

تم تحميل وعرض المادة من منصة



www.haqibati.net



منصة حقيبة التعليمية

منصة حقيبة هو موقع تعليمي يعمل على تسهيل العملية التعليمية بطريقة بسيطة وسهلة وتوفير كل ما يحتاجه المعلم والطالب لكافحة الصنوف الدراسية كما يحتوي الموقع على حلول جميع المواد مع الشروح المتنوعة للملمين.

المملكة العربية السعودية



وزارة التعليم

Ministry of Education

قررت وزارة التعليم تدريس
هذا الكتاب وطبعه على نفقتها

الذكاء الاصطناعي

التعليم الثانوي - نظام المسارات

السنة الثالثة

يُنْزَعُ مِجانًاً وَلِرِبَاعٍ

طبعة 2024-1446

ح()وزارة التعليم، ١٤٤٤ هـ

فهرسة مكتبة الملك فهد الوطنية أثناء النشر
وزارة التعليم

الذكاء الاصطناعي - المرحلة الثانوية - نظام المسارات - السنة
الثالثة . / وزارة التعليم . - الرياض ، ١٤٤٤ هـ
٣٤١ ص : ٢١٤ ٥٠٢ ٢١٤ سم

ردمك : ٩٧٨-٦٠٣-٥١١-٤٩٥-٠

١ - التعليم - مناهج - السعودية أ . العنوان
١٤٤٤ / ١١١٢٢ ديوي ٣٧٥, ٠٠٩٥٣١

رقم الإيداع : ١٤٤٤ / ١١١٢٢

ردمك : ٩٧٨-٦٠٣-٥١١-٤٩٥-٠

حقوق الطبع والنشر محفوظة لوزارة التعليم

www.moe.gov.sa

مواد إثرائية وداعمة على "منصة عين الإثرائية"



ien.edu.sa

أعزاءنا المعلمين والمعلمات، والطلاب والطالبات، وأولياء الأمور، وكل مهتم بال التربية والتعليم:
يسعدنا تواصلكم: لتطوير الكتاب المدرسي، ومقترحاتكم محل اهتمامنا.



fb.ien.edu.sa

الناشر: شركة تطوير للخدمات التعليمية

تم النشر بموجب اتفاقية خاصة بين شركة Binary Logic SA وشركة تطوير للخدمات التعليمية
(عقد رقم 3/0003/2022) للاستخدام في المملكة العربية السعودية

حقوق النشر © Binary Logic SA 2023

جميع الحقوق محفوظة. لا يجوز نسخ أي جزء من هذا المنشور أو تخزينه في أنظمة استرجاع البيانات أو نقله بأي شكل أو بأي وسيلة إلكترونية أو ميكانيكية أو بالنسخ الصوتي أو التسجيل أو غير ذلك دون إذن كتافي من الناشرين.

يرجى ملاحظة ما يلي: يحتوي هذا الكتاب على روابط إلى مواقع إلكترونية لا تدار من قبل شركة Binary Logic. ورغم أن شركة Binary Logic تتبذل قصارى جهودها لضمان دقة هذه الروابط وحدثتها وملايينها، إلا أنها لا تتحمل المسؤولية عن محتوى أي موقع إلكترونية خارجية.

إشعار بالعلامات التجارية: أسماء المنتجات والشركات المذكورة هنا قد تكون علامات تجارية أو علامات تجارية مسجلة وستستخدم فقط بغرض التعريف والتوضيح وليس هناك أي نية لانتهاك الحقوق. تنفي شركة Binary Logic وجود أي ارتباط أو رعاية أو تأييد من جانب مالكي العلامات التجارية المعنيين. تُعد Tinkercad علامة تجارية مسجلة لشركة Autodesk Inc. تُعد Python وشعارات Python علامات تجارية مسجلة لشركة Python Software Foundation. تُعد Jupyter علامة تجارية مسجلة لشركة Project Jupyter. تُعد CupCarbon علامة تجارية مسجلة لشركة CupCarbon. تُعد Arduino علامة تجارية مسجلة لشركة Arduino SA. تُعد Webots علامة تجارية مسجلة لشركة Cyberbotics Ltd. وCupCarbon.

ولا ترعى الشركات أو المنظمات المذكورة أعلاه هذا الكتاب أو تصرح به أو تصادق عليه.

حاول الناشر جاهداً تبع ملوك الحقوق الفكرية كافة، وإذا كان قد سقط اسم أيٌّ منهم سهواً فسيكون من دواعي سرور الناشر اتخاذ التدابير اللازمة في أقرب فرصة.



