispensables à connaître dans ce contexte ? Nous avons interrogé des systèmes d'IA, tels que ChatGPT et Gemini. Les résultats sont pour le moins étonnants ! Ces termes vous offriront une compréhension solide des concepts d'IA appliqués à l'électronique et à la fabrication.

### Fonction d'activation

Fonction des réseaux neuronaux qui détermine la sortie d'un neurone et contribue à introduire la non-linéarité. Le choix de cette fonction impacte directement les performances et les capacités d'apprentissage du réseau

### Algorithme

Procédure informatique étape par étape pour résoudre un problème ou effectuer une tâche. C'est un ensemble d'instructions que doivent suivre un ordinateur ou un utilisateur pour atteindre un objectif déterminé.

### Intelligence générale artificielle (AGI)

IA hypothétique capable de comprendre, d'apprendre et d'effectuer toute tâche intellectuelle comme un humain. Bien que l'AGI reste un concept théorique, les chercheurs travaillent activement au développement de systèmes d'IA dotés de telles capacités.

### Intelligence artificielle (IA)

Simulation par des machines de capacités cognitives humaines, telles que penser, apprendre et résoudre des problèmes. C'est un vaste domaine qui englobe un large éventail de technologies et d'applications, notamment des algorithmes simples, des chatbots, des réseaux neuronaux et des systèmes complexes comme les véhicules autonomes.

### Rétropropagation

Méthode d'apprentissage pour les réseaux neuronaux, ajustant les poids en recalculant l'erreur de la couche de sortie vers les couches précédentes pour réduire les écarts entre prédictions et réalités, optimisant ainsi les performances du réseau à chaque itération.

### Biais

Paramètre modifiable dans les modèles d'apprentissage automatique qui permet d'ajuster la fonction d'activation, influençant ainsi les prédictions du modèle. Le biais est crucial pour accroître la précision et la flexibilité, bien qu'il puisse introduire des erreurs systématiques.

### Big Data

Ensemble de données massives qui peuvent être analysées par des processus informatiques pour révéler des modèles, des tendances et des associations. Utilisé dans des domaines variés, comme la recherche scientifique et les applications IoT, le Big Data facilite les décisions basées sur l'analyse de données.

### Classification

Méthode d'apprentissage supervisé consistant à attribuer des données d'entrée à l'une de plusieurs catégories ou étiquettes prédéfinies. L'objectif est de créer un modèle capable de prédire la catégorie de nouvelles entrées basées sur l'apprentissage antérieur.

## Regroupement

Technique d'apprentissage non supervisée qui regroupe les points de données présentant des caractéristiques similaires en grappes. Le clustering est utilisé pour l'exploration des données, la reconnaissance des formes et l'identification des regroupements naturels au sein des ensembles de données.

## Réseau neuronal convolutif (CNN)

Modèle d'apprentissage profond particulièrement efficace pour les tâches de reconnaissance visuelle. Les CNN utilisent des couches convolutives pour apprendre automatiquement des hiérarchies spatiales de caractéristiques à partir d'images d'entrée, ce qui les rend bien adaptés aux applications de vision par ordinateur.

## Validation croisée

Technique d'évaluation des modèles d'apprentissage automatique par partitionnement des données en ensembles d'apprentissage et de validation. Elle permet d'évaluer les performances et la généralisabilité du modèle en réduisant le surajustement et en garantissant que le modèle fonctionne bien sur des données non vues.

## Augmentation des données

Technique qui élargit artificiellement les données d'apprentissage en générant des variations des échantillons de données existants. Les méthodes courantes comprennent la rotation, la mise à l'échelle, le retournement ou l'ajout de bruit aux images, ce qui permet d'améliorer la robustesse du modèle et d'éviter le surajustement.

## Exploration de données

Le processus de découverte de modèles et d'extraction d'informations utiles à partir de grands ensembles de données. Il implique des méthodes telles que la classification, le regroupement et l'apprentissage de règles d'association pour transformer les données brutes en informations exploitables pour la prise de décision.

## Prétraitement des données

Les mesures prises pour nettoyer, transformer et préparer les données brutes pour les modèles d'apprentissage automatique. Cela inclut le traitement des valeurs manquantes, la normalisation des données et l'encodage des variables catégorielles, qui sont cruciales pour garantir la précision des performances du modèle.

## Apprentissage en profondeur

Un sous-ensemble de l'apprentissage automatique utilisant des réseaux neuronaux avec de nombreuses couches pour modéliser des modèles de données complexes. L'apprentissage profond est particulièrement efficace pour traiter les grands ensembles de données à haute dimension, tels que les images, l'audio et le texte.

## Réduction de la dimensionnalité

Processus consistant à réduire le nombre de variables aléatoires considérées en obtenant un ensemble de variables principales. Cette technique permet d'améliorer l'efficacité des modèles, de réduire les coûts de calcul et d'éviter le surajustement dans les tâches d'apprentissage automatique.

## Abandon

Technique de régularisation des réseaux neuronaux qui ignore aléatoirement certains neurones pendant la formation afin d'éviter le surajustement. En « abandonnant » des nœuds, le dropout réduit la dépendance à l'égard de neurones spécifiques, améliorant ainsi la généralisation du modèle sur des données non vues.

## IA périphérique

Calcul et traitement de l'IA effectués localement sur des appareils en périphérie plutôt que sur des serveurs centralisés dans le cloud. Cette approche peut réduire la latence, améliorer la confidentialité et minimiser l'utilisation de la bande passante, ce qui en fait une solution intelligente pour les applications en temps réel telles que les véhicules autonomes et la réalité augmentée.

## Époque

Un cycle complet à travers l'ensemble des données d'entraînement pendant l'entraînement du modèle d'apprentissage automatique. Plusieurs époques sont souvent nécessaires pour s'assurer que le modèle a appris les modèles sous-jacents des données de manière adéquate.

## Ingénierie des caractéristiques

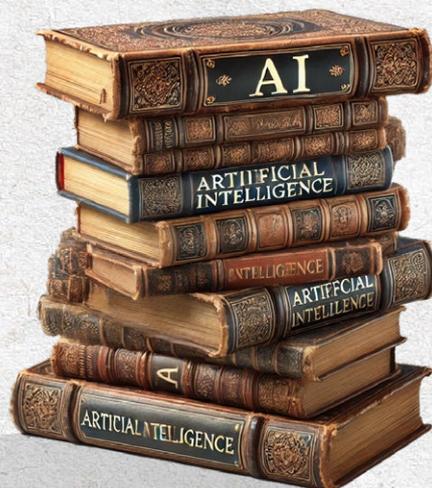
Le processus de sélection, de modification ou de développement de nouvelles caractéristiques pour améliorer les performances des modèles d'apprentissage automatique. Une ingénierie des caractéristiques efficace peut améliorer de manière significative la précision du modèle et réduire l'overfitting.

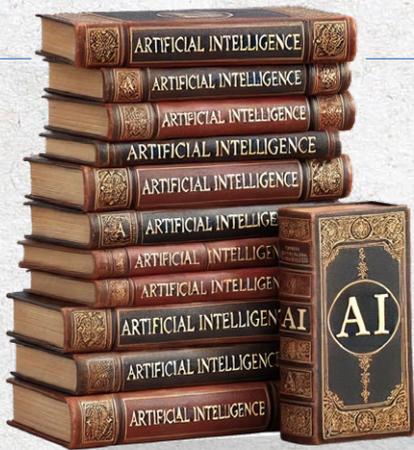
## Extraction de caractéristiques

Le processus de transformation des données brutes en un format adapté à l'apprentissage automatique en identifiant les caractéristiques pertinentes. Cette étape réduit la dimensionnalité et aide à se concentrer sur les attributs les plus informatifs pour la construction de modèles.

## Réseau adversarial génératif (GAN)

Une classe de cadres d'apprentissage automatique où deux réseaux neuronaux sont en concurrence pour générer des échantillons de données réalistes. Les GAN sont souvent utilisés pour créer des images synthétiques de haute qualité, des vidéos et même du texte.





### **Descente de gradient**

Algorithme d'optimisation utilisé pour minimiser la fonction de coût en ajustant les paramètres du modèle. Il met à jour itérativement les poids dans la direction qui réduit l'erreur, aidant le modèle à apprendre à partir des données.

### **Ajustement des hyperparamètres**

Le processus d'optimisation des paramètres d'un modèle d'apprentissage automatique pour améliorer ses performances. Les hyperparamètres (par exemple, le taux d'apprentissage ou le nombre de couches) sont ajustés manuellement pour trouver la meilleure configuration du modèle.

### **Inférence**

Le processus d'utilisation d'un modèle d'apprentissage automatique formé pour faire des prédictions sur de nouvelles données. L'inférence est effectuée après qu'un modèle a été formé et déployé, et elle est souvent utilisée dans des applications de prise de décision en temps réel.

### **Internet des objets (IoT)**

Réseau d'appareils interconnectés capables de collecter et d'échanger des données à l'aide de capteurs et de logiciels intégrés. L'IoT permet la surveillance à distance, l'automatisation et les perspectives basées sur les données dans divers secteurs, des maisons intelligentes aux systèmes industriels.

### **K voisins les plus proches (KNN)**

Algorithme d'apprentissage simple, basé sur les instances, utilisé pour la classification et la régression en comparant de nouveaux points de données à des exemples vus précédemment. Il classe en fonction de la classe majoritaire des points de données les plus proches, ce qui le rend facile à mettre en œuvre mais intensif en termes de calcul.

### **Espace latent**

Espace caché de faible dimension représentant les caractéristiques comprimées apprises par un réseau neuronal. L'espace latent est utilisé dans des techniques telles que les autoencodeurs pour la réduction de la dimensionnalité et la génération de données.

### **Régression logistique**

Modèle statistique utilisé pour la classification binaire, prédisant la probabilité d'appartenance à une classe. Il utilise une fonction logistique pour faire correspondre les valeurs d'entrée à une probabilité, ce qui le rend efficace pour faire la distinction entre deux classes.

### **Fonction de perte**

Fonction mathématique utilisée pour mesurer l'erreur entre les sorties prédites et réelles dans un modèle d'apprentissage automatique. La fonction de perte guide le processus d'optimisation pour minimiser les erreurs pendant la formation, ce qui est crucial pour la précision du modèle.

### **Apprentissage machine (ML)**

Un sous-ensemble de l'IA impliquant des algorithmes qui apprennent des modèles à partir de données pour faire des prédictions ou prendre des décisions. Les algorithmes ML peuvent être supervisés, non supervisés ou renforcés, en fonction de la nature des données et de la tâche.

### **Méta-apprentissage**

Technique d'IA dans laquelle les modèles apprennent à apprendre, en s'adaptant rapidement à de nouvelles tâches avec un minimum de données. Le méta-apprentissage vise à améliorer l'efficacité de l'apprentissage et les performances à travers diverses tâches en tirant parti des expériences d'apprentissage précédentes.

### **Compression de modèles**

Techniques telles que l'élagage ou la quantification qui réduisent la taille et la complexité des modèles d'apprentissage automatique. La compression rend les modèles plus efficaces pour le déploiement sur des appareils dont les ressources informatiques sont limitées ou restreintes.

### **Traitement du langage naturel (NLP)**

Branche de l'IA axée sur l'interaction entre les ordinateurs et le langage humain. Le NLP permet aux machines de comprendre, d'interpréter et de générer du langage humain, facilitant ainsi des applications telles que la traduction, l'analyse des sentiments et les chatbots.

### **Réseau neuronal**

Modèle informatique inspiré du cerveau humain, composé de nœuds interconnectés (neurones). Les réseaux neuronaux constituent l'épine dorsale de l'apprentissage profond, capable de modéliser des relations complexes et non linéaires dans les données.

### **Encodage à chaud**

Technique de prétraitement des données qui convertit les variables catégorielles en une matrice binaire. Elle permet aux modèles d'apprentissage automatique d'interpréter les données catégorielles en représentant chaque catégorie comme un vecteur unique.

## Surajustement

Une erreur de modélisation dans l'apprentissage automatique où le modèle apprend le bruit au lieu du modèle réel, ce qui donne des résultats médiocres sur les nouvelles données. Le surajustement se produit lorsqu'un modèle est trop complexe par rapport à la quantité de données d'apprentissage disponibles.

## Optimisation des paramètres

Processus consistant à trouver les meilleurs paramètres du modèle afin de minimiser l'erreur pendant la formation. Il s'agit d'ajuster des paramètres tels que les poids et les biais afin d'améliorer la précision et les performances du modèle.

## Perceptron

Le type le plus simple de réseau neuronal artificiel, constitué d'une seule couche utilisée pour les tâches de classification binaire. Le modèle de perceptron sert d'élément de base à des architectures de réseaux neuronaux plus complexes.

## Réseau neuronal récurrent (RNN)

Type de réseau neuronal qui retient les informations par le biais de boucles de rétroaction, adapté aux données séquentielles. Les RNN sont largement utilisés pour des tâches telles que la modélisation du langage, la reconnaissance vocale et la prédiction de séries temporelles.

## Régularisation

Techniques visant à empêcher le surajustement en ajoutant une pénalité à la complexité du modèle pendant la formation. Les méthodes de régularisation telles que les normes L1 ou L2 réduisent le surajustement et améliorent la généralisation du modèle sur de nouvelles données.

## Apprentissage par renforcement (RL)

Un type d'apprentissage automatique dans lequel un agent apprend à prendre des décisions en recevant des récompenses ou des pénalités. Le RL est largement utilisé en robotique, dans les jeux et dans d'autres scénarios de prise de décision où l'apprentissage par interaction est essentiel.

## Apprentissage supervisé

Un type d'apprentissage automatique où les modèles apprennent à partir d'ensembles de données étiquetés pour faire des prédictions ou prendre des décisions. Le modèle est formé à l'aide de paires entrée-sortie afin d'associer les entrées aux sorties correctes, ce qui convient à des tâches telles que la classification et la régression.

## Machine à vecteurs de support (SVM)

Algorithme d'apprentissage supervisé utilisé pour les tâches de classification et de régression, permettant de trouver la limite de décision optimale. Le SVM vise à maximiser la marge entre les différentes classes, assurant ainsi une classification robuste.

## Tenseur

Tableau multidimensionnel utilisé pour représenter les données dans les réseaux neuronaux, en particulier dans l'apprentissage profond. Les tenseurs fournissent un cadre pour manipuler de grands ensembles de données à travers plusieurs dimensions, facilitant ainsi des calculs efficaces.

## Apprentissage par transfert

Technique selon laquelle un modèle pré-entraîné est affiné sur une nouvelle tâche similaire afin de tirer parti des connaissances existantes. L'apprentissage par transfert est particulièrement utile lorsque les données d'entraînement sont rares ou que les ressources informatiques sont limitées.

## Insuffisance d'adaptation

Une erreur de modélisation où un modèle d'apprentissage automatique est trop simple pour capturer les modèles sous-jacents dans les données. L'inadaptation entraîne de mauvaises performances à la fois sur les données d'entraînement et sur les nouvelles données, ce qui nécessite un modèle plus complexe.

## Apprentissage non supervisé

Un type d'apprentissage automatique dans lequel les modèles apprennent des modèles à partir de données non étiquetées sans orientation spécifique. L'apprentissage non supervisé est utilisé pour des tâches telles que le clustering, la réduction de la dimensionnalité et la détection d'anomalies.

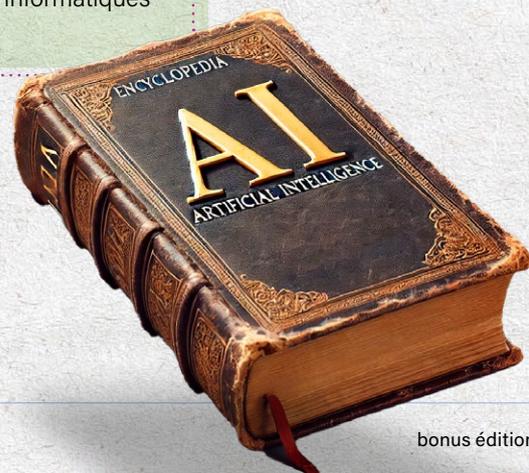
## Autoencodeur variationnel (VAE)

Type de réseau neuronal utilisé pour générer de nouveaux échantillons de données similaires à un ensemble de données donné. Les VAE apprennent la distribution des données d'entrée et génèrent de nouveaux points de données similaires, utiles pour la synthèse d'images et la détection d'anomalies.

## Poids

Paramètres des réseaux neuronaux qui sont ajustés pendant la formation pour minimiser la fonction de perte. Les poids déterminent la force des connexions entre les neurones, influençant la façon dont les signaux d'entrée sont transformés en prédictions de sortie.

240535-04



# Raspberry Pi

# AI Camera

simplifier l'edge computing



Figure 1. Le Raspberry Pi AI Camera (notez que le Raspberry Pi n'est pas inclus).

**Brian Tristam Williams (Elektor)**

Lors du salon Embedded World 2024, j'ai eu l'opportunité de découvrir la Raspberry Pi AI Camera. Bien qu'elle n'ait pas encore été officiellement annoncée à ce moment-là, elle a immédiatement capté l'attention grâce à ses fonctionnalités impressionnantes : une caméra dotée de capacités d'intelligence artificielle, capable de réaliser la détection d'objets et l'analyse de posture. Quelques mois plus tard, la caméra est officiellement sortie. J'ai mis la main sur l'une d'entre elles pour la mettre à l'épreuve.

Lorsque mon Raspberry Pi AI Camera est enfin arrivé, la boîte a révélé le module de la caméra, deux câbles plats, et - étonnamment - une petite bague de mise au point en plastique très pratique (**figure 1**). Dans le passé, ajuster la mise au point sur les caméras Raspberry Pi sans autofocus signifiait tordre l'objectif avec les doigts, ou pire, utiliser une pince à bec effilé (doucement). Ce n'est plus le cas aujourd'hui. Ce minuscule morceau de plastique bon marché a facilité la vie, même si l'absence d'autofocus signifiait qu'il fallait toujours bricoler un peu pour arriver à ses fins.

### Sous le petit capot

Le capteur de vision intelligent IMX500 de Sony est au cœur de la caméra Raspberry Pi AI, gérant à la fois la capture d'images haute résolution et le traitement IA embarqué. Pour soutenir cette technologie, le microcontrôleur RP2040 prend en charge les tâches périphériques essentielles, notamment la gestion du micrologiciel, la communication et le maintien d'une interaction fluide entre le module de caméra et le Raspberry Pi.

Le RP2040, également utilisé dans le Raspberry Pi Pico, est responsable de la coordination de la communication entre l'IMX500 et le Raspberry Pi. Bien qu'il n'effectue pas l'inférence de l'IA, il joue un rôle clé en veillant à ce que les modèles de réseaux neuronaux et les fonctions de la caméra soient chargés et fonctionnent correctement. Une fois que tout est configuré par le RP2040, l'IMX500 prend le relais pour le traitement de l'intelligence artificielle.

La Raspberry Pi AI Camera tire parti de l'IMX500 pour les tâches liées au réseau neuronal et du RP2040 pour le contrôle et la gestion globale. Cette configuration permet une gestion efficace des tâches d'inférence d'IA, telles que la détection d'objets et l'estimation de la pose, sans imposer une charge excessive au processeur du Raspberry Pi.

L'IMX500 de Sony est le premier capteur de vision intelligent au monde doté d'une capacité de traitement en périphérie, éliminant le besoin de faire appel à des serveurs externes ou des accélérateurs pour les tâches d'IA. Ainsi, toute l'inférence d'IA est réalisée directement sur le capteur. Cette conception élimine le besoin de processeurs externes ou de puces haute performance, réduisant considérablement la charge sur le processeur du Raspberry Pi et permettant des applications pilotées par l'IA en temps réel.

### Principales caractéristiques et avantages de l'IMX500

L'IMX500 associe un capteur d'image de 12,3 mégapixels à un puissant processeur de signal numérique (DSP) et à une mémoire SRAM dédiée sur la puce pour effectuer des tâches d'intelligence artificielle à grande vitesse. Cette « solution monopuce » empile le capteur et le matériel de traitement de l'IA dans une seule unité, optimisant l'ensemble du système pour un traitement de l'IA à faible latence et à faible consommation.

Voici quelques-unes des caractéristiques marquantes de l'IMX500 :

- Capteur 1/2,3" : L'IMX500 est doté d'un capteur qui prend en charge des résolutions allant jusqu'à  $4\ 056 \times 3\ 040$  pixels, ce qui le rend capable de capturer des images de haute qualité tout en exécutant des modèles d'IA en temps réel.
- Traitement optimisé de l'IA : L'accélérateur d'IA intégré élimine le besoin de processeurs ou de mémoire externes hautes performances, ce qui en fait une solution plus rentable et plus fiable. Cela se traduit par une réduction des coûts matériels et une amélioration de l'efficacité énergétique.
- Faible latence : En traitant l'inférence IA directement sur le capteur, l'IMX500 élimine la nécessité d'envoyer les données à un serveur ou à un accélérateur IA externe. Cela réduit considérablement le temps de latence et garantit que les décisions en matière d'IA sont prises presque instantanément.
- Confidentialité dès la conception : Le capteur peut émettre uniquement les métadonnées traitées, ce qui garantit que les données d'image brutes ne quittent jamais la puce si la protection de la vie privée est une préoccupation. Cette fonction est particulièrement utile dans les applications où les réglementations en matière de protection de la vie privée sont strictes, telles que les déploiements de magasins ou de villes intelligentes.