مقدمة

إن تقدم الدول وتطورها يقاس ب مدى قدرتها على الاستثمار في التعليم، ومدى استجابة نظامها التعليمي لمتطلبات العصر ومتغيراته. وحرصاً من وزارة التعليم على ديمومة تطوير أنظمتها التعليمية، واستجابة لرؤية المملكة العربية السعودية 2030 فقد باذرت الوزارة إلى اعتماد نظام «مسارات التعليم الثانوي» بهدف إحداث تغيير فاعل وشامل في المرحلة الثانوية.

إن نظام مسارات التعليم الثانوي يقدم نموذجاً تعليمياً متميزاً وحديثاً للتعليم الثانوي بالملكة العربية السعودية يسهم بكفاءة في:

- تعزيز قيم الانتماء لوطننا المملكة العربية السعودية، والولاء لقيادته الرشيدة حفظهم الله، انطلاقاً من عقيدة صافية مستندة على التعاليم الإسلامية السمحاء.
 - تعزيز قيم المواطنة من خلال التركيز عليها في المواد الدراسية والأنشطة، اتساقاً مع مطالب التنمية المستدامة، والخطط التنموية في المملكة العربية السعودية التي تؤكد على ترسیخ ثانوية القيم والهوية، والقائمة على تعاليم الإسلام والوسطية.
 - تأهيل الطلبة بما يتواافق مع التخصصات المستقبلية في الجامعات والكليات أو المهن المطلوبة؛ لضمان اتساق مخرجات التعليم مع متطلبات سوق العمل.
 - تمكين الطلبة من متابعة التعليم في المسار المفضل لديهم في مراحل مبكرة، وفق ميولهم وقدراتهم.
 - تمكين الطلبة من الالتحاق بالتخصصات العلمية والإدارية النوعية المرتبطة بسوق العمل، ووظائف المستقبل.
 - دمج الطلبة في بيئه تعليمية ممتعة ومحفزة داخل المدرسة قائمة على فلسفة بنائية، وممارسات تطبيقية ضمن مناخ تعليمي نشط.
 - نقل الطلبة عبر رحلة تعليمية متكاملة بدءاً من المرحلة الابتدائية حتى نهاية المرحلة الثانوية، وتُسهل عملية انتقالهم إلى مرحلة ما بعد التعليم العام.
 - تزويد الطلبة بالمهارات التقنية والشخصية التي تساعدهم على التعامل مع الحياة، والتجاوب مع متطلبات المرحلة.
 - توسيع الفرص أمام الطلبة الخريجين عبر خيارات متعددة إضافة إلى الجامعات مثل: الحصول على شهادات مهنية، والالتحاق بالكليات التطبيقية، والحصول على دبلومات وظيفية.
- ويكون نظام المسارات من تسعه فصول دراسية تدرس في ثلاثة سنوات، تتضمن سنة أولى مشتركة يتلقى فيها الطلبة الدروس في مجالات علمية وإنسانية متعددة، تليها سنتان تخصصيتان، يُسكن الطلبة بها في مسار عام وأربعة مسارات تخصصية تتسع مع ميولهم وقدراتهم، وهي: المسار الشرعي، مسار إدارة الأعمال، مسار علوم الحاسوب والهندسة، مسار الصحة والحياة، وهو ما يجعل هذا النظام هو الأفضل للطلبة من حيث:
- وجود مواد دراسية جديدة تتوافق مع متطلبات الثورة الصناعية الرابعة والخطط التنموية، ورؤية المملكة 2030، تهدف لتنمية مهارات التفكير العليا وحل المشكلات، والمهارات البحثية.
 - برامج المجال الاختياري التي تتسع مع احتياجات سوق العمل وميول الطلبة، حيث يمكن الطلبة من الالتحاق بمجال اختياري محدد وفق مصفوفة مهارات وظيفية محددة.
 - مقاييس ميول يضمن تحقيق كفاءة الطلبة وفاعليتهم، ويساعدهم في تحديد اتجاهاتهم وميولهم، وكشف مكامن القوة لديهم، مما يعزز من فرص نجاحهم في المستقبل.
 - العمل التطوعي المصمم للطلبة خصيصاً بما يتسع مع فلسفة النشاط في المدارس، ويعد أحد متطلبات التخرج؛ مما يساعد على تعزيز القيم الإنسانية، وبناء المجتمع وتنميته وتماسكه.
 - التجسير الذي يمكن الطلبة من الانتقال من مسار إلى آخر وفق آليات محددة.
 - حصص الإتقان التي يتم من خلالها تطوير المهارات وتحسين المستوى التحصيلي، من خلال تقديم حصص إتقان إثرائية وعلمية.