### Comment fonctionne l'IMX500

L'innovation majeure de l'IMX500 réside dans sa capacité à réali-



Figure 2: The Raspberry Pi AI Camera won't even tax a Raspberry Pi Zero.

ser l'inférence de l'IA directement sur le capteur. Les systèmes de vision classiques nécessitent l'envoi des images capturées à une unité de traitement centrale, un accélérateur d'IA externe, ou même un serveur distant. Ce transfert peut entraîner des délais significatifs, augmenter la consommation de bande passante et d'énergie, ce qui ralentit le traitement.

Avec l'IMX500, ces contraintes sont éliminées. Le capteur lui-même capture les données d'image brutes, les traite à l'aide de réseaux neuronaux pré-entraînés et restitue les résultats sous forme de métadonnées. Le Raspberry Pi - tout modèle doté d'un connecteur de caméra, du Raspberry Pi Zero (figure 2) au Raspberry Pi 5 - reçoit à la fois les données d'image et les résultats de l'IA en parallèle, ce qui permet au système d'effectuer des tâches telles que la détection d'objets et l'estimation de la pose sans matériel supplémentaire ni traitement complexe sur le Pi.

La capacité de l'IMX500 à recadrer et à mettre à l'échelle les images avec sa fonction intégrée de région d'intérêt (ROI) est un autre grand avantage. Cette fonction permet au capteur de se concentrer sur des zones spécifiques de l'image, garantissant que seules les parties pertinentes sont traitées par le réseau neuronal, ce qui optimise les performances et accélère l'inférence de l'IA, le tout sans utiliser le CPU de votre système hôte.

### Caractéristiques principales de l'IMX500 de Sony

Les principales spécifications sont assez impressionnantes pour un appareil photo qui est ostensiblement utilisé uniquement pour les applications d'IA, qui ne nécessitent généralement pas de résolutions super élevées :

- › Taille de l'image : 4 056 × 3 040 - c'est un peu plus que le 4K UHD en largeur, mais son rapport d'aspect 4:3 signifie 40 % de pixels en plus en hauteur.
- › Taille des pixels : 1,55 µm, ce qui permet à la caméra de capturer des images détaillées même dans des conditions d'éclairage difficiles.
- › Fréquence d'images : La caméra prend en charge jusqu'à 30 images par seconde (ips) à une résolution de 2 028 × 1 520 pixels et 10 fps à son impressionnante résolution complète, ce qui la rend adaptée aux applications vidéo en temps réel.
- › Longueur focale : 4,74 mm, avec une mise au point manuelle réglable allant de 20 cm à l'infini.
- › Champ de vision : Horizontal 66° ±3°, Vertical 52,3° ±3°, offrant une vue grand angle adaptée à diverses applications.
- › Température de fonctionnement : 0°C à 50°C.
- › Taille : 25 × 24 × 11,9 mm, c'est légèrement plus grand que le Raspberry Pi Camera Module 3, mais toujours assez compact pour s'intégrer dans de nombreuses applications existantes.

### Applications basées sur l'IA avec l'IMX500

Les capacités d'IA embarquées de la Sony IMX500 ouvrent un vaste champ de possibilités pour les applications basées sur la vision. En réalisant l'inférence d'IA directement sur le capteur, l'IMX500 permet l'utilisation de modèles d'apprentissage automatique avancés sans nécessiter d'accélérateurs matériels externes comme le Hailo ou le Coral TPU. Voici quelques applications possibles :

- › Détection d'objets : En utilisant le réseau neuronal MobileNet SSD, la caméra peut détecter des objets en temps réel, en fournissant des boîtes de délimitation et des valeurs de confiance pour chaque objet détecté. Elle est ainsi idéale pour des applications telles que les systèmes de sécurité, la vente au détail automatisée ou la surveillance industrielle.
- › Estimation de la pose : Grâce au réseau neuronal PoseNet, la caméra peut suivre et estimer les poses humaines en temps réel. Cette fonction trouve des applications dans les domaines de la santé, du suivi de la condition physique et de la robotique, où il est essentiel de comprendre les mouvements humains.
- › Segmentation sémantique des images : L'IMX500 permet une classification des images jusqu'au niveau du pixel, facilitant ainsi des applications sophistiquées telles que la surveillance dans les usines intelligentes ou la gestion d'infrastructures urbaines intelligentes.
- › Vision préservant la vie privée : Comme l'IMX500 est capable de traiter les images sur le capteur lui-même et n'émettre que les métadonnées, il convient parfaitement aux applications où la confidentialité est primordiale. Si vous le souhaitez, il peut analyser le trafic piétonnier ou détecter des comportements spécifiques sans jamais transmettre de données d'image brutes.

### Cas d'utilisation dans l'industrie

L'IMX500 a déjà démontré son efficacité dans divers secteurs, ouvrant la voie à une multitude d'applications de vision intelligente :

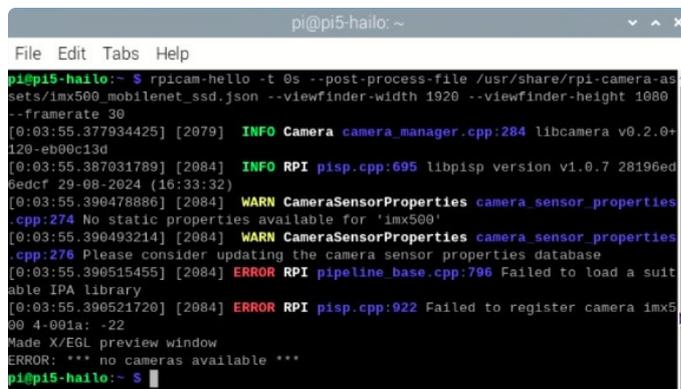


Figure 3. Le message « No cameras available » a persisté au début.

- › Commerce de détail intelligent : Dans les environnements de vente au détail, l'IMX500 peut être utilisé pour analyser le comportement des clients, détecter les produits et gérer les stocks en temps réel, tout en respectant la vie privée des clients.
- › Villes intelligentes : Les villes peuvent exploiter la capacité de la caméra à classer les objets (tels que les véhicules ou les piétons) et à détecter les situations dangereuses en temps réel, contribuant ainsi à des environnements urbains plus sûrs et plus efficaces.
- › Usines intelligentes : Dans les environnements industriels, l'IMX500 peut surveiller les lignes de production, détecter les anomalies et assurer la sécurité des travailleurs en suivant les mouvements dans les zones désignées.

Ces applications témoignent de la capacité de l'IMX500 à réduire la complexité et les coûts des systèmes tout en améliorant leur fiabilité et efficacité énergétique.

### Configuration

Il est donc temps pour moi de le configurer et de le faire fonctionner. Comme toujours, il y a eu quelques défis d'installation. Tout d'abord, j'ai procédé à la mise à jour et à la mise à niveau comme le recommande la documentation officielle [1] :

```
sudo apt update && sudo apt full-upgrade
```

J'ai ensuite installé le micrologiciel IMX500...

```
sudo apt install imx500-all
```

...et j'ai effectué le redémarrage recommandé :

```
sudo reboot
```

Cela aurait dû suffire, et j'aurais pu essayer de détecter des objets avec la commande

```
rpicas-hello -t 0s --post-process-file /usr/share/rpi-camera-assets/imx500_mobilenet_ssd.json --viewfinder-width 1920 --viewfinder-height 1080 --framerate 30
```

Cependant, au lieu de pouvoir démarrer immédiatement, je me suis heurté à l'erreur « aucune caméra disponible » (figure 3). Malgré plusieurs tentatives avec deux caméras différentes, deux câbles distincts et trois Raspberry Pis (deux modèles 5 et un modèle 4), je n'ai pas pu faire fonctionner l'application. J'ai consulté les forums, j'ai fait des recherches sur Google, et tout ce que j'ai obtenu, ce sont



Figure 4. Quelques framboises sur une tarte, ou un « donut » selon le modèle entraîné.

les étapes de dépannage génériques « l'avez-vous branché correctement ? ». Contraint de prendre du recul, j'ai réessayé plus tard et, curieusement, tout a fonctionné parfaitement. Je ne saurais dire exactement comment le problème a été résolu, mais si vous rencontrez cette difficulté, sachez que vous n'êtes pas le seul. Une fois la caméra reconnue, j'ai eu besoin de voir le flux en direct. Bien que je ne sois pas un grand fan de l'utilisation des interfaces graphiques sur les systèmes embarqués, pour les tâches de caméra en direct, elles ont certainement leurs charmes. Mais je n'avais pas envie de brancher une souris, un clavier et un moniteur, alors j'ai utilisé le service Raspberry Pi Connect [2], toujours en version bêta, car SSH ne convenait pas pour cette tâche. J'ai rencontré quelques problèmes mineurs, ce qui est à prévoir avec une version bêta. Avec la caméra fonctionnelle et Raspberry Pi Connect opérationnel sur mon ordinateur portable sous Windows 11, j'ai pu me déplacer et tester la caméra "dans la nature". Anticipant que les caméras IA seront utilisées dans divers environnements, j'ai voulu tester la mienne en extérieur, dans des conditions d'éclairage moins contrôlées.

### Détection d'objets

En utilisant la ligne de commande `rpical-hello` mentionnée plus haut, j'ai essayé la détection d'objets. Celle-ci identifie les objets en fournissant des boîtes de délimitation et des valeurs de confiance pour chaque objet détecté. Le traitement se fait directement sur la caméra, sans aucun post-traitement significatif nécessaire sur le Raspberry Pi lui-même. Une fois le tenseur de sortie généré, le système peut dessiner des boîtes de délimitation et des étiquettes sur l'image.



Figure 5. Ashton semble avoir le don fascinant de passer d'une espèce de mammifère à l'autre..

J'ai testé une variété d'objets du quotidien, essayant même de faire reconnaître des framboises. La caméra m'a informé que je regardais probablement un "ours en peluche". Ensuite, j'ai essayé avec une tarte, mais sans résultat. Alors, j'ai disposé les framboises sur la tarte (Figure 4), et à ma grande surprise, cela a été identifié comme un "beignet". C'était amusant, la tarte a été appréciée et les enfants ont découvert qu'ils aimaient maintenant les framboises. En parlant des enfants, voulant ajouter de l'action, j'ai sollicité l'aide de Chase et Ashton, plus énergiques que moi. J'ai ensuite testé avec des cibles en mouvement. Lorsqu'Ashton jouait avec un ballon de football, un être humain a été identifié (voir **figure 5**, à gauche), cependant le ballon n'a pas été reconnu, du moins dans ces conditions d'éclairage spécifiques. Lorsque je lui ai demandé de s'accroupir et de saisir le ballon, il a été immédiatement catégorisé comme un « chien » (voir **figure 5**, à droite).

### Estimation de la pose

Pour l'estimation de la pose, la caméra utilise PoseNet, un réseau neuronal qui marque des points clés sur le corps, identifiant les articulations et les membres. Contrairement à la détection d'objets, l'estimation de la pose nécessite un post-traitement supplémentaire sur le Raspberry Pi pour générer le résultat final. Une fois opérationnelle, nous avons pu superposer des figures en bâtonnets, à la fois dans de bonnes conditions d'éclairage (**figure 6**, gauche), et quand il faisait un peu plus sombre (**figure 6**, centre). Cependant, lors de tests à grande vitesse, comme Chase sprintant devant l'objectif, la caméra a parfois perdu la trace des figures, allant jusqu'à "poursuivre" Chase (**figure 6**, droite). Elle a également eu des difficultés avec le flou de mouvement, donc un bon éclairage



Figure 6. Chase a besoin de ralentir dans l'obscurité.

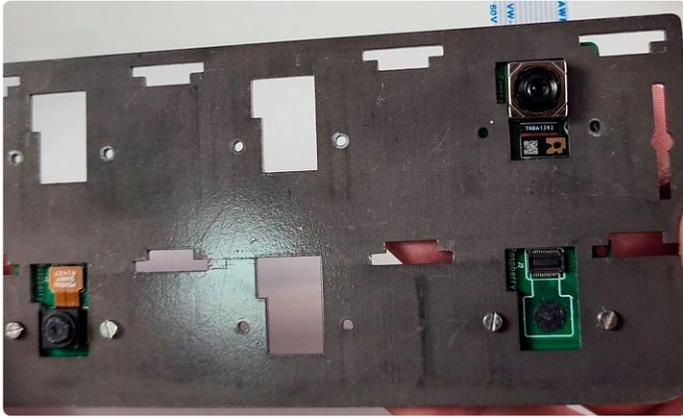


Figure 7. Le Raspberry Pi Camera Module 3 et les modèles antérieurs s'adaptent à ce gabarit de test multi-caméras.



Figure 8. Le Raspberry Pi AI Camera peut ne pas s'adapter aux boîtiers de caméra précédents.

serait préférable pour des résultats fiables. Outre le contrôle de l'éclairage, vous pourriez également ajuster la luminosité, l'exposition et les paramètres ISO depuis la ligne de commande pour maintenir une qualité d'image décente. Votre application finale pourrait devoir automatiser cela si vous ne pouvez pas contrôler l'éclairage ambiant.

### Compatibilité mécanique

Le module de la caméra AI est légèrement plus grand que les caméras Raspberry Pi précédentes, ce qui signifie qu'il n'est pas totalement compatible avec tous les boîtiers antérieurs. Je l'ai découvert par moi-même lorsque j'ai tenté d'installer la caméra AI dans un dispositif de test que j'avais fabriqué pour comparer plusieurs versions du module de caméra Raspberry Pi. Le module de caméra 3 s'adaptait bien (**figure 7**), mais pas la caméra AI Raspberry Pi (**figure 8**). Le marché des accessoires tiers comblera sans doute ce vide, mais vous pourriez toujours imprimer quelque chose en 3D, comme l'a fait Raspberry Pi eux-mêmes (**figure 9**) lors de la présentation de la caméra avant son lancement officiel.

### Beaucoup de potentiel

Vous disposez désormais d'une AI Camera qui ne sollicite pas outre mesure votre CPU et ne nécessite pas, par exemple, l'ajout d'un accélérateur externe sur votre Raspberry Pi M.2 HAT+, ce qui pourrait monopoliser le bus que vous préféreriez peut-être réserver pour un SSD. Malgré des difficultés initiales, la caméra a démontré un poten-



Figure 9. Le Raspberry Pi AI Camera a été dévoilée en avant-première avec un boîtier imprimé en 3D.

tiel remarquable. Avec ses fonctionnalités de détection d'objets et d'estimation de la pose déjà activées, j'ai seulement commencé à explorer ce qu'elle est capable d'accomplir. Grâce à la puissance de traitement IA intégrée du Sony IMX500, cette caméra se révèle être un outil précieux pour les maker, les éducateurs, et quiconque est intéressé par l'expérimentation de l'Edge AI. ◀



240635-04

### À propos de l'auteur

Brian Tristam Williams est passionné par les ordinateurs et l'électronique depuis l'obtention de son premier micro-ordinateur à l'âge de 10 ans. Son parcours avec Elektor Magazine a débuté à 16 ans, lorsqu'il a acheté son premier numéro. Depuis, il s'immerge dans l'univers de l'électronique et de l'informatique, toujours avide de découvrir et d'apprendre. Entré chez Elektor en 2010, il se consacre aujourd'hui à l'étude des évolutions technologiques récentes, avec un intérêt particulier pour l'intelligence artificielle et les ordinateurs à carte unique comme le Raspberry Pi.

### Questions ou commentaires ?

Nous souhaitons connaître votre utilisation de l'IA et son impact sur vous ces deux dernières années. Si vous avez des questions ou souhaitez partager vos commentaires, n'hésitez pas à m'envoyer un courriel à [brian.williams@elektor.com](mailto:brian.williams@elektor.com). Retrouvez-moi également chaque mois dans Elektor Engineering Insights sur YouTube, ou suivez-moi sur X @briantw.

### Produits

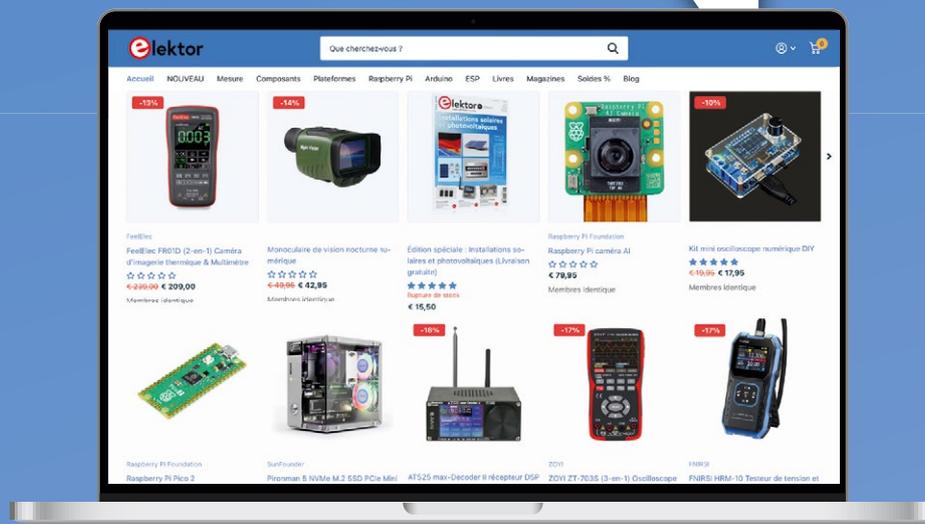
- ▶ **Raspberry Pi AI Camera**  
[www.elektor.fr/20953](http://www.elektor.fr/20953)
- ▶ **Raspberry Pi Zero 2 WH**  
[www.elektor.fr/20952](http://www.elektor.fr/20952)
- ▶ **Raspberry Pi 5 (4 GB RAM)**  
[www.elektor.fr/20598](http://www.elektor.fr/20598)



### LIENS

- [1] Raspberry Pi Documentation: AI Camera: <https://raspberrypi.com/documentation/accessories/ai-camera.html>  
 [2] Raspberry Pi Connect remote control: <https://www.raspberrypi.com/software/connect>

# Quel est votre avis ?



Chez Elektor, nous offrons bien plus que de simples produits électroniques – nous créons une expérience avec des produits de qualité et un service client exceptionnel, soutenus par la passion de notre communauté.

Partagez votre avis sur  
[www.elektor.fr/pages/customer-reviews](http://www.elektor.fr/pages/customer-reviews)



★★★★★

### Très bonne présentation

Malgré mon anglais technique poussif, la présentation et le développement du sujet aident vraiment le novice que je suis. Les programmes, sur fond bleu, se détachent parfaitement du reste du texte.

★★★★★

### Un utilisateur satisfait de son achat

Excellent rapport qualité/prix, regulation en température précise, n'a rien à envier à une marque commençant par un "W", dont les produits équivalent sont beaucoup plus chers. Je conseille cette station de soudage.

★★★★★

### Très bon service client Elektor

Malgré un problème de composants oubliés, j'ai reçu un autre exemplaire du kit dans un délai très rapide.

Bravo pour cette efficacité devenue trop rare.

# L'intelligence artificielle dans Elektor

L'équipe Elektor

Rejoignez-nous pour un voyage fascinant à travers les archives d'Elektor, où nous explorons l'évolution de l'intelligence artificielle (IA) au sein de la communauté électronique. Des premières expériences d'apprentissage automatique à l'intégration de l'IA dans les projets modernes, découvrez comment l'IA a influencé les tendances technologiques, inspiré l'innovation et façonné l'avenir de la conception électronique. Explorez nos meilleurs articles sélectionnés par la rédaction.

Autrefois science-fiction, l'intelligence artificielle (IA) est aujourd'hui une pierre angulaire de la technologie moderne. Elektor, pionnier de l'électronique avec des articles remontant à 1961, a été à l'avant-garde de cette évolution, explorant le potentiel de l'IA dès ses premiers développements. Que vous feuilletiez manuellement les anciennes éditions du magazine *Elektor* ou que vous utilisiez la version bêta de notre Elektor GPT [1], vous découvrirez que les thématiques liées à l'IA sont présentes depuis des décennies. De la couverture des réseaux neuronaux et de la logique floue dans les années 1970 et 1980 à l'analyse des projets actuels intégrant des technologies d'IA avancées, notre contenu a constamment reflété les avancées spectaculaires de cette technologie. Nous vous invitons à explorer une sélection rigoureuse d'articles significatifs sur l'IA, extraits de nos archives étendues. Si tous les articles ne se concentrent pas explicitement sur l'IA, les concepts et innovations discutés, tels que la reconnaissance de motifs, l'automatisation et l'apprentissage automatique, sont cruciaux pour le développement de l'intelligence artificielle.

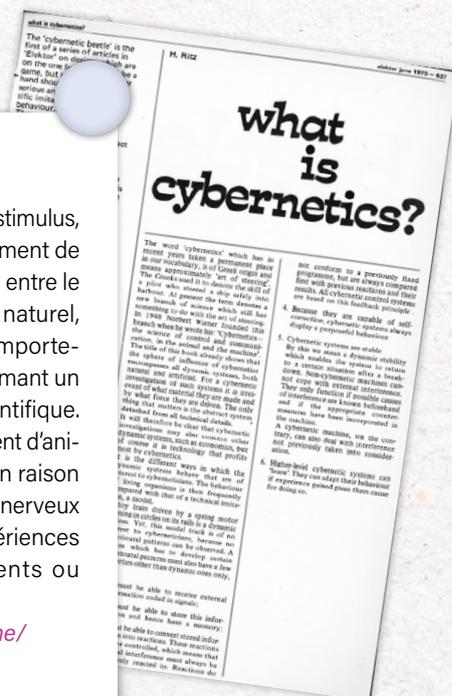
## Qu'est-ce que la cybernétique ? (Elektor, juin 1975)

**Focus :** Discussions sur les modèles cybernétiques simulant le comportement animal, explorant les concepts d'apprentissage, d'adaptabilité et d'intelligence dans les systèmes artificiels.

Le « scarabée cybernétique » est le premier d'une série d'articles dans Elektor sur des réalisations qui, bien qu'apparemment ludiques, doivent être pris au sérieux comme des tentatives parfois scientifiques d'imiter le comportement animal. Équipés d'un « système nerveux » électronique, ces projets cybernétiques réagissent de manière ciblée aux stimuli externes acoustiques, optiques et tactiles. La conception de ces modèles permet d'adapter

la réponse non seulement au type de stimulus, mais aussi à l'état du système au moment de sa réception. Plus la correspondance entre le stimulus et la réaction est fidèle au naturel, plus le modèle se rapproche du comportement de l'animal représenté, transformant un simple jouet en un outil d'étude scientifique. Cependant, reproduire le comportement d'animaux évolués reste un défi majeur en raison des capacités limitées des systèmes nerveux électroniques, limitant ainsi les expériences scientifiques à des comportements ou modèles simplifiés. Lire la suite :

[www.elektormagazine.com/magazine/elektor-197506/57395](http://www.elektormagazine.com/magazine/elektor-197506/57395)



**L'ordinateur et les échecs : Comment pense le monstre (Elektor, février 1979)**

**L'ordinateur et les échecs**

Comment pense le monstre

Le jeu d'échecs nous est apparu pendant longtemps comme un symbole des processus intellectuels de l'homme. Tout récemment, la perspective de voir un champion humain - battu par un ordinateur jouant aux échecs nous semblait encore lointaine. Cependant, il y a quelques mois, au cours d'un match qui a fait l'objet d'une importante publication internationale publiée d'échecs, David Levy, a été défait par un ordinateur programmé par son frère, le programmeur américain de programmation venant d'Amérique du Nord. L'histoire de cette partie est racontée par M. Levy lui-même dans un autre article de ce numéro.

Le présent article nous décrit le contexte dans lequel les ordinateurs jouent aux échecs : il souligne leurs points forts et leurs faiblesses, et s'appuie sur les échecs que possèdent Karpov et le dernier Champion du Monde d'échecs constitué de chair et d'os.

Il y a trente ans, l'ordinateur électronique était encore dans l'enfance, et avant toute chose il avait été conçu pour résoudre les problèmes de la thermo-dynamique. A cette époque, si un d'échecs était programmé, il était destiné à servir d'exercice de programmation pour les étudiants de l'Université anglaise Clarendon. Le match programmé entre l'ordinateur et un champion humain n'a eu lieu qu'en 1949, et ce n'est qu'en 1956 qu'il a été programmé pour jouer aux échecs. C'est en 1949 qu'il a été programmé pour jouer aux échecs. C'est en 1949 qu'il a été programmé pour jouer aux échecs. C'est en 1949 qu'il a été programmé pour jouer aux échecs.

*Le développement d'ordinateurs jouant aux échecs et les contributions clés à l'intelligence artificielle, en particulier celles de Claude Shannon.*

Il y a trente ans, l'ordinateur électronique était encore dans l'enfance, et avant toute chose il illustrait le premier principe de la Thermo-dynamique : tout travail est de la chaleur. À cette époque, le jeu d'échecs attirait l'attention de nombreux chercheurs travaillant dans le domaine de l'intelligence artificielle. Le mathématicien anglais Claude Shannon a été le premier qui ait vraiment proposé une méthode permettant de programmer un ordinateur pour jouer aux échecs. C'est en 1949 qu'il a publié, sous le titre "Programming a computer for playing chess" (comment programmer un ordinateur pour jouer aux échecs), un article fondamental, à la fois parce que c'était le premier article publié sur ce sujet, mais surtout parce que la plupart des idées de Shannon sont toujours utilisées de nos jours par les plus puissants des programmes de jeu d'échecs. L'intérêt porté par Shannon à la programmation des échecs était dû à ce qu'il croyait que le jeu est un moyen idéal de tester l'intelligence d'une machine. Le jeu d'échecs est clairement défini en termes d'opérations licites (le mouvement des pièces) et d'objectif final (le mat), tout en n'étant ni trop simple, au point d'être trivial, ni trop complexe, au point de ne pas pouvoir se prêter à l'analyse. Lire la suite :

[www.elektormagazine.fr/magazine/elektor-197902/54014](http://www.elektormagazine.fr/magazine/elektor-197902/54014)



**Échiquier, pièces et mouvements**  
Shannon a proposé de représenter l'échiquier dans la machine en utilisant une case de la mémoire de l'ordinateur à chaque case de l'échiquier. Chaque pièce est alors décrite par une valeur numérique. Il y a 26 cases blanches, 26 pour les blancs et 26 pour les noirs, soit 52 cases au total. Ces nombres qui représentent la case de l'échiquier occupent une case de mémoire appropriée. De nombreux programmes ont été écrits et ont permis de tester l'efficacité de cette méthode. À l'époque, on ne pouvait pas programmer un ordinateur pour qu'il jouait aux échecs.

**ARTIFICIAL INTELLIGENCE**  
by M. Seymour, BSc, University of St. Andrews

Man is intelligent, but his intelligence is often thwarted (or worse) by his environment. That realization has given rise to a dream: that one day it may be possible to build a machine that can think. That is, need not be programmed to perform its functions.

Machine intelligence has been the subject of many papers. The most famous is that of Alan Turing (1912-1954), who proposed the Turing Machine, which is a machine that can be programmed to perform any function that can be described by a finite set of instructions. This is the basis of modern computers. It is also the basis of artificial intelligence. It is the most general concept of intelligence that we have at present. It is the most general concept of intelligence that we have at present.

**SCIENCE & TECHNOLOGY**  
Intelligence, Intentionality and Self Awareness  
by Dr T. Farrimond, University of Waikato, New Zealand

This paper deals with some of the problems in ascribing intelligence to computers. It is suggested that machines which only process the symbols of language are not intelligent even though they may produce an output similar to that from an intelligent human. It is maintained that self awareness in humans, coupled with the ability to interact directly with the environment by means of the development of a social-ecological conscience.

**Intelligence artificielle (Elekter, mai 1988)**

*Focus : L'évolution de l'intelligence artificielle, depuis Charles Babbage et Alan Turing jusqu'à son développement en tant que domaine reconnu en 1956, tout en abordant les idées fausses et les mythes qui entourent l'intelligence des machines.*

L'intelligence humaine est certes remarquable, mais elle peut être entravée, voire compromise, par son environnement. Cette réalité a nourri un rêve ambitieux : celui de créer un jour une machine capable de penser de manière autonome, sans nécessiter de programmation spécifique pour réaliser ses tâches. Charles Babbage (1792-1871) fut le pionnier de cette idée, envisageant pour la première fois le concept d'intelligence mécanique. Plus tard, Alan Mathison Turing (1912-1954), célèbre pour la machine de Turing, a largement contribué à cette vision. Sa machine illustre que les machines sont des entités mathématiques et son théorème démontre que l'ensemble des opérations mathématiques calculables coïncide avec celles réalisables par une machine. Turing a aussi proposé une théorie sur les questions auxquelles une machine intelligente pourrait théoriquement répondre. L'intelligence artificielle, qui s'est développée à partir des recherches en informatique numérique pendant la Seconde Guerre mondiale, a été reconnue comme une discipline à part entière en 1956. Depuis, elle a engendré de nombreux mythes, notamment dans la presse grand public. Toutefois, les allégations selon lesquelles les ordinateurs peuvent accomplir des tâches sans intervention humaine sont souvent démenties après vérification, révélant qu'il s'agit plutôt d'illusions d'intelligence, résultant de la capacité des ordinateurs à traiter les données à une vitesse extraordinaire. Lire la suite :

[www.elektormagazine.com/magazine/elektor-198805/47340](http://www.elektormagazine.com/magazine/elektor-198805/47340)

**Intelligence, intentionnalité et conscience de soi (Elekter, novembre 1989)**

*Focus : Discussion de certains problèmes liés à l'attribution de l'intelligence aux ordinateurs, et étude de l'intentionnalité, de l'origine de la conscience de soi, et des traductions du cerveau et de la machine.*

Dans son article « Artificial Intelligence », M. Seymour propose un compte rendu à la fois intéressant et éclairant sur les défis rencontrés par les concepteurs d'ordinateurs dans le développement de machines dotées d'intelligence artificielle. L'article débat des arguments pour et contre la définition de ce que constitue l'intelligence artificielle, abordant notamment la question de l'intentionnalité, comme le souligne Searle en 1984. Ce document explore ces concepts du point de vue d'un psychologue qui était étudiant à Manchester au moment où Alan Turing étudiait les aspects théoriques du traitement de l'information. Bien que la puissance des dispositifs électroniques ait considérablement augmenté depuis lors, la terminologie utilisée pour décrire les processus informatiques et les fonctions cérébrales n'a pas évolué de manière similaire. À la base, nous observons une résurgence de l'anthropomorphisme, souvent critiquée par les biologistes qui refusent de prêter des traits humains aux comportements des animaux moins évolués. Par ailleurs, l'imprécision du langage se manifeste également dans des expressions comme « les ordinateurs parlent entre eux ». Cette façon de s'exprimer résulte souvent d'une simplification linguistique, préférant réutiliser des concepts existants plutôt que d'en créer de nouveaux. Toutefois, cette approche comporte des risques, notamment celui de diluer les concepts à un point tel qu'ils deviennent non justifiables. Lire la suite :

[www.elektormagazine.com/magazine/elektor-198911/47684](http://www.elektormagazine.com/magazine/elektor-198911/47684)

## FUZZY LOGIC: AN INTRODUCTION

Fuzzy logic is a kind of statistical reasoning, whose foundations can be said to have been laid in the 18th century by the British philosopher Thomas Bayes. With this technique, large amounts of data can be condensed into a much smaller set of variable rules than with rigid logic. The result is an expert system that can process information faster, and provide a more flexible, more human-like response than conventional logic.

The great German polymath, Gottfried Leibniz (1646-1716), dreamed about creating a way whereby complicated

### la logique floue : Une introduction (Elektor, juillet 1992)

**Focus :** Introduction à la logique floue en tant que méthode de raisonnement flexible adaptée aux systèmes experts et aux réponses de type humain dans l'intelligence artificielle.

La logique floue est une forme de raisonnement statistique, dont les fondements remontent au XVIII<sup>e</sup> siècle avec le philosophe britannique Thomas Bayes. Cette technique permet de condenser de grandes quantités de données en un ensemble de règles variables bien plus restreint que la logique rigide. Elle aboutit à la création de systèmes experts capables de traiter l'information plus rapidement et d'offrir une réponse plus flexible et plus proche du raisonnement humain que la logique conventionnelle. Le grand polymathe allemand, Gottfried Leibniz (1646-1716), rêvait de concevoir une méthode permettant à des philosophes de discuter et de résoudre tout différend humain une fois pour toutes par la pure logique. Cependant, lui et de nombreux autres penseurs après lui ont découvert qu'il existe de nombreux problèmes qui ne peuvent être résolus par la seule logique. Cette prise de conscience a donné naissance à une autre manière de tenter de résoudre les problèmes : l'utilisation des statistiques. Dans le raisonnement statistique, les probabilités expriment l'idée du « peut-être ». La logique floue, qui est une méthode de ce type de raisonnement et dont les bases ont été posées au XVIII<sup>e</sup> siècle par Thomas Bayes, ne se limite pas au « vrai » et au « faux », aux 1 et aux 0, au « noir » et au « blanc », mais inclut également toutes les différentes nuances de gris intermédiaires. Ainsi, la logique floue peut condenser d'importants volumes de données en un ensemble de règles variables beaucoup moins volumineux que la logique rigide. Le résultat est un système expert capable de traiter l'information plus rapidement et de fournir une réponse plus flexible et plus humaine que la logique conventionnelle. Lire la suite :

[www.elektormagazine.com/magazine/elektor-199207/32683](http://www.elektormagazine.com/magazine/elektor-199207/32683)

Les rédacteurs ont utilisé Elektor GPT (Archive Assistant) pour rechercher du contenu dans des articles précédents d'Elektor. Qu'est-ce que c'est et que propose-t-il ? Fait-il partie de ChatGPT ?



Drafts  

 Elektor GPT (Archive Assistant), dont la version bêta a été mise en ligne en avril 2024, est un outil conçu pour aider les utilisateurs à rechercher et accéder efficacement aux archives numériques du magazine Elektor. Il permet aux membres de la communauté Elektor de retrouver rapidement des articles, des projets et des ressources liés à l'électronique, facilitant ainsi leurs recherches et la planification de leurs projets. Les membres de la communauté peuvent l'utiliser pour rechercher des sujets spécifiques, localiser d'anciens numéros ou explorer des articles correspondant à leurs centres d'intérêt, leur faisant ainsi gagner du temps et des efforts dans l'exploration de la vaste collection de contenus d'Elektor.

 Enter a prompt for ChatGPT   

MICROINFORMATIQUE

## Les réseaux neuraux aux commandes

Les neuro-ordinateurs

### Les réseaux neuraux aux commandes : Les neuro-ordinateurs à nos portes (Elektor, octobre 2001)

**Focus :** Présentation des neurones, des possibilités de mise en œuvre du neuro-ordinateur, de la modélisation d'un réseau de neurones artificiels (ANN) et de l'entraînement.

Normalement, les neurones sont organisés en structures parfaitement définies, telles que, par exemple, le cerveau, la moelle épinière et les nerfs périphériques. Chaque neurone est un centre de transfert d'information (Note : nous disons bien transfert et non pas stockage). Il peut recevoir de l'information sous la forme de signaux électriques en provenance d'un nombre d'autres neurones du réseau, traiter cette information et la passer à d'autres neurones. Au niveau du cerveau humain, par exemple, un neurone est connecté à jusqu'à 10 000 autres neurones. L'art et la manière de ce transfert d'information de neurone à neurone dépendent du

nombre de connexions physiques existant entre les neurones et de l'intensité (la force) de chaque connexion. Le nombre de connexions possibles est bien plus important que le nombre de neurones présents. On estime qu'un cerveau humain pourrait comporter jusqu'à 1016 connexions, une ressource énorme pour la mémoire et des actions intelligentes. Dès lors que l'on admet que le réseau neural d'un animal est capable d'actions de reconnaissance complexe et de contrôle, les scientifiques ont essayé de créer un équivalent artificiel, un réseau neural artificiel (un ANN = Artificial Neural Network). Un ANN est constitué d'unités de neurones simulant l'action des neurones d'un animal. Ils comportent des étages d'entrée, de traitement et de sortie. Les premiers ANN électroniques ayant jamais été conçus étaient basés sur des tubes, mais

les progrès furent très minces jusqu'à l'arrivée des VLSI, les composants à intégration très élevée. De nos jours, étant donnée la puissance de calcul du plus petit des ordinateurs haut de gamme, nous pouvons reproduire un modèle mathématique des ANN. Comme le prouve le logiciel décrit un peu plus loin, ces opérations peuvent être réalisées à l'aide d'un système faisant appel à des microprocesseurs conventionnels. Il existe également une approche utilisant des processeurs spécifiques créés selon les spécifications du client pour la réalisation de vrais neuro-ordinateurs. Ils ont été conçus pour exceller dans les types de traitements spécifiques requis pour simuler des ANN, où l'approche par traitement parallèle semble être la plus efficace.

[www.elektormagazine.fr/magazine/elektor-200106/9136](http://www.elektormagazine.fr/magazine/elektor-200106/9136)

# La pratique des réseaux neuraux

1ère partie : introduction aux réseaux neuraux

Chris McLeod et Grant Maxwell

Les réseaux neuraux artificiels, en abrégé ANN, sont une forme célèbre de l'intelligence artificielle. Ils se basent sur les modes opératoires des cellules nerveuses et de nombreux chercheurs estiment qu'ils sont notre meilleur espoir d'introduire l'intelligence dans une machine. Si vous êtes un amateur de la série télévisuelle « Star Trek », vous savez que M. Data est d'un cerveau « neuronique », de même que le robot

Mais que ces merveilleuses technologies soient le nez plus près de la machine ou du cerveau, ce sujet fascinant d'une manière pratique, ce qui vous permettra d'expérimenter vos propres réseaux neuraux. Un réseau neural est un réseau de processeurs interconnectés. Chaque processeur individuel n'est capable de réaliser qu'une tâche mathématique très simple, mais leur interconnexion fournit des résultats complexes. Le schéma de la figure 1 présente un réseau neural type. Pour comprendre le fonctionnement d'un réseau neural, examinons l'objet qui l'inspire : le cerveau. Ce qu'on nomme communément les « cellules nerveuses » sont baptisées « neurones » par les biologistes. Ce sont de minuscules cellules vivantes, qui composent notre cerveau et notre système nerveux. Tout individu en comporte environ une centaine de milliards. Lire la suite :

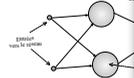


Figure 1. Un réseau neural type.



Figure 2. Un neurone biologique.

## La pratique des réseaux neuraux (Elektor, février 2003)

**Focus : les réseaux neuronaux, la création et l'histoire des ANN, ainsi que les algorithmes d'apprentissage et de formation.**

Les réseaux neuraux artificiels, en abrégé ANN (Artificial Neural Networks), sont une forme célèbre de l'intelligence artificielle (IA). Ils se basent sur les modes opératoires des cellules nerveuses et de nombreux chercheurs estiment qu'ils sont notre meilleur espoir d'introduire une véritable intelligence dans une machine. Si vous êtes un amateur de la série télévisuelle « Star Trek », vous savez que M. Data est supposé disposer d'un cerveau « neuronique », de même que le robot de Terminator. Bien que ces merveilles technologiques soient le nec plus ultra de la recherche en informatique, ils sont aussi à la portée de l'amateur enthousiaste. Le but de ces articles est de présenter ce sujet fascinant d'une

manière pratique, ce qui vous permettra d'expérimenter vos propres réseaux neuraux. Un réseau neural est un réseau de processeurs interconnectés. Chaque processeur individuel n'est capable de réaliser qu'une tâche mathématique très simple, mais leur interconnexion fournit des résultats complexes. Le schéma de la figure 1 présente un réseau neural type. Pour comprendre le fonctionnement d'un réseau neural, examinons l'objet qui l'inspire : le cerveau. Ce qu'on nomme communément les « cellules nerveuses » sont baptisées « neurones » par les biologistes. Ce sont de minuscules cellules vivantes, qui composent notre cerveau et notre système nerveux. Tout individu en comporte environ une centaine de milliards. Lire la suite :

<https://www.elektormagazine.fr/magazine/elektor-200302/9555>

ENTRETIEN

## apprentissage automatique : un bel avenir

Entretien avec Daniel Situnayake

### Apprentissage automatique : un bel avenir (Elektor, novembre/décembre 2020)

**Focus : l'apprentissage automatique embarqué, TinyML, Edge Impulse, et les projets TinyML.**

Daniel Situnayake est ingénieur et ingénieux. Selon ses mots, l'apprentissage automatique (machine learning en anglais, ML) est une « technique unique en son genre ». Il nous parle ici du potentiel du ML et présente TinyML, ainsi que quelques applications idéales. Nous évoquons aussi son expérience de développeur chez Google. Situnayake affirme : « Il y a quatre contraintes principales pour qu'une application soit idéale pour TinyML. Si une application a une connectivité limitée, une faible tolérance à la latence, une source d'alimentation limitée ou une exigence de confidentialité élevée, TinyML vous évitera l'envoi de données à partir de l'appareil. Seuls certains problèmes peuvent être résolus par l'apprentissage automatique. Ce sont des problèmes pour lesquels un peu de flou est acceptable, car l'apprentissage automatique donne rarement des réponses absolues. Il est parfait pour prendre des photos d'animaux, où l'erreur occasionnelle est acceptable, mais il n'est pas assez fiable dans certaines applications critiques pour la sécurité. » Lire la suite :

<https://www.elektormagazine.fr/magazine/elektor-160/59136>



### Traitement d'images avec le module Jetson Nano de Nvidia (Elektor, septembre/octobre 2021)

**Focus : le Nvidia Jetson Nano, la formation avec la Jetson Nano, le développement via un navigateur web, et plus encore.**

Aucun développeur ne devrait ignorer le potentiel de l'intelligence artificielle (IA). Des outils comme le Maixduino de Sipeed et le MAX78000 de Maxim, déjà présentés dans le magazine Elektor, sont des options appropriées pour faire vos premiers pas dans l'univers de l'IA. Pour sa part, le module Jetson Nano de Nvidia est un matériel beaucoup plus puissant de la classe des ordinateurs monocarte, doté d'un mémoire RAM d'articles, nous découvrirons les applications possibles, notamment dans les domaines du traitement d'images ou de la robotique. processeur ARM à quatre cœurs, de 4 Go de et d'un processeur graphique assorti de 128 cœurs CUDA. Dans cette série d'articles, nous découvrirons les applications possibles, notamment dans les domaines du traitement d'images ou de la robotique.