- خيارات التعليم المدمج، والتعلم عن بعد، والذي يُبني في نظام المسارات على أساس من المرونة، والملاءمة والتفاعل والفعالية.
- مشروع التخرج الذي يساعد الطلبة على دمج الخبرات النظرية مع الممارسات التطبيقية.
- شهادات مهنية ومهارية تمنح للطلبة بعد إنجازهم مهامًّا محددة، واختبارات معينة بالشراكة مع جهات تخصصية.

وبالتالي فإن مسار علوم الحاسوب والهندسة كأحد المسارات المستحدثة في المرحلة الثانوية يسهم في تحقيق أفضل الممارسات عبر الاستثمار في رأس المال البشري، وتحويل الطالب إلى فرد مشارك ومنتج للعلوم والمعارف، مع إكسابه المهارات والخبرات اللازمـة لاستكمال دراسته في تخصصات تتناسب مع ميوله وقدراته أو الالتحاق بسوق العمل.

وتعـد مادة الذكاء الاصطناعـي أحد المواد الرئـيسـة في مـسـار عـلـوم الـحـاسـوب والـهـنـدـسـة، حيث تسـهـم في توضـيـح مـفـاهـيم الذـكـاء الـاـصـطـنـاعـيـ والـقـنـيـاتـ المرـتـبـطةـ بهاـ بماـ يـسـاعـدـ عـلـىـ توـظـيفـ هـذـهـ القـنـيـاتـ فيـ عـدـةـ مـجاـلـاتـ حـيـاتـيـةـ مـثـلـ المـدـنـ الـذـكـيـةـ وـالـعـلـيـمـ وـالـزـرـاعـةـ وـالـطـبـ وـغـيرـهـ مـنـ الـمـجاـلـاتـ الـاـقـتـصـادـيـةـ الـمـتـوـعـةـ. وـتـهـدـيـ المـادـةـ إـلـىـ تـعـرـيـفـ الطـالـبـ بـأـهـمـيـةـ الذـكـاءـ الـاـصـطـنـاعـيـ وـدـورـهـ فيـ الـجـيلـ الـرـابـعـ مـنـ الـصـنـاعـةـ. وـكـذـلـكـ تـرـكـزـ عـلـىـ الـلـبـنـاتـ الـأـسـاسـيـةـ لـتـقـنـيـاتـ الذـكـاءـ الـاـصـطـنـاعـيـ، ثـمـ تـتـعـرـضـ بـشـكـلـ تـقـصـيـلـيـ لـلـتـطـبـيقـاتـ الـمـتـقـدـمـةـ الـتـيـ تـتـعـلـقـ بـالـأـنـظـمـةـ الـقـائـمـةـ عـلـىـ الـقـوـاـدـ وـأـنـظـمـةـ مـعـالـجـةـ الـلـغـاتـ الـطـبـعـيـةـ. كـمـ تـشـتـمـلـ هـذـهـ المـادـةـ عـلـىـ مـشـارـيعـ وـتـمـارـينـ تـطـبـيقـيـةـ لـمـاـ يـتـعـلـمـهـ الطـالـبـ؛ لـحـلـ مـشـاـكـلـ وـاقـعـيـةـ تـحـاـكـيـ مـسـتـوـيـاتـ الـعـرـفـيـةـ، بـتـوجـيهـ وـاـشـرافـ مـنـ الـمـعـلـمـ.

ويـتـمـيزـ كـتـابـ الذـكـاءـ الـاـصـطـنـاعـيـ بـأـسـالـيـبـ حـدـيـثـةـ، تـتوـافـرـ فـيـهـ عـنـاصـرـ الـجـذـبـ وـالـتـشـوـيـقـ، وـالـتـيـ تـجـعـلـ الـطـلـبـ يـقـبـلـونـ عـلـىـ تـعـلـمـهـ وـالـتـفـاعـلـ مـعـهـ، مـنـ خـلـالـ مـاـ يـقـدـمـهـ مـنـ تـدـرـيـبـاتـ وـأـنـشـطـةـ مـتـوـعـةـ، كـمـ يـؤـكـدـ هـذـهـ الـكـتـابـ عـلـىـ جـوـانـبـ مـهـمـةـ فيـ تـعـلـيمـ الذـكـاءـ الـاـصـطـنـاعـيـ وـتـعـلـمـهـ، تـتـمـثـلـ فـيـ:

- التـرـابـطـ الوـثـيقـ بـيـنـ الـمـحـتـوـيـاتـ وـالـمـواقـفـ وـالـمـسـكـلـاتـ الـحـيـاتـيـةـ.
- تـنـوعـ طـرـائقـ عـرـضـ الـمـحـتـوـيـ بـصـورـةـ جـذـابـةـ وـمـشـوـقةـ.
- إـبـرـازـ دـورـ الـمـتـعـلـمـ فـيـ عـمـلـيـاتـ الـتـعـلـيمـ وـالـتـعـلـمـ.
- الـاـهـتمـامـ بـتـرـابـطـ مـحـتـوـيـاتـ هـمـاـ يـجـعـلـ مـنـهـ كـلـاـ مـتـكـامـلـاـ.
- الـاـهـتمـامـ بـتـوـظـيفـ تـقـنـيـاتـ مـنـاسـبـةـ فـيـ الـمـواقـفـ الـمـخـلـفـةـ.
- الـاـهـتمـامـ بـتـوـظـيفـ أـسـالـيـبـ مـتـنـوـعـةـ فـيـ تـقـوـيمـ الـطـلـبـةـ بـمـاـ يـتـنـاسـبـ مـعـ الـفـروـقـ الـفـرـديـةـ بـيـنـهـمـ.

ولـوـاـكـبـةـ الـتـطـوـرـاتـ الـعـالـمـيـةـ فـيـ هـذـهـ الـمـاجـالـ، فـيـانـ كـتـابـ مـادـةـ الذـكـاءـ الـاـصـطـنـاعـيـ سـوـفـ يـوـفـرـ لـلـمـعـلـمـ مـجمـوـعـةـ مـتـكـامـلـةـ مـنـ الـمـوـادـ الـتـعـلـيمـيـةـ مـتـنـوـعـةـ تـرـاعـيـ الـفـروـقـ الـفـرـديـةـ بـيـنـ الـطـلـبـةـ، بـالـإـضـافـةـ إـلـىـ الـبـرـمـجـيـاتـ وـالـمـوـاـقـعـ الـتـعـلـيمـيـةـ، الـتـيـ توـفـرـ لـلـطـلـبـةـ فـرـصـةـ تـوـظـيفـ الـتـقـنـيـاتـ الـحـدـيـثـةـ وـالـتـوـاـصـلـ الـمـبـنيـ عـلـىـ الـمـارـسـةـ؛ مـمـاـ يـؤـكـدـ دـورـهـ فـيـ عـلـيـةـ الـتـعـلـيمـ وـالـتـعـلـمـ.

وـنـحـنـ إـذـ نـقـدـمـ هـذـهـ الـكـتـابـ لـأـعـزـائـنـاـ الـطـلـبـةـ، نـأـمـلـ أـنـ يـسـتـحـوذـ عـلـىـ اـهـتـامـهـمـ، وـيـلـبـيـ مـتـطلـبـاتـهـمـ، وـيـجـعـلـ تـعـلـمـهـمـ لـهـذـهـ الـمـادـةـ أـكـثـرـ مـتـعـةـ وـفـائـدـةـ.

وـالـلـهـ وـلـيـ التـوـفـيقـ



بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



الفهرس

الجزء الثاني

4. التعرف على الصور 196
الدرس الأول
التعلم الموجه لتحليل الصور 197
تمرينات 218
الدرس الثاني
التعلم غير الموجه لتحليل الصور 220
تمرينات 234
الدرس الثالث
توليد البيانات المرئية 236
تمرينات 246
المشروع 248
5. خوارزميات التحسين واتخاذ القرار... 250
الدرس الأول
مشكلة تخصيص الموارد 251
تمرينات 264
الدرس الثاني
مشكلة جدولة الموارد 267
تمرينات 279
الدرس الثالث
مشكلة تحسين المسار 283
تمرينات 294
المشروع 298
6. الذكاء الاصطناعي والمجتمع 300
الدرس الأول
مقدمة في أخلاقيات الذكاء الاصطناعي 301
تمرينات 310
الدرس الثاني
التطبيقات الروبوتية 1 312
تمرينات 326
الدرس الثالث
التطبيقات الروبوتية 2 328
تمرينات 336
المشروع 338