<https://www.elektormagazine.fr/magazine/elektor-184/59874>



Produit

> Archive d'Elektor (USB Stick) [www.elektor.fr/20375](http://www.elektor.fr/20375)



### LIEN

[1] Elektor GPT (ChatGPT registration necessary): <https://tinyurl.com/Elektor-GPT>

# Hailo AI Kit

## avec Raspberry Pi 5

Dogan Ibrahim (Royaume-Uni)

Pour ceux qui connaissent déjà le Raspberry Pi 5 mais hésitent à explorer l'Edge Computing et le matériel associé, le livre d'Elektor, *Getting Started with the Raspberry Pi 5 AI Kit*, constitue une excellente introduction. Ce guide est riche en exemples pratiques pour débiter efficacement la programmation IA avec le Raspberry Pi 5, s'appuyant sur le kit Raspberry Pi AI d'Elektor. Pour illustrer le potentiel de ce livre et du kit, voici un extrait qui explique comment la reconnaissance de personnes peut être effectuée de deux manières différentes à l'aide d'outils d'IA gratuits, ainsi qu'une introduction concise aux composants logiciels Hailo

**Note de la rédaction :** cet article est un extrait du livre « Getting Started with the Raspberry Pi AI Kit », qui sera publié par Elektor en 2024. Il a été formaté et légèrement modifié pour correspondre aux normes éditoriales et à la mise en page du magazine Elektor. L'auteur et l'éditeur seront heureux de répondre aux questions – pour les contacter, voir l'encadré « **questions ou commentaires ?** »..

Le kit Raspberry Pi 5 AI (**figure 1**) est un accélérateur pour l'inférence de réseaux neuronaux avec une capacité de 13 TOPS (trillions d'opérations par seconde) et est conçu autour de la puce Hailo-8L. Ce kit inclut le Raspberry Pi M.2 HAT+ et un module d'accélération Hailo AI destiné à être utilisé avec le Raspberry Pi 5. Ce module adopte le format M.2 2242 et est préinstallé dans le M.2 HAT+, auquel il se connecte via un connecteur M-key edge. Le M.2 HAT+ facilite la communication entre l'interface M.2 du module AI et l'interface PCIe 2.0 du Raspberry Pi 5. En conséquence, ce kit AI offre une solution abordable, efficace et économe en énergie, adaptée

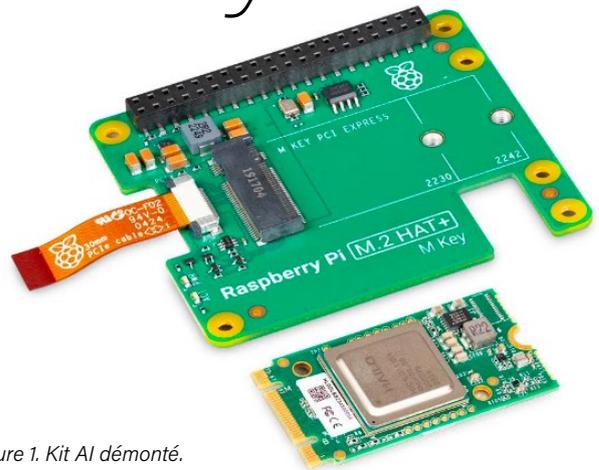


Figure 1. Kit AI démonté.

à une multitude d'applications IA, y compris la reconnaissance d'objets, l'automatisation industrielle, la gestion des processus, la sécurité, la robotique, le secteur médical et bien plus encore.

### Caractéristiques

- Contient un accélérateur d'inférence de réseau neuronal capable de 13 TOPS
- Entièrement intégré à la pile logicielle de l'appareil photo Raspberry Pi
- Le pad thermique préinstallé entre le module et le HAT+ répartit la chaleur entre les composants, améliorant ainsi les performances.
- Conforme aux spécifications du Raspberry Pi HAT+.

### Inclus

Chaque AI Kit est livré avec un module AI préinstallé, un câble ruban, un connecteur GPIO et du matériel de montage. En détail, sont inclus dans le kit :

- Accélérateur Hailo 8L avec unité de traitement neuronal (NPU).
- Raspberry Pi M.2 HAT+
- Pad thermique préinstallé entre le module et le M.2 HAT+.
- Kit de matériel d'assemblage (entretoises, vis)
- Embase d'empilage GPIO de 16 mm
- 4 entretoises filetées
- 8 vis
- 1 vis pour fixer et soutenir le périphérique M.2.

## Configuration du matériel

La **figure 2** illustre l'AI Kit monté sur un Raspberry Pi 5. Pour utiliser l'AI Kit, il doit d'abord être installé au-dessus du Raspberry Pi 5. Il est conseillé d'utiliser ce kit avec le refroidisseur actif Raspberry Pi. Si vous disposez d'un tel refroidisseur, assurez-vous de l'installer avant de monter l'AI Kit. De plus, il est préférable d'installer la caméra du Raspberry Pi 5 (par exemple, la caméra V3) avant le kit AI, ce qui facilitera le branchement du câble de la caméra.

## Installation du logiciel du AI Kit

Pour commencer, vous devez vous assurer que la dernière version du système d'exploitation Bookworm est installée sur votre Raspberry Pi 5.

Exécutez les commandes suivantes pour mettre à jour le système d'exploitation vers la dernière version

```
pi@raspberrypi:~ $ sudo apt update
pi@raspberrypi:~ $ sudo apt full-upgrade
```

Assurez-vous que le micrologiciel du Raspberry Pi 5 est à jour :

```
pi@raspberrypi:~ $ sudo rpi-eeprom-update
```

Si vous voyez "décembre 2023" ou une date ultérieure, passez à l'étape suivante. Si vous voyez une date antérieure au 6 décembre 2023, exécutez la commande suivante pour ouvrir l'outil de configuration Raspberry Pi :

```
pi@raspberrypi:~ $ sudo raspi-config
```

Sous *Advanced Options Bootloader Version*, choisissez *Latest*. Quittez ensuite *raspi-config* avec *Finish* ou la touche *Echap*. Exécutez la commande suivante :

```
pi@raspberrypi:~ $ sudo rpi-eeprom-update -a
```

Pour obtenir des performances optimales du dispositif Hailo, il est nécessaire de régler *PCIe* sur *Gen3*. Bien qu'il soit possible d'utiliser *Gen2*, les performances seront moindres. Les étapes sont les suivantes :

```
pi@raspberrypi:~ $ sudo raspi-config
```

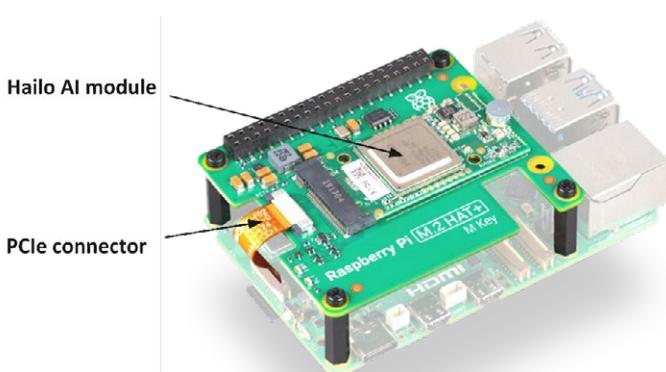


Figure 2. Kit AI assemblé.

Sélectionnez l'option 6. *Advanced Options*, puis sélectionnez l'option *A8 PCIe Speed*. Choisissez *Yes* pour activer le mode *PCIe Gen 3*. Cliquez sur *Finish* pour quitter.

Redémarrez votre Raspberry Pi 5 :

```
pi@raspberrypi:~ $ sudo reboot
```

## Installation du logiciel du Hailo AI Kit

Exécutez la commande suivante pour installer le logiciel Hailo AI Kit sur Raspberry Pi 5 :

```
pi@raspberrypi:~ $ sudo apt install hailo-all
```

La commande ci-dessus installe les dépendances suivantes :

- Pilote de périphérique et micrologiciel du noyau Hailo
- Logiciel d'exécution HailoRT
- Paquet de base Hailo Tappas
- Les étapes de démonstration du logiciel de post-traitement Hailo rpicam-apps

Redémarrez votre Raspberry Pi 5 pour que les paramètres ci-dessus prennent effet :

```
pi@raspberrypi:~ $ sudo reboot
```

## Vérification de l'installation du logiciel

Vous devez vérifier l'installation du logiciel pour vous assurer que tous les composants du logiciel sont en place et que l'AI kit peut être reconnu par le Raspberry Pi 5. Les étapes sont :

- Assurez-vous que le matériel AI kit est installé sur votre Raspberry Pi 5 comme décrit précédemment.
- Entrez la commande suivante :

```
pi@raspberrypi:~ $ hailortcli fw-control identify
```

Si tout est correct, vous devriez voir une sortie similaire à la **figure 3**. Notez ici que la version du logiciel est 4.17.

- Vous devriez également tester l'installation de *TAPPAS Core* en exécutant la commande suivante :

```
pi@raspberrypi:~ $ gst-inspect-1.0 hailotools
```

```
pi@raspberrypi:~ $ hailortcli fw-control identify
Executing on device: 0000:01:00.0
Identifying board
Control Protocol Version: 2
Firmware Version: 4.17.0 (release,app,extended context switch buffer)
Logger Version: 0
Board Name: Hailo-8
Device Architecture: HAILO8L
Serial Number: HLDDLBB241901947
Part Number: HM21LB1C2LAE
Product Name: HAILO-8L AI ACC M.2 B+M KEY MODULE EXT TMP

pi@raspberrypi:~ $ █
```

Figure 3. Vérification de l'installation du logiciel.

```

pi@raspberrypi:~$ gst-inspect-1.0 hailotools
Plugin Details:
Name: hailotools
Description: hailo tools plugin
Filename: /lib/aarch64-linux-gnu/gstreamer-1.0/libgsthailo
.so
Version: 3.28.2
License: unknown
Source module: gst-hailo-tools
Binary package: gst-hailo-tools
Origin URL: https://hailo.ai/

hailoagggregator: hailoagggregator - Cascading
hailocounter: hailocounter - postprocessing element
hailocropper: hailocropper
hailoexportfile: hailoexportfile - export element
hailoexportzmq: hailoexportzmq - export element
hailofilter: hailofilter - postprocessing element
hailogallery: Hailo gallery element
hailograytonv12: hailograytonv12 - postprocessing element
hailoimportzmq: hailoimportzmq - import element
hailomuxer: Muxer pipeline merging

```

Figure 4. Test TAPPAS Core installation (une partie de l'affichage est montrée).

```

pi@raspberrypi:~$ dmesg | grep -i hailo
[ 4.245963] hailo: Init module. driver version 4.18.0
[ 4.246076] hailo 0000:01:00.0: Probing on: 1e60:2864...
[ 4.246081] hailo 0000:01:00.0: Probing: Allocate memory for device
,
11632
[ 4.246099] hailo 0000:01:00.0: enabling device (0000 -> 0002)
[ 4.246105] hailo 0000:01:00.0: Probing: Device enabled
[ 4.246123] hailo 0000:01:00.0: Probing: mapped bar 0 - 00000000352
4
[ 4.246129] hailo 0000:01:00.0: Probing: mapped bar 2 - 00000000b64
[ 4.246134] hailo 0000:01:00.0: Probing: mapped bar 4 - 00000000159
^

```

Figure 5. Vérification des journaux du noyau (une partie de l'affichage est montrée).

Si tout va bien, vous devriez voir quelque chose de similaire à la **figure 4**.

Si `hailo` ou `hailotools` sont introuvables, essayez de supprimer le registre GStreamer :

```

pi@raspberrypi:~$ rm ~/.cache/gstreamer-1.0/registry.aarch64.bin

```

› En outre, vous pouvez exécuter la commande suivante pour vérifier les journaux du noyau :

```

pi@raspberrypi:~$ dmesg | grep -i hailo

```

Ce qui devrait donner une sortie similaire à **figure 5**.

› Enfin, vous devez vérifier que la caméra fonctionne correctement. Entrez la commande suivante, qui affichera un aperçu de la caméra pendant 10 secondes.

```

pi@raspberrypi:~$ rplicam-hello-t 10s

```

Si vous utilisez un module V3 camera avec votre Raspberry Pi 5, ajoutez les lignes suivantes à votre fichier `config.txt` :

- › Editer le fichier `config.txt` :  
`sudo nano /boot/firmware/config.txt`
- › Remplacer la ligne : `camera_auto_detect=1`  
par `camera_auto_detect=0`
- › Insérer la ligne : `dtoverlay=imx708`
- › Tapez `CntrlX` suivi de `Y` pour sauvegarder et quitter.

Saisissez à nouveau la commande `rplicam-hello -t 10s` pour vérifier à nouveau le fonctionnement de la caméra. À ce stade, vous avez vérifié que le matériel et le logiciel AI Kit ont été correctement installés et que votre caméra fonctionne.

## Exécution des programmes de démonstration

Un certain nombre de programmes de démonstration sont disponibles avec l'AI Kit pour le Raspberry Pi 5. Les étapes pour installer certains de ces programmes de démonstration sont :

› Cloner le dépôt

```

git clone https://github.com/hailo-ai/hailo-rpi5-examples.git

```

› Entrer dans le répertoire du dépôt :

```

cd hailo-rpi5-examples

```

› Pour exécuter les exemples, vous devez vous assurer que votre environnement est correctement configuré. Vous pouvez le faire en utilisant le script suivant. Ce script définira les variables d'environnement nécessaires et activera l'environnement virtuel Hailo (s'il n'existe pas, il le créera).

```

source setup_env.sh

```

› Assurez-vous d'être dans l'environnement virtuel et exécutez la commande suivante. Cela peut prendre un certain temps, attendez qu'elle soit terminée.

```

pip install -r requirements.txt

```

› Téléchargement des ressources. Cela peut prendre un certain temps, attendez qu'il soit terminé :

```

./download_resources.sh

```

Ce dépôt contient des exemples de pipelines de base pour la plateforme RPi5 de Hailo. Les exemples démontrent la détection d'objets, l'estimation de la pose humaine et la segmentation d'instances. Il est construit comme des modèles pour vous permettre d'utiliser ces applications comme base pour vos propres projets.

Le dossier `hailo-rpi5-examples` contient les dossiers et les fichiers présentés dans la **figure 6**.

Les programmes d'applications (détection, estimation de la pose, segmentation des instances) sont dans le dossier `basic_pipelines` comme le montre la **figure 7**.

## Exemple de démonstration de détection

Cet exemple démontre la détection d'objets. Il utilise le modèle `YOLOv6n` par défaut. Il supporte également les modèles `yolov8s` et `yolox_s_leaky`. Il utilise la couche NMS (Non-Maximum Suppression) de Hailo en tant que partie du fichier HEF, de sorte que tous les réseaux de détection qui sont compilés



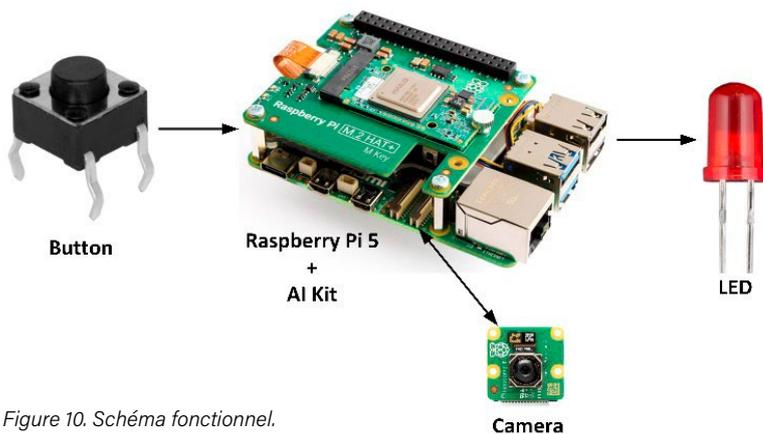


Figure 10. Schéma fonctionnel.

**Schéma fonctionnel:** La **figure 10** présente le schéma fonctionnel du projet.

**Schéma du circuit :** Le schéma du circuit, présenté à la **figure 11**, montre la LED connectée au pin 21 du Raspberry Pi 5 via une résistance de  $330\ \Omega$  pour limiter le courant. Un bouton-poussoir est relié au pin 20. Le bouton est normalement au niveau haut (logic 1) et passe au niveau bas (logic 0) lorsqu'il est pressé.

**Listage du programme :** Le code Python est présenté dans le **listage 1**. Le programme crée un sous-programme et s'exécute comme un programme shell. Au début du programme, la bibliothèque `gpiozero` est importée et le port GPIO 21 du Raspberry Pi 5 est affecté à LED et le bouton est affecté au port 20.

Le programme d'inférence Hailo de post-traitement `rpicas-apps` est lancé dans une boucle `while` et la sortie de ce programme est comparée si elle contient le mot `person`. c'est-à-dire si une personne a été détectée. Si c'est le cas, le message `Personne détectée` s'affiche sur l'écran, le programme shell se termine et la LED s'allume. Le programme attend ensuite que le bouton soit pressé. L'appui sur le bouton est comme un accusé de réception de la part de l'utilisateur. L'appui sur le bouton éteint la LED. Le programme attend alors 15 secondes, puis le processus de détection reprend depuis le début.

Ce programme peut facilement être modifié en remplaçant la LED par un relais ou un buzzer, et en ajustant le délai d'attente selon les besoins spécifiques de l'application. Il est particulièrement adapté à des applications de sécurité, où il est crucial de détecter la présence humaine. Par ailleurs, il est possible de configurer la détection d'autres types d'objets et de programmer des actions en conséquence.

### Formation à la détection d'objets

La détection et l'apprentissage d'objets via l'IA sont des processus complexes nécessitant une compréhension approfondie et une maîtrise pratique de la programmation, notamment en Python. Le chapitre 11 du livre décrit en détail comment mener à bien la formation à la détection d'objets sur un système Ubuntu, avec des résultats appliqués sur un Raspberry Pi 5. 

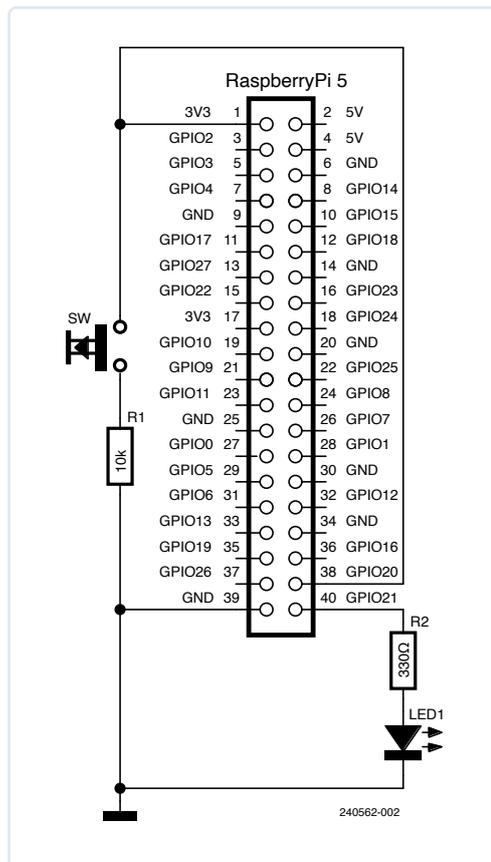


Figure 11. Schéma du circuit.



### À propos de l'auteur

Dogan Ibrahim est titulaire d'une licence en ingénierie électronique, d'une Master en ingénierie du contrôle automatique et d'un doctorat en traitement des signaux numériques. Il a travaillé dans de nombreuses organisations industrielles avant de revenir à la vie universitaire. Le professeur Ibrahim est l'auteur de plus de 70 ouvrages techniques et a publié plus de 200 articles techniques sur les microcontrôleurs, les microprocesseurs et les domaines connexes. Il est ingénieur électricien agréé et membre de l'Institution of the Engineering Technology. Il est un professionnel certifié d'Arduino.

240562-04



## Listage 1. Code Python.

```
#-----  
#           DETECT PERSON AND TURN ON LED  
#           -----  
#  
# File   : Detect.py  
# Date   : October, 2024  
# Author : Dogan Ibrahim  
#-----  
import os  
import subprocess  
from gpiozero import LED, Button  
from time import sleep  
led = LED(21)                # LED port  
button = Button(20)         # Button port  
led.off()                   # LED OFF  
while(True):  
    p=subprocess.call("rpicam-hello -n -v 2 -t 0 \  
        --post-process-file /home/pi/rpicam-apps/assets/hailo_yolov8_inference.json\  
        --lores-width 640 --lores-height 640 2>&1 | grep -m 1 -c \  
        --line-buffered 'person'",shell=True)  
    print("Person detected...")  
#  
# At this point a person has been detected  
#  
    led.on()  
    button.wait_for_press() # Wait for button press  
    led.off()  
    sleep(15)
```

### Questions ou commentaires ?

Envoyez un courriel à l'auteur (d.ibrahim@btinternet.com), ou contactez Elektor (redaction@elektor.fr).



### Produit

- > Dogan Ibrahim, *Getting Started with the Raspberry Pi AI Kit* (Elektor 2024)  
[www.elektor.fr/21031](http://www.elektor.fr/21031)
- > Dogan Ibrahim, *Getting Started with the Raspberry Pi AI Kit* (Elektor 2024, E-book)  
[www.elektor.fr/21032](http://www.elektor.fr/21032)
- > Raspberry Pi AI Kit  
[www.elektor.fr/20879](http://www.elektor.fr/20879)



### L'impact de l'IA sur la gestion énergétique des bâtiments intelligents

Alors que la technologie d'intelligence artificielle évolue rapidement, elle pourrait jouer un rôle significatif dans la réduction de la consommation énergétique et des émissions de carbone dans les bâtiments [1]. Cette recherche [2] explore les façons par lesquelles l'IA peut diminuer les coûts énergétiques et les émissions de carbone, en soulignant la nécessité de mener d'autres études pour quantifier pleinement le potentiel de l'IA. L'étude propose une méthode systématique pour évaluer l'impact de l'IA, prévoyant des réductions significatives de la consommation d'énergie et des émissions d'ici 2050.

Grâce à la technologie de l'IA et aux politiques d'efficacité, les émissions de CO2 pourraient être réduites d'environ 40 % d'ici 2050 par rapport à une trajectoire de référence sans intervention (BAU). La mise en œuvre à la fois de l'IA et d'efforts politiques pourrait conduire à une réduction de 60 %. En renforçant l'intégration de sources de production électrique à faibles émissions, il est envisageable d'éliminer presque totalement les émissions d'ici 2050, ce qui permettrait de réaliser des économies de l'ordre de 93 à 95 % par rapport aux tendances actuelles.

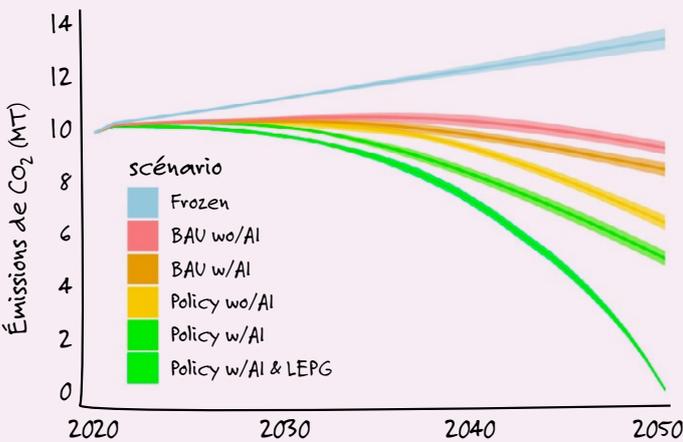
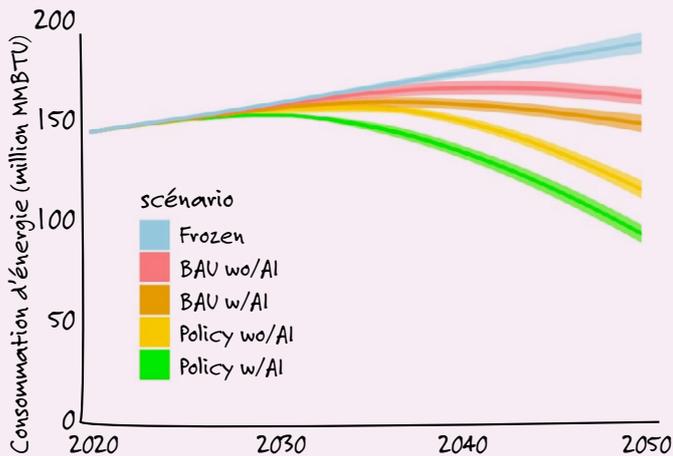
L'IA pourrait contribuer à réduire les émissions de CO<sub>2</sub> de :

**~40%**

par rapport au scénario BAU.

**~90%**

par rapport au scénario BAU lorsqu'il est combiné à des politiques d'efficacité énergétique et à une production d'électricité à faible taux d'émission (LEPG)



Consommation d'énergie par scénario. BAU stands for business-as-usual. The darker color for each scenario indicates the average estimate and the lighter color for each scenario indicates the estimated ranges from the sensitivity analysis.[2]

Présentez des données précises et actualisées sur l'adoption et l'utilisation de l'IA dans les principaux pays de l'UE ( par population).



Drafts



Voici un résumé de l'adoption et de l'utilisation de l'IA dans les principaux pays de l'UE par population en 2024 : En Allemagne, environ 11 % des entreprises utilisent les technologies de l'IA, principalement dans les secteurs de l'automatisation, de la fabrication et de l'automobile, selon la Commission Européenne. En France, l'adoption de l'IA est d'environ 10 %, avec des applications clés dans les secteurs de la santé et de la finance. En Italie, 7,5 % des entreprises ont adopté l'IA, surtout dans les secteurs industriels. En Espagne, l'utilisation de l'IA est en croissance, mais aucune donnée spécifique en pourcentage n'est disponible pour 2024, le pays se concentrant sur la transformation numérique. En Pologne, l'adoption est d'environ 3,7 %, ce qui représente l'un des taux les plus bas en Europe.

Enter a prompt for ChatGPT



# Les géants de la technologie développent des puces d'IA

La pénurie mondiale de puces causée par la pandémie de COVID-19 en 2020 sérieusement impacté la production de GPU. La pandémie a provoqué des perturbations dans la chaîne d'approvisionnement mondiale, causant des retards dans la production et la distribution de puces. Face à cette situation, plusieurs entreprises ont pris l'initiative de développer leurs propres puces spécialisées en intelligence artificielle. Voici une liste de ces entreprises :

- **Google** : Amélioration de sa technologie Tensor Processing Unit (TPU) [4] pour Google Cloud.
- **OpenAI** : Exploration du développement de puces d'IA propriétaires [5].
- **Microsoft** : Lancement de deux puces personnalisées - Microsoft Azure Maia AI Accelerator et Azure Cobalt CPU [6].
- **Amazon** : Sortie de la puce Inferentia AI [7] et de l'accélérateur AWS Trainium ML de deuxième génération [8].
- **Meta** : Développement d'une puce personnalisée pour ses initiatives en matière d'IA [9].
- **Huawei** : Priorité à la production de puces d'IA, ralentissement de la production de smartphones [10].
- **Tesla** : Création de la puce Dojo AI [11] pour l'apprentissage automatique dans la conduite autonome.
- **Baidu** : Développement de la puce Kunlun AI pour l'apprentissage profond et la reconnaissance vocale.
- **Alibaba** : Lancement de la puce Hanguang 800 AI [12] pour améliorer le ML dans les services cloud.

240435-04

# Adoption des assistants IA de programmation et défis en cours

Une récente enquête menée par Stack Overflow [3] a révélé que les développeurs adoptent largement les assistants IA de programmation.

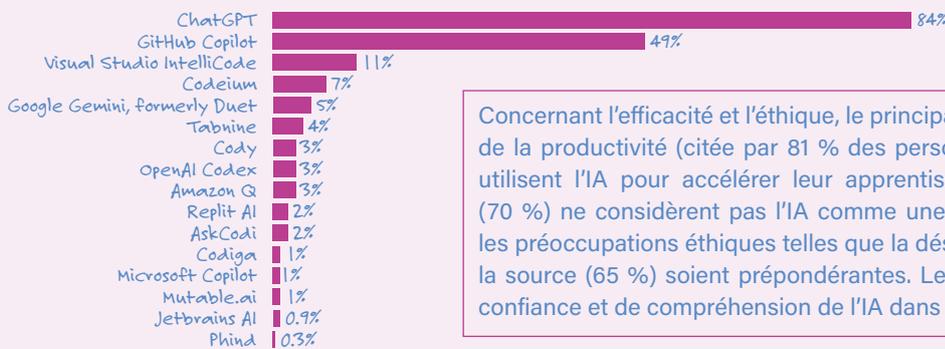
**76% vs 70%**

des personnes interrogées utilisent ou prévoient d'utiliser des assistants IA de programmation par rapport à l'année dernière.

**62% vs 44%**

utilisent désormais activement les outils d'IA l'année précédente.

Quel est le principal outil IA de programmation utilisé par les développeurs professionnels ? [3]



Concernant l'efficacité et l'éthique, le principal avantage de l'IA est l'augmentation de la productivité (citée par 81 % des personnes interrogées), tandis que 62 % utilisent l'IA pour accélérer leur apprentissage. La plupart des développeurs (70 %) ne considèrent pas l'IA comme une menace pour leur emploi, bien que les préoccupations éthiques telles que la désinformation (79 %) et l'attribution de la source (65 %) soient prépondérantes. Le plus grand défi reste le manque de confiance et de compréhension de l'IA dans les processus de codage.

## LIENS

- [1] N. Flaherty, "AI can cut smart building energy management by over 19%," eeNews, 2024: <https://tinyurl.com/ai-smart-energy>
- [2] C. Ding, J. Ke, M. Levine et al., "Potential of artificial intelligence in reducing energy and carbon emissions of commercial buildings at scale," Nat Commun (2024): <https://doi.org/10.1038/s41467-024-50088-4>
- [3] "2024 Developer Survey," Stack Overflow, May 2024: <https://survey.stackoverflow.co/2024/ai/>
- [4] Accelerate AI development with Google Cloud TPUs: <https://cloud.google.com/tpu?hl=en>
- [5] A. Tong, M. Cherney, C. Bing, S. Nellis, "Exclusive: ChatGPT-owner OpenAI is exploring making its own AI chips," Reuters, 2023: <https://tinyurl.com/chatgpt-chip>
- [6] J. Siegel, "With a systems approach to chips, Microsoft aims to tailor everything 'from silicon to service' to meet AI demand," Microsoft, 2023: <https://tinyurl.com/microsoft-ai-chip>
- [7] AWS Inferentia: <https://aws.amazon.com/machine-learning/inferentia/>
- [8] AWS Trainium: <https://aws.amazon.com/machine-learning/trainium/>
- [9] F. Potkin, J. Zhu, "Exclusive: AI chip demand forces Huawei to slow smartphone production," Reuters, 2024: <https://tinyurl.com/huawei-chip>
- [10] K. Paul, S. Nellis, M. Cherney, "Exclusive: Meta to deploy in-house custom chips this year to power AI drive," Reuters, 2024: <https://tinyurl.com/meta-chip>
- [11] "TSMC Reportedly Commences Production of Tesla's Next-Generation Dojo Chips, Anticipates 40x Increase in Computing Power in 3 Years," TrendForce, 2024: <https://tinyurl.com/tesla-chip>
- [12] Y. Jiao, L. Han, X. Long, et al., "Hanguang 800 NPU," Alibaba Group: <https://tinyurl.com/alibaba-chip>

# télécommande IR universelle basée sur l'IA

## Contrôle gestuel avec MediaPipe et Raspberry Pi

Antonio Aloisio (Italie)

Si vous souhaitez vous initier à l'intelligence artificielle, ce projet pourrait être l'opportunité idéale ! Utilisant un Raspberry Pi 5, la plateforme MediaPipe Studio de Google et une petite carte d'interface enfichable, vous pouvez mettre en place un système de reconnaissance gestuelle polyvalent contrôler votre téléviseur ou d'autres appareils fonctionnant à l'aide de télécommandes infrarouges.

IHM, abréviation de *Human-Machine Interface*, est un terme qui désigne toutes les technologies ou appareils permettant l'interaction entre les humains et les machines. Les IHM jouent un rôle crucial dans divers secteurs, allant de la production industrielle à l'électronique de consommation, en facilitant et en améliorant les échanges entre les utilisateurs et les systèmes mécaniques ou électroniques. Les IHM les plus couramment utilisées sont :

- **Interfaces utilisateur graphiques (GUI)** : très répandues, elles intègrent des écrans graphiques qui permettent aux utilisateurs d'interagir avec les machines via des icônes, des boutons et des menus. Elles sont typiques des systèmes d'exploitation de PC, par exemple.
- **Interfaces utilisateur vocales (IUV)** : elles permettent aux utilisateurs d'interagir avec les machines via des commandes vocales. Ce type d'IHM gagne en popularité avec l'émergence des assistants vocaux tels que Siri d'Apple, Google Assistant et Amazon Alexa.
- **Interfaces utilisateur tactiles** : elles permettent aux utilisateurs d'interagir avec les machines par le biais du toucher, comme avec les écrans tactiles, les claviers et les souris.
- **Interfaces utilisateur gestuelles** : elles permettent aux utilisateurs d'interagir avec les machines grâce à des mouvements physiques, tels que les gestes de la main détectés par des caméras ou des capteurs de mouvement, et seront essentielles pour ce projet.

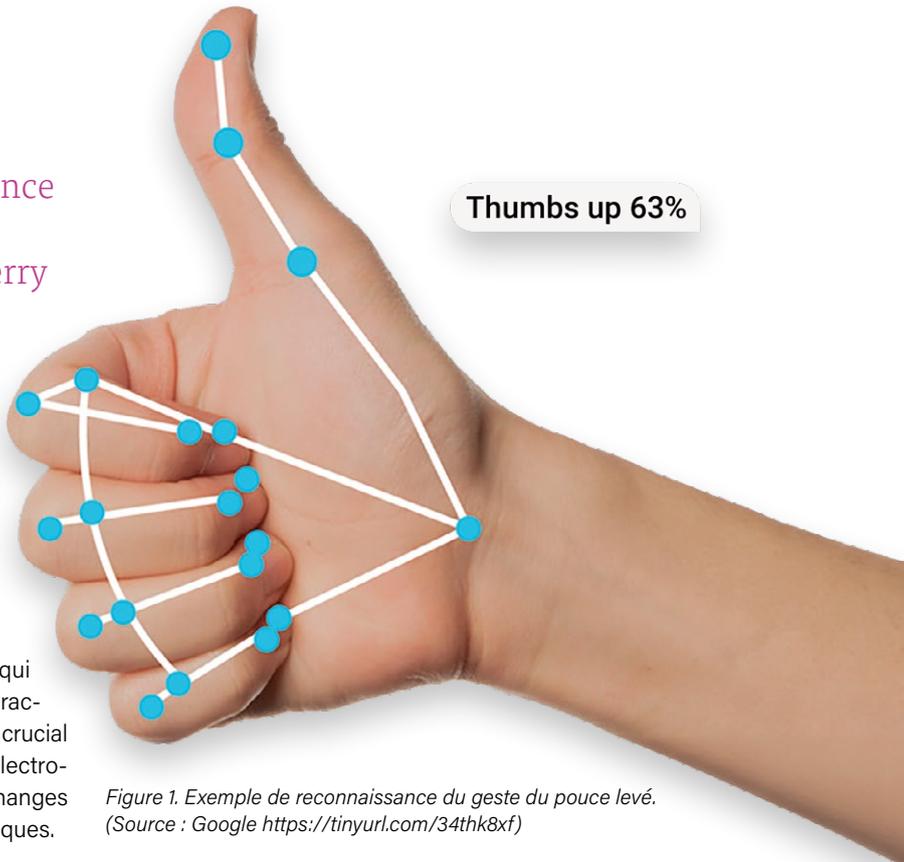


Figure 1. Exemple de reconnaissance du geste du pouce levé. (Source : Google <https://tinyurl.com/34thk8xf>)

Les applications vont de l'automatisation industrielle (utilisée pour surveiller et contrôler les machines et les processus industriels) à l'électronique grand public (les écrans tactiles sont courants dans les appareils grand public tels que les smartphones, les tablettes, les ordinateurs et les téléviseurs). Dans le domaine de la domotique, les IHM permettent aux utilisateurs de contrôler les lumières, les thermostats, les systèmes de sécurité et d'autres appareils domestiques intelligents. Elles sont essentielles dans les véhicules pour permettre aux utilisateurs d'interagir avec les systèmes de navigation, les systèmes de divertissement et d'autres fonctionnalités.

L'interaction doit respecter certaines normes d'ergonomie et de fonctionnalité qui ne sont pas toujours respectées. Prenons pour exemple les critiques récentes de l'Euro NCAP concernant la complexité croissante des véhicules, qui ont transféré des commandes essentielles vers des écrans centraux, obligeant les conducteurs à détacher leur regard de la route, augmentant ainsi le risque d'accidents dus à la distraction (source : ETSC [1]). Rendre les IHM plus intuitives (conviviales) est donc l'un des objectifs que les entreprises s'efforcent d'atteindre.

L'interaction avec les machines est un aspect de notre quotidien qui devient crucial dans de nombreux secteurs, améliorant l'efficacité, la sécurité et l'expérience utilisateur globale. Actuellement, de nombreux systèmes d'IHM intègrent l'intelligence artificielle (IA) pour optimiser leur fonctionnement, reflétant l'innovation continue dans ce domaine.

Dans le cadre de notre projet, nous explorons l'utilisation de la reconnaissance des gestes de la main pour commander un téléviseur, en utilisant un système d'IA. Ce projet vise à remplacer l'un des dispositifs les plus communs et appréciés du quotidien, la télécommande. Imaginez le plaisir de pouvoir allumer votre téléviseur simplement par un mouvement de la main, comme si vous utilisiez la « force Jedi »

L'approche du projet est ludique, mais il se veut une porte d'entrée vers l'utilisation des systèmes d'IA par tous, en l'occurrence visant à créer des IHM gestuelles.

## Logiciels

L'IA est une branche de l'informatique qui se concentre sur le développement de systèmes et de technologies capables de simuler les processus de l'intelligence humaine, tels que la réflexion et la résolution de problèmes auxquels nous sommes habitués. L'apprentissage automatique (ML), un sous-ensemble essentiel de l'IA, se concentre sur l'élaboration de méthodes permettant à un système informatique d'apprendre à partir de données antérieures afin de faire des prédictions ou de prendre des décisions sans programmation explicite.

L'acquisition de données constitue la première étape du ML, où divers types de données comme le texte, les images, les sons ou les chiffres sont collectés. Ces données peuvent provenir de capteurs, de bases de données ou même de médias sociaux. La qualité des données est essentielle pour déterminer le succès d'un modèle de ML. Les algorithmes de ML sont les outils qui permettent aux systèmes informatiques d'apprendre à partir des données. Il existe différents types d'algorithmes, chacun étant adapté à des tâches spécifiques. Par exemple, les algorithmes de régression peuvent être utilisés pour faire des prédictions basées sur des données historiques, tandis que les algorithmes de classification sont utiles pour attribuer des catégories aux données.

Le processus de formation d'un système de ML (algorithme + données) consiste à alimenter l'algorithme avec des données étiquetées, c'est-à-dire des données auxquelles sont déjà associées des réponses correctes, permettant ainsi à l'algorithme d'apprendre les relations entre les données. Cette étape nécessite un certain temps et des ressources informatiques, mais elle est essentielle à la création de modèles précis.

Une fois formé, le modèle doit être évalué afin de déterminer ses performances sur de nouvelles données. Cette étape est cruciale pour vérifier la capacité de généralisation du modèle. Si le modèle ne répond pas aux performances attendues, il peut être nécessaire de l'optimiser en ajustant divers paramètres ou en utilisant des techniques de réglage. Ce processus est connu sous le nom d'optimisation du modèle et peut nécessiter une certaine expérimentation pour trouver la combinaison optimale de paramètres.

## MediaPipe

Google offre une importante contribution à la création, la formation et l'optimisation d'algorithmes avec sa plateforme open source, MediaPipe. Le nom « MediaPipe » évoque le concept de « pipeline médiatique ».

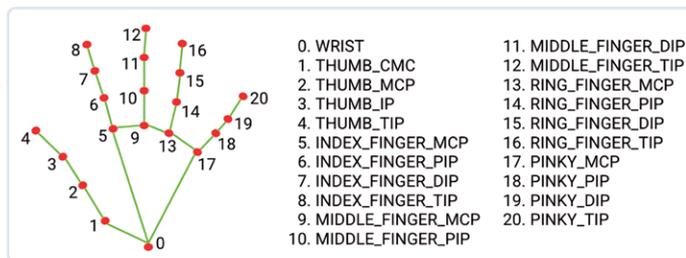


Figure 2. Points reconnus sur la paume - points de repère. (Source: Google [https://ai.google.dev/edge/mediapipe/solutions/vision/gesture\\_recognizer](https://ai.google.dev/edge/mediapipe/solutions/vision/gesture_recognizer))

MediaPipe est défini par Google comme fonctionnant sur l'appareil (*on-device*), ce qui signifie qu'il est également capable de fonctionner sur un appareil matériel hors ligne, nécessitant de connexion internet. Cela rend nos projets portables et intégrables dans différentes applications. caractérise sa plateforme comme *no-code*, ce qui signifie qu'elle est accessible même à ceux qui possèdent peu de compétences en programmation.

Ce concept rappelle celui de l'univers Arduino, qui a démocratisé l'accès à l'électronique et à la programmation pour un public sans connaissances préalables. MediaPipe va également dans ce sens, en proposant de manière simple un sujet à l'origine très complexe comme l'IA. Pour explorer les capacités de MediaPipe, il suffit de visiter la page web de reconnaissance gestuelle de MediaPipe Studio [2]. Après connexion avec un compte Google, le navigateur peut utiliser la webcam pour reconnaître les gestes de la main, qu'elle soit gauche ou droite, car le logiciel identifie également laquelle, et nous effectuons l'un des gestes suivants :

1. Poing
2. Paume ouverte
3. Index pointé vers le haut
4. Pouce levé
5. Pouce vers le bas
6. Symbole de *la victoire* avec deux doigts
7. *Je t'aime* dans la langue des gestes (position finale).

La page affiche, en temps réel et en superposition sur la vidéo, 21 points de repère des mains, connectés par des segments colorés, comme illustré dans le **figure 1**. Les points clés sont également appelés *points de repère* et représentent les parties significatives des mains, telles que le bout des doigts, les pouces, les paumes, etc. Le suivi précis de ces points de repère permet de déterminer la pose et les mouvements des mains dans une application (**figure 2**).

Sur la page web, sous l'image vidéo, on trouvera également des informations complémentaires, telles que le pourcentage de confiance dans la reconnaissance du geste effectué et le type de geste identifié. MediaPipe propose ensuite une solution appelée *Hand Tracking* qui permet la reconnaissance et le suivi des mains en temps réel dans un flux vidéo. Ce module de MediaPipe a été nommé *HandLandmarks* en conséquence. Le module commence par détecter la présence de mains dans la vidéo et identifie les régions de l'image qui les contiennent. Une fois les mains détectées, le suivi des points de repère peut commencer. Après l'identification des points de repère, le module peut estimer la position des mains dans la vidéo. Cela inclut des informations telles que l'orientation de la main, la direction des doigts et d'autres détails qui peuvent être utilisés pour interpréter les gestes. MediaPipe est basé sur TensorFlow lite, une version allégée mais puissante de la plateforme d'apprentissage automatique de Google. MediaPipe utilise un modèle pré-entraîné capable de reconnaître les gestes à partir d'environ 30 000 images réelles. Les utilisateurs peuvent aussi personnaliser l'entraînement avec leurs propres images en suivant un tutoriel dédié [3].

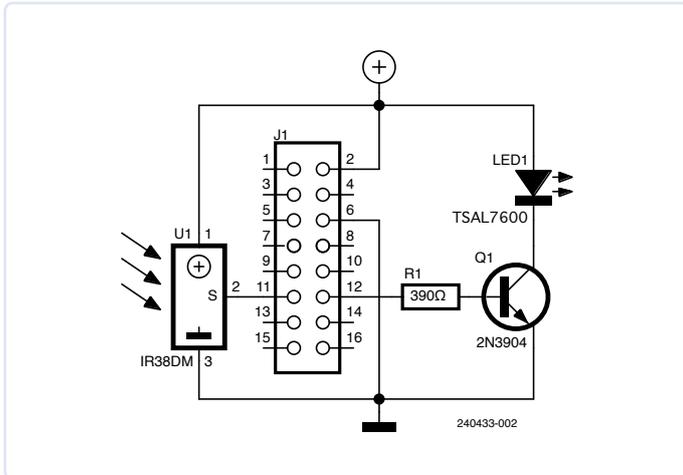


Figure 3. Schéma de l'interface Rx-Tx IR simple et enfichable.

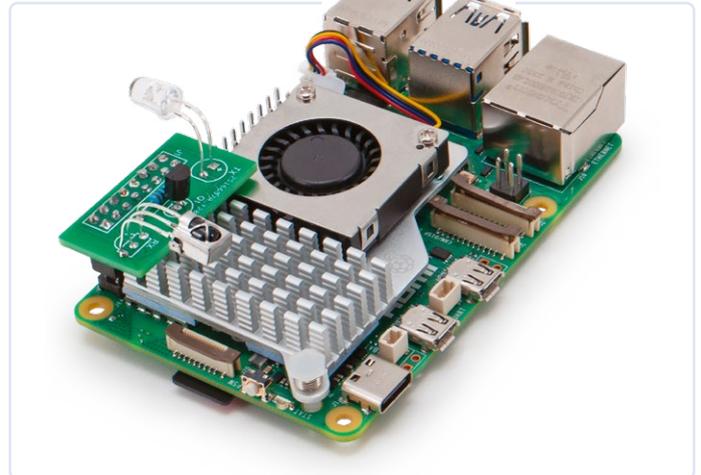


Figure 4. La petite carte d'interface IR, montée sur le Raspberry Pi 5.

Amusez-vous à explorer les autres systèmes de ML fournis par MediaPipe tels que la classification d'images, la détection d'objets ou de visages. La documentation qui s'y trouve vous permettra d'approfondir les sujets qui vous intéressent le plus. MediaPipe est multiplateforme ; en effet, vous pouvez créer des projets pour Android, iOS et Web (JavaScript). Dans notre projet, nous utiliserons Python, c'est-à-dire l'un des langages de programmation les plus populaires dans le domaine du ML (et au-delà) pour sa facilité d'utilisation, sa syntaxe intuitive - et les nombreuses ressources pédagogiques et bibliothèques disponibles - ce qui en fait un excellent choix pour les débutants que pour les programmeurs expérimentés.

Un seul article ne suffirait pas pour couvrir en détail le vaste univers de TensorFlow, MediaPipe et Python. Cependant, nous espérons que cet aperçu vous incitera à explorer ces technologies et à orienter vos études vers des sujets essentiels dans le domaine de l'informatique moderne et future.

## MediaPipe sur Raspberry Pi

Commençons de manière pratique, en installant MediaPipe sur notre Raspberry Pi 5 afin de pouvoir l'utiliser immédiatement sur l'appareil. Connectez-vous à votre carte bien que nous recommandions VNC, pour la simplicité et la puissance d'utilisation [4]. Python est intégré dans le système d'exploitation du Raspberry Pi. Entrez en mode administrateur avec la commande `sudo bash`, puis mettez à jour votre système avec `apt update` et `apt upgrade`.

Installez la bibliothèque MediaPipe pour Python avec la commande `pip install mediapipe`. En Python, `pip` est un outil de gestion de paquets qui facilite l'installation, la gestion et la mise à jour des bibliothèques et frameworks externes.

Le nom `pip` est un acronyme récursif qui signifie *Python Installs Packages*. Certaines versions du système d'exploitation Raspberry Pi peuvent donner des erreurs lors de l'installation de paquets. Vous pouvez résoudre le problème en supprimant la gestion des paquets externes avec la commande `rm /usr/lib/python3.* /EXTERNAL-LY-MANAGED`, et exécutez à nouveau `pip`.

Vous devez maintenant télécharger le modèle de données pour la reconnaissance gestuelle de MediaPipe [5]. Placez-le dans le même

dossier que celui où vous comptez créer le programme Python. Nous utiliserons également OpenCV (Open Source Computer Vision Library), une bibliothèque puissante pour le traitement d'images et la vision par ordinateur. OpenCV offre de nombreuses fonctionnalités pour l'analyse et la manipulation d'images, la reconnaissance de formes (motifs récurrents ou régularités dans un ensemble de données), le suivi d'objets, la vision par ordinateur, et bien plus encore.

Faisons l'installation avec `pip install opencv-python`. Nous avons tout pour essayer sur notre système autonome (application ou système pouvant fonctionner de manière indépendante). Si vous êtes déjà un développeur Python, utilisez l'éditeur auquel vous êtes habitué - nous avons utilisé Geany - déjà installé sur Raspberry OS. Dans le **listage 1**, vous trouverez le programme à écrire sur l'éditeur commenté et expliqué en détail. Lancez-le (icône d'avion dans Geany). Une nouvelle fenêtre s'ouvrira alors avec le flux vidéo en direct et le repère de la main. Le geste reconnu apparaîtra dans le terminal de l'éditeur.

Notons comment dans la section `match...case` nous avons laissé en commentaire (en Python, avec le symbole `#` en début de ligne) les instructions `os.system`, c'est-à-dire les commandes du système d'exploitation qui permettront d'envoyer les signaux IR, que nous utiliserons après avoir abordé l'aspect matériel.

## Acquisition et envoi de signaux IR

Pour l'apprentissage et l'envoi des signaux infrarouges (IR), nous allons fabriquer une interface simple - dont le schéma est présenté à la **figure 3** - avec un petit boîtier de circuit imprimé, un récepteur IR et une LED émettrice IR. Grâce à un connecteur adapté, elle se branchera directement sur le connecteur GPIO du Raspberry Pi, comme illustré sur la **figure 4**.

Pour la capture d'images, nous utiliserons une webcam USB connectée au Raspberry Pi. Le schéma est parfaitement compatible avec n'importe quelle caméra que vous avez pour votre carte. Pour donner une stabilité de support au circuit imprimé, nous avons utilisé les 16 premières broches (numérotées de 1 à 16 GPIO 23), voir **Figure 5**.

En réalité, il n'y a que quatre broches connectées :

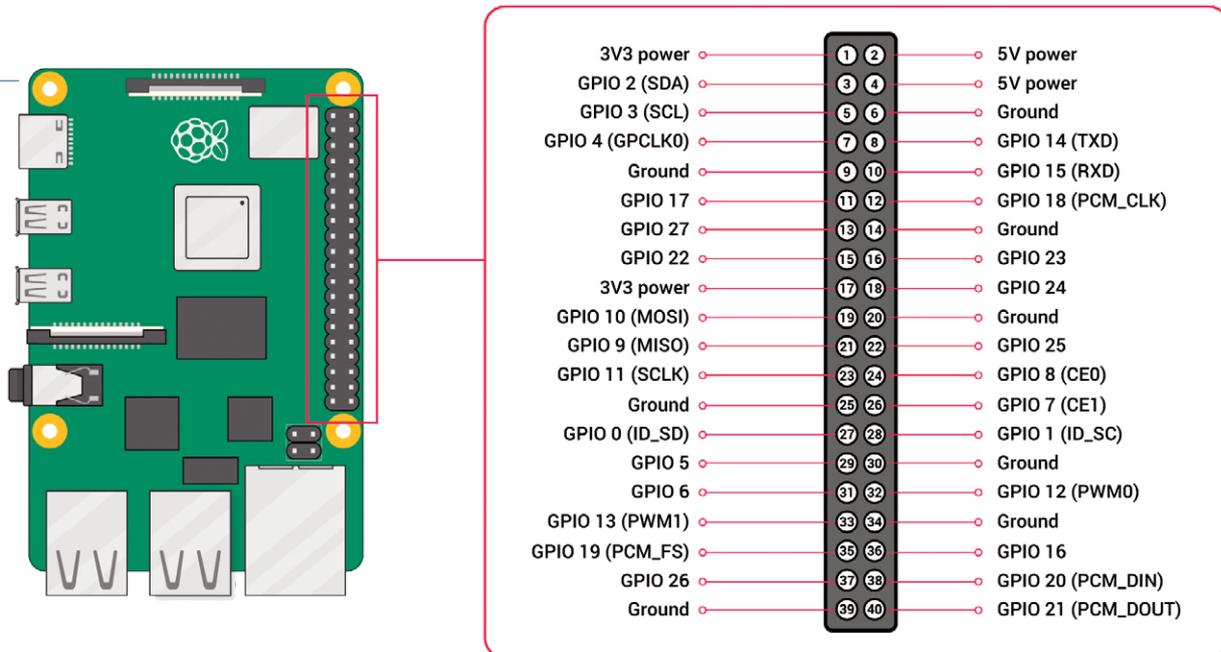


Figure 5. Brochage des GPIO du Raspberry Pi 5. (Source : <https://tinyurl.com/5dpvj5ne>)

- > Pin 2 Vcc +5 V
- > Pin 6 GND
- > Pin 11 GPIO 17 pour le récepteur IR
- > Pin 12 GPIO 18 pour l'émetteur IR

Le transistor Q1 permet d'alimenter la LED IR à 5 V DC, d'augmenter sa puissance d'émission et de fournir un courant limité sur les GPIO du Raspberry Pi, qui délivrent 3,3 V DC. L'émetteur utilisé est un TSAL7600 de Vishay Semiconductors, une diode IR à haute puissance de rayonnement de 940 nm dans un boîtier en plastique transparent. Si vous disposez d'une vieille télécommande, vous pouvez aussi essayer d'utiliser son LED IR.

Le récepteur est un IR38DM (également disponible sous le nom de MIM-5385K2 par Unity Opto Technology), un capteur IR très sensible avec préamplificateur, démodulateur et filtre, calibré à la fréquence de 38 kHz (600 µs burst/pause) avec amplificateur/équilibreur intégré (figure 6).

La méthode utilisée consiste à mémoriser le signal décodé par le récepteur sur le Raspberry Pi, puis à le renvoyer avec l'émetteur, en associant chaque geste à un signal de sortie.

Le décodage effectué par le capteur et une bibliothèque supplémentaire installée sur la carte nous permettra d'avoir une séquence de nombres, que nous stockerons dans de simples fichiers textes, pour chaque bouton de télécommande que nous souhaiterions implémenter. Le Raspberry Pi dispose d'une fonctionnalité native permettant l'émission et la réception de fichiers de signaux IR. Nous éditons le fichier `/boot/firmware/conFiguratxt`.

Pour ceux qui ne sont pas familiers avec RaspberryOS, nous recommandons que toutes les instructions d'édition de fichiers soient effectuées avec l'éditeur de système `nano`. Celui-ci, contrairement aux éditeurs GUI, lorsqu'il est ouvert depuis le terminal avec les droits d'administrateur (`sudo bash`) permet d'ouvrir, d'éditer et de sauvegarder tous les types de fichiers, y compris les fichiers système. Ainsi, à partir du terminal, tapez :

```
nano /boot/firmware/conFiguratxt
(attention au patch correct)
```

Supprimer les commentaires (comme en Python, le caractère #) pour activer les lignes suivantes :

```
# Additional overlays and parameters are documented:
dtoverlay=gpio-ir,gpio_pin=17
dtoverlay=gpio-ir-tx,gpio_pin=18
```

Sur certaines versions de RaspberryOS, il se peut que vous ne trouviez pas du tout ces lignes ; dans ce cas, il vous suffit de les écrire vous-même. En procédant ainsi, nous demandons au système d'exploitation de définir la broche 12 (GPIO18) comme émetteur IR et la broche 11 (GPIO17) comme récepteur IR.

Cette opération est possible car ces fonctionnalités sont natives dans le noyau Linux. Redémarrez pour que les configurations soient effectives. Il nous faut maintenant installer une fonctionnalité clé pour mettre en œuvre notre système.

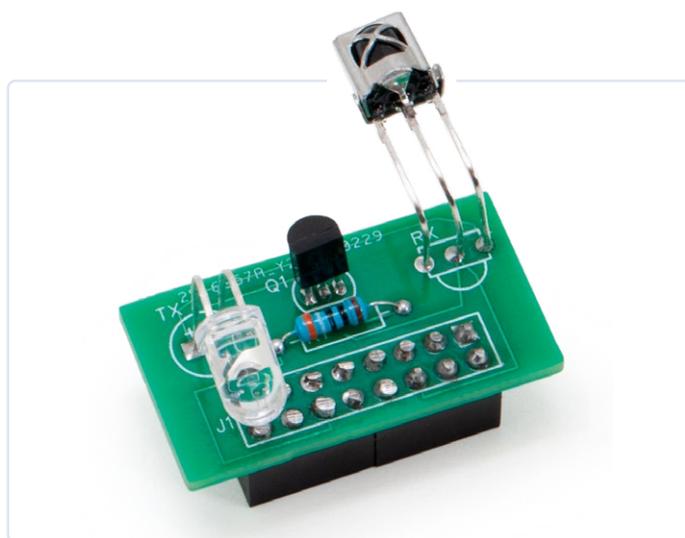


Figure 6. Le circuit imprimé avec la LED TX, le transistor boost et le module RX à droite.



## Listage 1. Code Python avec la boucle pour la reconnaissance des gestes.

```
# Import of the necessary libraries
import os
import cv2
import mediapipe as mp
from mediapipe.tasks import python
# Maximum number of hands to be detected and path of gesture recognition model
numero_mani = 1
model_path = "gesture_recognizer.task"
# MediaPipe library initialization
GestureRecognizer = mp.tasks.vision.GestureRecognizer
GestureRecognizerOptions = mp.tasks.vision.GestureRecognizerOptions
GestureRecognizerResult = mp.tasks.vision.GestureRecognizerResult
VisionRunningMode = mp.tasks.vision.RunningMode

# Variable to store the last gesture recognized
last_gesture = None
# Function to print the result of gesture recognition
def print_result(result: GestureRecognizerResult, output_image: mp.Image, timestamp_ms: int):
    global last_gesture

    for single_hand_gesture_data in result.gestures:
        gesture_name = single_hand_gesture_data[0].category_name
        # Checks if the recognized gesture is different from the last detected gesture
        # Used to give an ir impulse after each gesture
        if gesture_name != last_gesture:
            last_gesture = gesture_name
            # Prints the new recognized gesture
            print("Nuovo gesto riconosciuto:", gesture_name)
            # Correspondences between the recognized gesture and the actions to be performed
            # When you have ir commands available uncomment the os.system instruction
            match gesture_name:
                case "Open_Palm":
                    print("palmo aperto")
                    # os.system('ir-ctl -d /dev/lirc0 --send=on_off.txt')
                case "Thumb_Up":
                    print("pollice su")
                    # os.system('ir-ctl -d /dev/lirc0 --send=volume_su.txt')
                case "Thumb_Down":
                    print("pollice giu")
                    # os.system('ir-ctl -d /dev/lirc0 --send=volume_giu.txt')
                case "Pointing_Up":
                    print("dito in su")
                    # os.system('ir-ctl -d /dev/lirc0 --send=canali_avanti.txt')
                case "Victory":
                    print("vittoria")
                    # os.system('ir-ctl -d /dev/lirc0 --send=canali_indietro.txt')

# Options for the gesture recognizer
options = GestureRecognizerOptions(
    base_options=python.BaseOptions(model_asset_path=model_path),
    running_mode=VisionRunningMode.LIVE_STREAM,
    num_hands = numero_mani,
    result_callback=print_result)
```

```

# Creating the gesture recognizer
recognizer = GestureRecognizer.create_from_options(options)
timestamp = 0
mp_drawing = mp.solutions.drawing_utils
mp_hands = mp.solutions.hands
# Initialization of the hand recognizer
hands = mp_hands.Hands(
    static_image_mode=False,
    max_num_hands=numero_mani,
    min_detection_confidence=0.65,
    min_tracking_confidence=0.65)
# Initializing webcam video capture
# If you have multiple video input devices connected to Raspberry
# you need to type the correct number in place of 0
cap = cv2.VideoCapture(0)
# Main program cycle
while True:
    # Capturing a frame by the webcam
    ret, frame = cap.read()
    if not ret:
        break

    # Frame horizontal flip
    frame = cv2.flip(frame, 1)
    # Frame conversion BGR to RGB (MediaPipe compatible)
    frame = cv2.cvtColor(frame, cv2.COLOR_BGR2RGB)
    # Frame processing for hand detection
    results = hands.process(frame)
    # Frame conversion from RGB to BGR for visualization
    frame = cv2.cvtColor(frame, cv2.COLOR_RGB2BGR)
    # Creating a numpy array with the frame converted to RGB
    np_array = cv2.cvtColor(frame, cv2.COLOR_BGR2RGB)

    # If hands are detected in the frame
    if results.multi_hand_landmarks:
        for hand_landmarks in results.multi_hand_landmarks:
            # Drawing of hand landmarks on the frame
            mp_drawing.draw_landmarks(frame, hand_landmarks, mp_hands.HAND_CONNECTIONS)
            # Creation of an Image type object compatible with MediaPipe

            mp_image = mp.Image(image_format=mp.ImageFormat.SRGB, data=np_array)
            # Asynchronous gesture recognition on the hand
            recognizer.recognize_async(mp_image, timestamp)
            timestamp = timestamp + 1 # Must monotonously increase in LIVE_STREAM mode

    # Shows the frame with the detected gestures
    cv2.imshow('Riconoscimento Gestuale', frame)

    # If the Esc key is pressed, stop the cycle
    if cv2.waitKey(1) & 0xFF == 27:
        break
# Release the video capture and close all windows
cap.release()
cv2.destroyAllWindows()

```

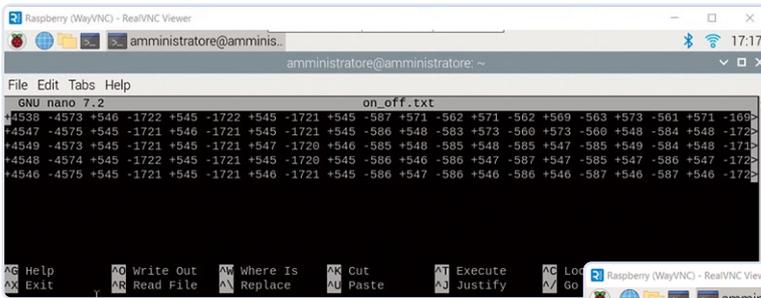


Figure 7. Signal reçu de la télécommande, lié au bouton marche-arrêt dans l'encodage du mode2. (Source : RealVNC [www.realvnc.com/en/](http://www.realvnc.com/en/))

Depuis le terminal :

```
apt install v4l-utils
```

*v4l-utils* est un paquet d'utilitaires open-source conçu pour fonctionner avec les périphériques vidéo Linux (V4L, Video for Linux). V4L est un sous-système du noyau Linux qui permet aux applications d'interagir avec les périphériques vidéo, tels que les webcams, les tuners TV, les cartes d'acquisition vidéo et, bien sûr, les signaux IR.

Les utilitaires *v4l-utils* fournissent un ensemble d'outils pour configurer, contrôler et gérer ces périphériques.

Dans le listage 1, vous avez remarqué que l'instruction `ir-ctl` est associée à la commande `os.system` (c'est-à-dire une instruction Python qui exécute directement une fonctionnalité appartenant au système).

C'est l'un des utilitaires de *v4l-utils* qui vous permet de contrôler les périphériques IR. Avec `ir-ctl`, vous pouvez envoyer et recevoir des signaux infrarouges. Dans le répertoire `/dev/` se trouvent les fichiers `lirc0` pour l'envoi de signaux et `lirc1` pour la transmission, qui sont des fonctionnalités dérivées du paquetage LIRC, désormais intégré au noyau du système d'exploitation dans les dernières versions de Linux. Pour en savoir plus, vous pouvez vous rendre ici [6].

Testez-le maintenant, en saisissant :

```
ir-ctl -d /dev/lirc1 --receive=on_off.txt
```

Le terminal reste en attente d'événements. Prenez la télécommande que vous voulez « cloner », appuyez sur le bouton `on_off` en le dirigeant vers le récepteur IR. Essayez d'appuyer rapidement, et une seule fois, pour ne pas envoyer trop de codes en même temps. Appuyez sur `ctrl+c` pour terminer l'acquisition. Analysez avec nano le fichier `on_off.txt` créé.

Le fichier doit ressembler à la figure 7. La séquence de chiffres reçue est en `mode2` qui est un type spécifique d'encodage des signaux IR capturés. Chaque paire de chiffres représente la longueur des impulsions (+, ou impulsion) et les intervalles entre les impulsions (-, ou espace). Le Mode2 est également une fonctionnalité de `lirc`, comme nous l'avons déjà mentionné, maintenant intégrée dans le système d'exploitation. Pour en savoir plus, vous pouvez consulter [7].

Si vous avez appuyé assez longtemps sur la touche `on_off`, il se peut que vous ayez stocké plusieurs lignes de mode2 codes. Vous devrez alors supprimer ceux qui se répètent. En effet, la première ligne du codage suffit, les autres sont pratiquement des répétitions du codage reçu (d'ailleurs, on peut voir la similitude entre les lignes).

Après avoir supprimé les lignes inutiles, allez à la fin de la première et supprimez la dernière valeur, qui représente le délai d'attente entre les envois de signaux (entre les lignes). Cette valeur n'est pas nécessaire à la transmission, et elle est également facile à identifier car c'est un nombre assez important, comparé aux autres.

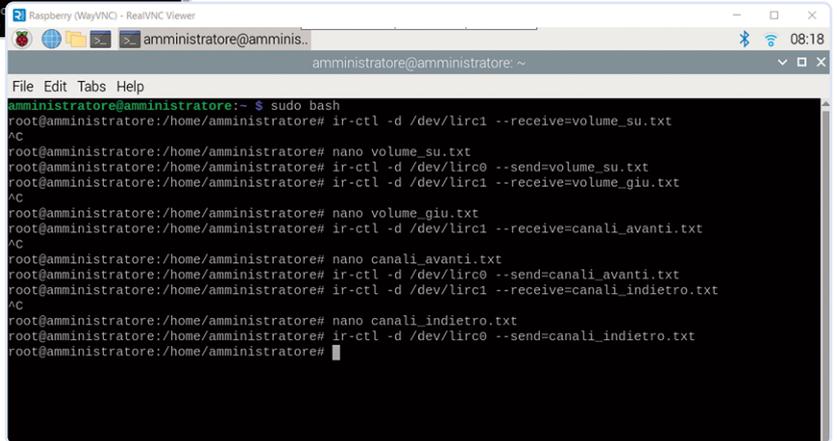


Figure 8. Enregistrement et envoi des autres signaux IR de la télécommande. (Source : RealVNC [www.realvnc.com/en/](http://www.realvnc.com/en/))

Enregistrez le fichier et revenez au terminal (`ctrl+x ; yes`). Orientez l'émetteur vers le téléviseur et saisissez sur le terminal :

```
ir-ctl -d /dev/lirc0 --send=on_off.txt
```

Si tout a fonctionné, votre téléviseur se sera allumé « par magie » (ou éteint, s'il était déjà allumé). Effectuez la même procédure pour les autres touches, comme illustré à la figure 8. Vous pouvez, bien sûr, modifier les correspondances à votre guise. Celles de notre projet sont présentées dans le tableau 1.

Nous recommandons de placer le fichier Python, le modèle MediaPipe `gesture_recognizer.task` et les fichiers `txt` dans le dossier `personnel` principal (dans notre projet, `/home/admin`).

Exécutez le fichier Python et placez votre main dans le cadre de la webcam. Alternez les commandes gestuelles avec le poing - qui n'a pas d'instructions appariées - afin de bien les discriminer. Les figures 9a à 9d montrent le système à l'œuvre, reconnaissant le doigt pointé vers le haut (9a), la paume ouverte (9b), le pouce vers le bas (9c) et le pouce levé (9d).

Pendant que vous contrôliez votre appareil en ouvrant la paume de votre main, ne vous êtes-vous pas senti comme un Jedi, du moins pendant un certain temps ?

Tableau 1. Correspondance entre les gestes de la main et les commandes de la télévision.

| Geste de la main   | Commande TV | Fichier txt         |
|--------------------|-------------|---------------------|
| Palm Open          | On-Off      | on_off.txt          |
| Thumb Up           | Volume Up   | volume_su.txt       |
| Thumb Down         | Volume Down | volume_giu.txt      |
| Finger Pointing Up | Channel Fwd | canali_avanti.txt   |
| Victory Sign       | Channel Rev | canali_indietro.txt |

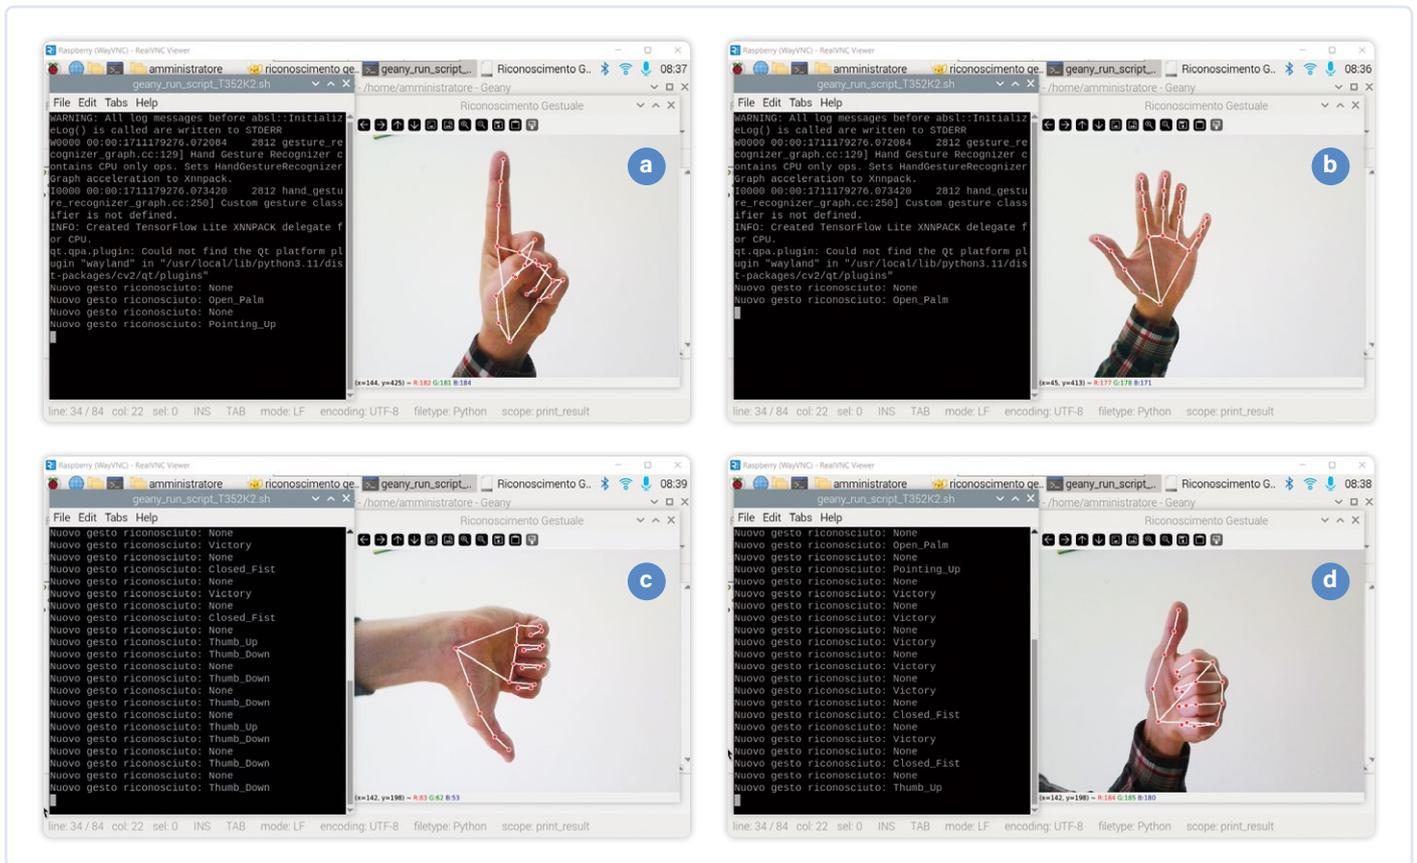


Figure 9. Ces quatre images montrent les principaux gestes reconnus par le système. À droite de chacune d'entre elles, vous pouvez lire les séquences de reconnaissance, qui varient en fonction de la sortie du processus. (Source : RealVNC [www.realvnc.com/en/](http://www.realvnc.com/en/))

## Autres applications

Nous avons commencé à explorer le monde de l'intelligence artificielle et de l'apprentissage automatique à travers un projet initialement simple, qui ouvre toutefois la porte à un cursus enrichissant dans un domaine nouveau et captivant, là où la technologie moderne évolue avec rapidité. Utilisant un Raspberry Pi, très prisé dans la communauté des makers, nous avons la flexibilité de remplacer notre circuit imprimé (PCB) par n'importe quel périphérique de sortie. Cela nous permet de contrôler divers appareils électriques dans notre maison. Un ensemble de fichiers téléchargeables pour le logiciel et les schémas de circuits imprimés pour ce projet est disponible sur la page web d'Elektor Labs [8].

240433-04

## Questions ou commentaires ?

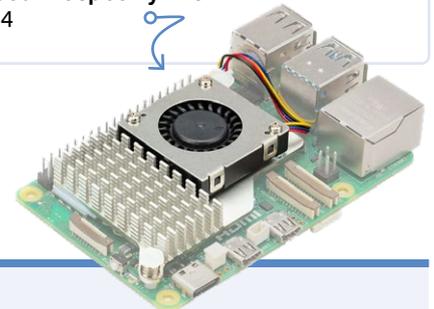
Contactez Elektor ([redaction@elektor.fr](mailto:redaction@elektor.fr)).



## Produits

➤ **Raspberry Pi 5 (8 GB RAM)**  
[www.elektor.fr/20599](http://www.elektor.fr/20599)

➤ **Refroidisseur actif pour Raspberry Pi 5**  
[www.elektor.fr/20604](http://www.elektor.fr/20604)



## LIENS

- [1] European Safety Transport Council on EuroNCAP : <https://tinyurl.com/3rs8z9cv>
- [2] Page web de MediaPipe Studio gesture recognition : <https://tinyurl.com/44jxnep8>
- [3] MediaPipe customization guide : <https://tinyurl.com/y9bbpu5h>
- [4] RealVNC VNC viewer - page de téléchargement : <https://tinyurl.com/3dvhjfru>
- [5] MediaPipe gesture recognition task download: <https://tinyurl.com/4xsrfz8z>
- [6] Page web de LIRC : <https://lirc.org/>
- [7] Ubuntu webpage for ir-ctl tool usage : <https://tinyurl.com/68xpxd22>
- [8] Ce projet sur Elektor Labs : <https://www.elektormagazine.fr/labs/ai-based-universal-ir-remote-control>

# L'IA pour la conception de produits

le monde des générateurs d'art IA



Figure 1. Rendu d'un amplificateur Hi-Fi créé avec Midjourney par l'auteur.

Edwin van den Oetelaar (Pays-Bas)

Au cours de l'année passée, l'IA pour la création d'images a réalisé des progrès notables, démocratisant ainsi cette technologie. Cela représente-t-il un outil puissant pour les amateurs d'électronique et les créateurs ? Un simple croquis et une description soignée peuvent désormais produire des images photoréalistes de nos idées. Mais est-ce réellement aussi simple ? Quelle utilité pratique cette technologie offre-t-elle vraiment ?

Depuis l'émergence de l'IA, j'ai été fasciné par ses possibilités créatives et je me suis empressé de tester les nouveaux outils disponibles en ligne, tels que Midjourney, Stable Diffusion, Freepik Sketch, et Dall-E 3.0. Dans cet article, je souhaite partager mon avis sur ces outils, tout en précisant que cette liste n'est pas exhaustive et pourrait être obsolète au moment de sa publication. J'ai tenté de concevoir un amplificateur audio esthétiquement plaisant, en combinant croquis, photos d'équipements existants et directives précises. Utilisant principalement Midjourney ainsi que d'autres plateformes, je décrirai aussi des concepts techniques tels que l'ingénierie des invites, l'inpainting et le transfert de style, afin de matérialiser ma vision.

## Des progrès fulgurants

Si je devais partir d'un constat initial, je dirais que les développements dans le domaine de la génération d'images par Gen-AI évoluent à la vitesse de l'éclair. Chaque semaine voit l'émergence de nouveaux services et modèles en ligne. La qualité des images s'améliore de manière impressionnante. Il semble désormais exister une solution IA pour chaque besoin.

La commodité est au service de l'utilisateur - si vous n'arrivez pas à trouver une idée ou si la créativité vous fait défaut, divers services payants vous proposent des exemples d'idées, des styles et des modèles adaptés à chaque défi, qu'il s'agisse de conception de logos, de choix de palettes de couleurs, de design d'applications ou de stylisme de mode. De plus en plus d'entreprises intègrent l'IA à leurs services existants, et le nombre d'outils et de modèles hors ligne de qualité supérieure continue de croître, incluant des options comme Flux-1-Schnell et Stable Diffusion.

Les portraits photoréalistes générés par ces technologies sont désormais si proches des vraies photos qu'ils trompent même les regards les plus avertis. Les défis récents, tels que l'incorporation de texte dans les images, sont désormais aisément surmontés, et les anomalies telles que les membres déformés deviennent rares. L'IA offre une nouvelle source d'inspiration. Avec de simples commandes textuelles, l'IA est capable de générer diverses variations d'un design, ouvrant la voie à des idées novatrices. Des outils comme Midjourney et Stable Diffusion XL permettent aux utilisateurs de créer plusieurs prototypes à partir d'un simple croquis ou d'une consigne, facilitant l'exploration de possibilités de design autrement ignorées.

La **figure 1** montre un rendu d'un amplificateur Hi-Fi créé avec Midjourney. (Voir l'encadré **Démarrer avec Midjourney**).

### Démarrer avec Midjourney

Comment démarrer avec Midjourney : en un clic !

- › Rendez-vous sur le site officiel de Midjourney [1].
- › Cliquez sur « Se connecter » pour vous connecter avec votre compte Discord ou votre compte Google.
- › Voilà, c'est tout.

### Ingénierie des invites

L'ingénierie des invites est la formulation ciblée de commandes textuelles pour guider les IA génériques, telles que Midjourney et Stable Diffusion, dans la création d'images. Dans la conception de produits, cette technique requiert l'utilisation de termes spécifiques et de descriptions détaillées pour instruire l'IA sur les formes, styles et détails désirés. Il est crucial d'être minutieux dans la formulation des tâches afin que les images produites soient fidèles à la vision initiale. Toutefois, cette démarche peut être complexe, car une même invite peut entraîner différentes variations, illustrées par les quatre exemples de la **figure 2**. Cette variabilité est due à l'utilisation d'un paramètre aléatoire, ou "seed", que vous pouvez fixer avec Stable Diffusion pour influencer le résultat.

Une utilisation courante de *ChatGPT* (également une Gen-AI) est de générer des invites. Vous pouvez demander à ChatGPT comment configurer au mieux une invite, par exemple pour Midjourney. Vous obtiendrez alors une explication sur la façon dont une telle invite est construite, les facteurs de pondération, les drapeaux, etc, avec lesquels vous pouvez expérimenter et itérer.

### La facilité d'édition et d'affinage

L'un des principaux attraits de la Gen-AI réside dans sa capacité à modifier ou à affiner des idées existantes plus aisément que de créer à partir de zéro. Ce processus itératif offre aux concepteurs la possibilité d'explorer rapidement différentes alternatives. Cela s'aligne parfaitement avec la manière de procéder de nombreux jeunes amateurs qui préfèrent essayer quelque chose rapidement, puis le peaufiner, trouvant dans cette rapidité une source de motivation. La technique d'élimination sélective et de régénération de certaines parties d'une image est connue sous le nom d'*inpainting sélectif*. La **figure 3** illustre cette méthode.

### Limites du graphisme ludique

Les technologies telles que la Gen-AI, l'impression 3D, et la découpe laser permettent souvent de produire d'innombrables itérations sans se préoccuper des coûts. Cela peut être amusant et rapide, mais sans une vision claire du design, sans dimensions appropriées ou matériaux adaptés à la fonction envisagée, les résultats seront insatisfaisants. Il est crucial de planifier à l'avance ce que l'on souhaite réaliser, de réfléchir aux utilisations possibles et de travailler de manière ciblée. Sans un ensemble défini de règles de conception, de matériaux et de dimensions, il est impossible d'atteindre un résultat cohérent.

### Le facteur d'accoutumance, toujours variable !

L'utilisation de plateformes comme Midjourney peut parfois sembler plus ludique qu'utile, avec des utilisateurs générant sans cesse de nouvelles variations dans l'espoir qu'un chef-d'œuvre émerge spontanément. Pour les passionnés disposant de beaucoup de temps libre, comme ceux qui travaillent depuis leur grenier, le processus de génération continue d'itérations et de variations peut devenir addictif, semblable à d'autres activités en ligne. Chaque nouvelle variation générée provoque une poussée d'adrénaline comparable à celle ressentie lors de jeux d'argent ou de hasard, rendant l'expérience excitante et engageante.

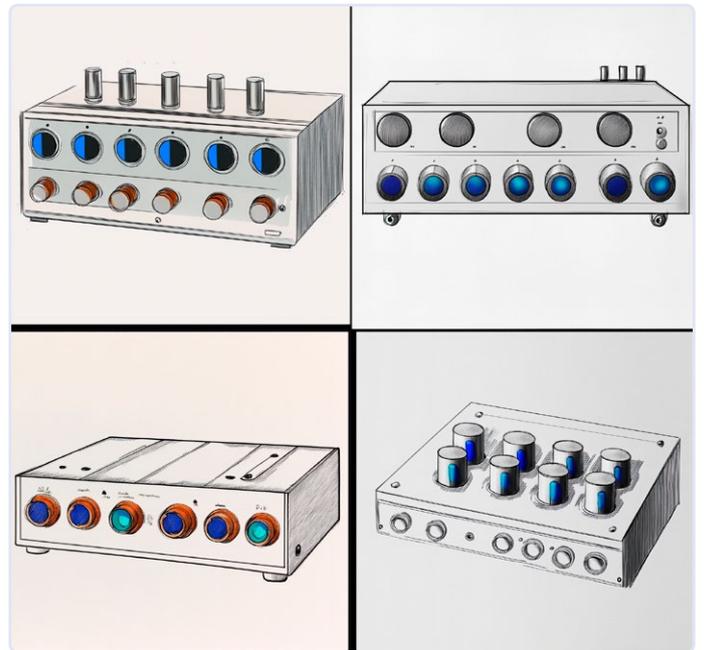


Figure 2. La même invite a produit quatre variantes différentes d'amplificateur.

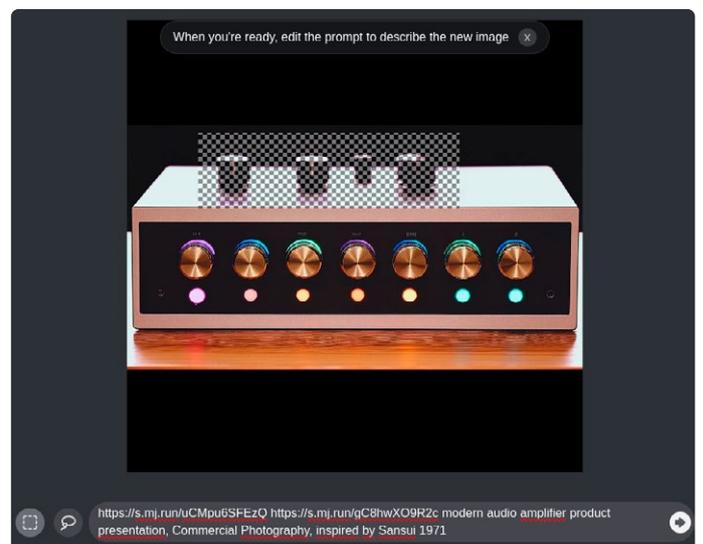


Figure 3. Application de la technique d'*inpainting sélectif*, pour supprimer une partie indésirable de l'image générée.

Figure 4. Exemple d'image générée par l'IA, issue du mélange et de l'interprétation des deux images sources.



### Limites, médiocrité

Les IA génériques telles que Midjourney et Stable Diffusion travaillent à partir d'un vaste ensemble de données d'images existantes. L'IA combine des éléments de ces données pour créer une sorte de vue « moyenne ». Cela peut donner l'impression qu'il est difficile de créer des images vraiment nouvelles, puisque la Gen-AI se rabat toujours sur ce qu'elle a « vu » auparavant.

L'ingénierie intelligente des invites permet aux utilisateurs de forcer des combinaisons uniques et surprenantes. La puissance de l'IA réside précisément dans la combinaison d'éléments de manière inattendue, créant des images qui semblent originales et différentes, même lorsqu'elles sont basées sur des données existantes. Si l'IA ne peut pas créer des choses entièrement nouvelles à partir de zéro, elle peut produire des résultats perçus comme uniques en raison de la façon dont elle réinterprète des éléments familiers.

### Utilisation de facteurs de pondération et de références stylistiques dans les messages-guides

Les facteurs de pondération dans les invites peuvent être utilisés pour mettre l'accent sur certains éléments de la conception. Cela permet de mieux contrôler le résultat et de créer des dessins qui reflètent plus fidèlement la vision souhaitée. Vous pouvez utiliser des `::` et des valeurs numériques à cette fin.

Un exemple dans Midjourney : Si vous souhaitez que l'IA mette l'accent sur un dispositif au premier plan et non à l'arrière-plan, vous pouvez le faire avec une invite telle que :

```
/imagine a high-tech speaker on a table in a modern living room, clean design, minimalist ::2 background blurred ::0.5
```

Ici `minimalist` a un facteur de pondération de 2 par rapport aux autres éléments et `background blurred` juste un facteur de pondération de 0,5.

Les références de style renvoient à une autre image pour adopter un style spécifique. Pour ce faire, vous utilisez `--sref` suivi de l'URL de l'image de référence.

Dans Midjourney, si vous souhaitez adopter un style spécifique d'une image, utilisez par exemple :

```
/imagine futuristic device with blue accents --sref https://example.com/image.jpg
```

### Coût et accessibilité

La conception traditionnelle de produits peut être longue et coûteuse, en particulier pour les amateurs disposant de ressources limitées. Les outils de la Gen-AI réduisent considérablement cet obstacle en permettant de générer des conceptions rapidement et à peu de frais. Au lieu de passer des heures à faire des croquis et à modéliser, les concepteurs peuvent désormais créer des dizaines d'images en quelques minutes.

La disponibilité d'IA génériques abordables ou gratuites rend cette technologie accessible à un large public. Des outils comme DALL-E d'OpenAI (via le site ChatGPT) et Flux ou Stable Diffusion (via *poe.com*) offrent même un accès gratuit aux fonctions de base, ce qui permet aux amateurs de se lancer en un rien de temps.

Pour les makers, il n'est peut-être pas utile d'apprendre tous les tenants et aboutissants des outils GenAI. Ces outils évoluent rapidement et deviennent obsolètes au même rythme. En outre, la création de graphiques n'est souvent pas dans les cordes des ingénieurs en électronique, qui se concentrent davantage sur la fonction que sur la forme. Cherchez autour de vous des personnes dont le hobby est la stimulation GenAI, tout comme vous avez votre propre hobby. Collaborer avec eux peut être non seulement agréable, mais aussi mutuellement instructif.

### Aperçu des générateurs d'art IA en ligne

#### Bing Image Creator

- Modèle artistique d'IA : DALL-E 3.
- Plate-forme : Web.
- Prix : Gratuit : Gratuit.

Bing Image Creator est le résultat de la collaboration entre Microsoft et OpenAI. Il utilise le dernier modèle de DALL-E, DALL-E 3, et est actuellement disponible gratuitement.

#### DALL-E 3 (via ChatGPT)

- Plate-forme : Web (via ChatGPT).
- Coût : 20 \$/mois dans le cadre de ChatGPT Plus.

DALL-E 3 est une amélioration substantielle par rapport à DALL-E 2, surtout si vous avez un abonnement ChatGPT Plus. Les résultats sont nettement meilleurs et vous avez plus de contrôle en le combinant avec ChatGPT.

## Canva

- › Modèle artistique AI : Stable Diffusion.
- › Plateforme : Web, iOS, Android.
- › Coût : gratuit : Gratuit ; à partir de 12,99 \$/mois pour Pro avec plus de fonctionnalités d'IA.

Canva a récemment ajouté un générateur d'art texte-image. Cette fonctionnalité s'intègre parfaitement au reste de l'application de conception basée sur des modèles, ce qui vous permet d'ajouter un art généré par l'IA à tout, des posts sur les médias sociaux aux cartes d'anniversaire.

## NightCafe

- › Modèles artistiques d'IA : Stable Diffusion, DALL-E 2, CLIP-Guided Diffusion, VQGAN-CLIP.
- › Plateforme : Web.
- › Coût : À partir de 6 \$/mois pour 100 crédits (bons pour environ 1 240 images par mois).

NightCafe offre des fonctionnalités supplémentaires telles que des styles pour DALL-E 2 et Stable Diffusion, et vous permet d'utiliser d'anciens modèles d'art génératif.

## OpenArt

- › Modèles d'art AI : Stable Diffusion, DALL-E 2, et autres modèles open-source.
- › Plate-forme : Web.
- › Coût : Gratuit pour 50 crédits d'essai ; à partir de 10 \$/mois pour 5 000 crédits.

Comme NightCafe, OpenArt offre des fonctionnalités supplémentaires pour Stable Diffusion et DALL-E 2, ainsi qu'un accès à des modèles open-source supplémentaires. Vous avez plus de contrôle sur les détails spécifiques des images que vous générez. OpenArt propose également des options telles que le sketch-to-image et

un transformateur de stock art qui adapte les images de stock à vos besoins.

## Adobe FireflyFl

- › Plate-forme : Web, Adobe Express, Adobe Photoshop et autres outils Adobe.
- › Coût : Gratuit pour 25 crédits par mois ; à partir de 5 \$/mois pour 100 crédits par mois (et inclus dans divers abonnements Adobe).

Bien que vous puissiez l'utiliser en ligne, il est désormais intégré directement dans les produits Adobe tels qu'Express et Photoshop. L'une des meilleures fonctionnalités de Firefly est la possibilité de créer des effets de texte personnalisés à l'aide d'une invite écrite.

## Quora Poe

Une plateforme, Quora Poe, une application ou un service créé par Quora, est disponible sur le Web. Cette plateforme permet aux utilisateurs d'interagir avec différents modèles d'IA, notamment ChatGPT et d'autres chatbots basés sur l'IA. On y trouve, entre autres, FLUX-schnell [2] et Stable Diffusion [3]. Il y aura probablement un nombre limité de crédits, mais vous pouvez les essayer.

## Autres services en ligne

Dans mon bricolage général, j'ai également expérimenté FreePik [4]. Cet outil propose une fonctionnalité intéressante : en plus de saisir des prompts - comme Midjourney ou Stable Diffusion - vous pouvez esquisser en temps réel. Au fur et à mesure que vous dessinez, l'image s'adapte à votre esquisse.

Ce que l'on remarque cependant, c'est que l'image change constamment, ce qui rend difficile un contrôle précis. Le dimensionnement et la précision technique font défaut à tous les ImageGen-AI. La **figure 5** montre un exemple de rendu : l'image rendue à droite est dérivée directement de l'esquisse (très) grossière faite à la main à gauche.

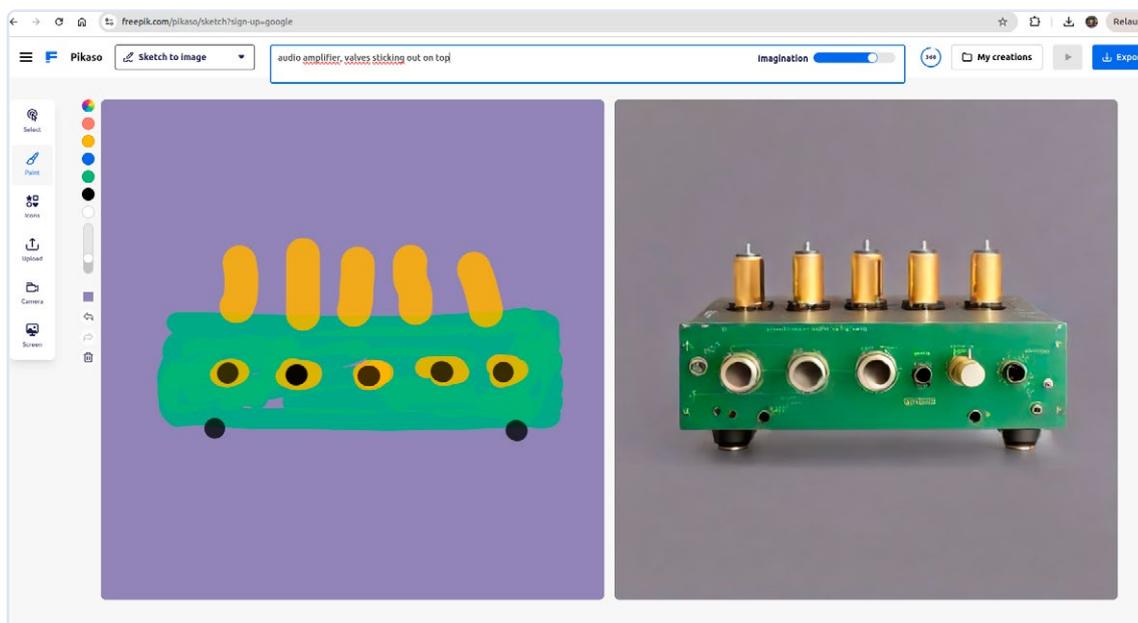


Figure 5. L'IA est utile ! L'image rendue à droite a été créée par FreePik à partir de l'esquisse (très) provisoire réalisée à la main à gauche.

FreePik est gratuit pour un nombre limité d'actions par jour, mais si vous voulez vraiment vous lancer, un abonnement est nécessaire. Outre FreePik, de nombreux nouveaux services en ligne sont désormais disponibles.

Bien sûr, il en existe beaucoup d'autres sur le web : il suffit de taper : « AI art generators » dans votre barre de recherche, et vous découvrirez un monde dont vous ignoriez probablement l'existence !

## Alternatives hors ligne

**Flux.1-Schnell** (je recommande celui-ci) : Une implémentation rapide et efficace de la diffusion stable, conçue pour fonctionner sur du matériel grand public.

- Avantages : Rapide, efficace, et peut fonctionner sur du matériel moins puissant.
- CONTRE : Peut-être moins personnalisable que l'implémentation complète de Stable Diffusion.

Pour tester Flux.1 en ligne ou l'exécuter chez vous, visitez [5]. Gardez à l'esprit que vous aurez besoin d'une carte vidéo puissante si vous voulez vous installer, de préférence une Nvidia avec au moins 12 GB VRAM et de nombreux CUDA cores. Plus la carte est puissante, moins vous aurez de latence.

**Stable Diffusion web UI**: si vous souhaitez vous initier à celle-ci sur votre propre PC, vous pouvez jeter un coup d'œil à [6]. Là encore, une carte vidéo puissante est indispensable pour un fonctionnement fluide.

## Limites techniques de la Gen-AI dans la conception

Les contraintes techniques sur la forme et la fonction rendent le travail de l'ingénieur à la fois intéressant et indispensable. L'ingénieur doit tenir compte d'un large éventail d'exigences - des performances fonctionnelles à la fabricabilité, la maintenabilité et la recyclabilité, également connues sous le nom de *Design for X* (DFx). Les outils Gen-AI ne sont actuellement pas (encore) en mesure de fournir ce processus ; bien qu'ils puissent rapidement générer de jolies images, la valeur réelle d'une bonne conception réside dans l'application pratique des connaissances et de l'expérience en matière d'ingénierie.

## L'avenir de l'IA générique dans la conception

De nouveaux outils sont disponibles chaque jour ; on a l'impression de vivre une aventure, de faire de nouvelles découvertes chaque jour. Cependant, le rôle de l'ingénieur reste crucial dans la création de conceptions fonctionnelles et fabricables. La Gen-AI peut actuel-

lement servir principalement d'outil pour visualiser rapidement des idées, mais le processus de conception proprement dit nécessite une collaboration approfondie entre l'ingénieur, le concepteur et le dessinateur industriel pour répondre à toutes les exigences complexes. Les outils d'IA actuels ne sont pas encore suffisamment utiles à cet égard, mais ils peuvent contribuer au processus créatif en générant rapidement des concepts visuellement attrayants. Pour l'instant, leur utilité se limite donc à cet aspect du processus de conception. ◀



230514-04

### À propos de l'auteur

Ing. Edwin van den Oetelaar, expert et coach technique à Fontys ICT, collabore avec les étudiants sur des projets captivants comme la construction de robots, de véhicules autonomes et d'autres dispositifs électroniques. Passionné d'enseignement pratique, il aide les étudiants à développer des compétences authentiques à travers des projets tangibles. Qu'il s'agisse de concevoir des circuits ou de développer des technologies innovantes, Edwin est toujours à la pointe et partage volontiers son savoir. Durant son temps libre, il s'adonne à l'électronique et suit les évolutions du secteur. Convaincu que l'apprentissage et la création doivent rester ludiques, il s'efforce d'inspirer la future génération d'ingénieurs.

### Questions ou commentaires ?

Contactez Elektor (redaction@elektor.fr).

### Note de l'auteur

Les personnes désireuses d'en savoir plus sur l'IA peuvent lire le livre *Living and Learning With AI*, écrit (en néerlandais) par mes collègues de la faculté des TIC [7].



### Produits

- **D. Situnayake, Jenny Plunkett, *AI at the Edge* (O'Reilly, 2023)**  
[www.elektor.fr/20465](http://www.elektor.fr/20465)



## LIENS

- [1] Site officiel de Midjourney : <https://www.midjourney.com/>
- [2] FLUX-schnell at Quora Poe website: <https://poe.com/FLUX-schnell>
- [3] Stable Diffusion XL at Quora Poe website: <https://poe.com/StableDiffusionXL>
- [4] Pikaso's website: <https://www.freepik.com/pikaso>
- [5] Website for Flux.1 testing: <https://huggingface.co/black-forest-labs/FLUX.1-schnell>
- [6] Stable Diffusion on GitHub: <https://github.com/AUTOMATIC1111/stable-diffusion-webui>
- [7] R. Huijts, K. Suilen, D. Bloks, E. Saçan "Leven en Leren met AI" (Noordhoff Business): <https://tinyurl.com/hdej6mpm>

# Mettez la main sur du matériel d'IA de pointe !

## Kit Raspberry Pi AI

Le Raspberry Pi AI Kit comprend le HAT M.2 pour Raspberry Pi et un module d'accélération IA Hailo, destiné à être utilisé avec le Raspberry Pi 5. Il offre un moyen accessible, économique et écoénergétique d'intégrer une IA performante. Découvrez des applications telles que le contrôle de processus, la sécurité, l'automatisation domestique et la robotique !

[www.elektor.fr/20879](http://www.elektor.fr/20879)



## Unitree Go2 Pro Robot quadrupède

L'Unitree Go2 est un robot quadrupède conçu pour la recherche et le développement de systèmes autonomes dans les domaines de l'interaction homme-robot (HRI), SLAM et le transport. Grâce à ses quatre jambes et à ses 12 degrés de liberté (12DOF), ce robot peut s'adapter à divers types de terrains.

[www.elektor.fr/20357](http://www.elektor.fr/20357)



## BeagleY-AI SBC avec GPU, DSP et accélérateurs d'IA

Le BeagleY-AI est un ordinateur monocarte 64 bits quadricœur, puissant, open-source et abordable, équipé d'un GPU, d'un DSP et d'accélérateurs de vision/apprentissage profond, conçu pour les développeurs et les créateurs. Les utilisateurs peuvent profiter des images logicielles Debian Linux fournies par BeagleBoard.org, qui incluent un environnement de développement intégré.

[www.elektor.fr/20991](http://www.elektor.fr/20991)

## Raspberry Pi AI Camera

La Raspberry Pi AI Camera est un module caméra compact basé sur le capteur de vision intelligent Sony IMX500. L'IMX500 combine un capteur d'image CMOS de 12 MP avec une accélération d'inférence intégrée pour divers modèles de réseaux neuronaux, permettant aux utilisateurs de développer des applications IA avancées basées sur la vision sans nécessiter d'accélérateur séparé.

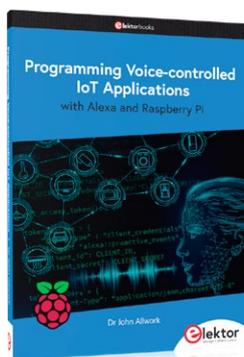
[www.elektor.fr/20953](http://www.elektor.fr/20953)



## Kit de développement Waveshare Jetson Orin Nano AI

Ce kit de développement informatique pour l'IA en périphérie est basé sur le module Jetson Orin Nano et propose une grande variété d'interfaces périphériques telles que M.2, DP, USB, etc. Le kit est également livré avec une carte réseau sans fil AW-CB375NF préinstallée, qui prend en charge Bluetooth 5.0 et le Wi-Fi double bande, avec deux antennes PCB supplémentaires, pour assurer une connexion réseau sans fil rapide et fiable ainsi qu'une communication Bluetooth.

[www.elektor.fr/20762](http://www.elektor.fr/20762)



## Programming Voice-controlled IoT Applications with Alexa and Raspberry Pi

Ce livre est divisé en deux parties : la création de compétences Alexa et la conception de dispositifs IoT (Internet des objets) utilisant un Raspberry Pi. Il couvre des sujets tels que le développement de compétences Alexa, les achats intégrés, et l'utilisation d'AWS Lambda, ainsi que la création d'appareils domestiques intelligents contrôlés par Alexa. Les lecteurs apprennent également la messagerie MQTT, la création de notifications proactives, et la transformation d'un Raspberry Pi en un appareil Alexa autonome.

[www.elektor.fr/20400](http://www.elektor.fr/20400)

# Rejoignez la communauté Elektor



Devenez membre  
maintenant !



- ✓ accès à l'archive numérique depuis 1978 !
- ✓ 8x magazine imprimé Elektor
- ✓ 8x magazine numérique (PDF)
- ✓ 10 % de remise dans l'e-choppe et des offres exclusives pour les membres
- ✓ accès à plus de 5000 fichiers Gerber



Également disponible

abonnement



sans papier !

- ✓ accès à l'archive numérique d'Elektor
- ✓ 10 % de remise dans l'e-choppe
- ✓ 8x magazine Elektor (PDF)
- ✓ accès à plus de 5000 fichiers Gerber



[www.elektormagazine.fr/membres](http://www.elektormagazine.fr/membres)