الجزء الأول

1. أساسيات الذكاء الاصطناعي 10
الدرس الأول
مقدمة في الذكاء الاصطناعي 11
تمرينات 21
الدرس الثاني
هياكل البيانات في الذكاء الاصطناعي 23
تمرينات 50
الدرس الثالث
هياكل البيانات غير الخطية 53
تمرينات 63
المشروع 68
2. خوارزميات الذكاء الاصطناعي 70
الدرس الأول
الاستدعاء الذاتي 71
تمرينات 77
الدرس الثاني
خوارزمية البحث بأولوية العمق 79
والبحث بأولوية الاتساع 86
تمرينات 86
الدرس الثالث
اتخاذ القرار القائم على القواعد 89
تمرينات 105
الدرس الرابع
خوارزميات البحث المستنيرة 107
تمرينات 128
المشروع 130
3. معالجة اللغات الطبيعية 132
الدرس الأول
التعلم الموجه 133
تمرينات 152
الدرس الثاني
التعلم غير الموجه 154
تمرينات 170
الدرس الثالث
توليد النص 172
تمرينات 189
المشروع 192

الجزء الأول

الوحدة الأولى
أساسيات الذكاء الاصطناعي

الوحدة الثانية
خوارزميات الذكاء الاصطناعي

الوحدة الثالثة
معالجة اللغات الطبيعية



١. أساسيات الذكاء الاصطناعي

سيتعرف الطالب في هذه الوحدة على تاريخ الذكاء الاصطناعي (Artificial Intelligence - AI) وتطبيقاته. كما سيتعلم المزيد حول هيكل البيانات المتقدمة، مثل الطوابير والمكدسات، والقواعد المترابطة، والمخططات، والأشجار الثنائية، وسيستخدم هذه التراكيب لاحقاً لإنشاء مشاريع الذكاء الاصطناعي.

أهداف التعلم

بنهاية هذه الوحدة سيكون الطالب قادراً على أن:

- > يذكر معالم تاريخ الذكاء الاصطناعي (AI).
- > يعدد أمثلة لتطبيقات الذكاء الاصطناعي (AI).
- > يصف عمليات هيكل بيانات المكدس.
- > يصف عمليات هيكل بيانات الطابور.
- > يحدد الاختلافات بين هيكل بيانات المكدس وهيكل بيانات الطابور.
- > يصف العمليات الرئيسية المطبقة على البيانات في القائمة المترابطة.
- > يشرح استخدام هيكل بيانات الشجرة.
- > يحدد الاختلافات بين هيكل بيانات الشجرة وهيكل بيانات المخطط.
- > يستخدم لغة برمجة البايثون (Python) لاستكشاف هيكل البيانات المعقدة.

الأدوات

- > مفكرة جوبيتر (Jupyter Notebook)

مقدمة في الذكاء الاصطناعي

رابط الدرس الرقمي



www.ien.edu.sa

وكلاء الذكاء الاصطناعي (AI Agents)

وكيـل الذـكـاء الـاـصـطـنـاعـي هو بـرـنـامـج يـعـمل نـيـابـة عنـ المـسـتـخـدـم أوـ النـظـام فيـ إـدـراك بيـئـته، وـصـنـعـ القرـارات، وـاتـخـاذـ الإـجـراءـات وـفـقـاـ لهاـ، وـقـدـ يـكـونـ الوـكـيلـ بـسيـطـاـ أوـ مـعـقـدـاـ، ذاتـيـ التـحـكـمـ أوـ شـبـهـ ذاتـيـ التـحـكـمـ، أوـ يـعـملـ فيـ بـيـئـاتـ مـتـنـوـعةـ، مـثـلـ مـسـتـنـدـةـ إـلـىـ الـوـبـ، أوـ الـمـادـيـةـ، أوـ الـافـتـراضـيـةـ.

الشبـكـاتـ العـصـبـيـةـ (Neural Networks)

الـشـبـكـاتـ العـصـبـيـةـ هيـ نوعـ منـ بـرـنـامـجـ الحـاسـبـ المـصـمـمـةـ لـمـحاـكـاـةـ طـرـيقـةـ عـمـلـ الدـمـاغـ الـبـشـريـ، وـهـيـ مـكـوـنـةـ مـنـ خـلـاـيـاـ وـطـبـقـاتـ عـصـبـيـةـ يـمـكـنـهاـ معـالـجـةـ الـمـلـوـعـاتـ وـنـقـلـهاـ.

ماـ الذـكـاءـ الـاـصـطـنـاعـيـ؟

What is Artificial Intelligence (AI)

الـذـكـاءـ الـاـصـطـنـاعـيـ (AI) هوـ أـحـدـ مـجاـلـاتـ عـلـومـ الـحـاسـبـ الـأـلـيـ الـتـيـ تـعـنىـ بـتـصـمـيمـ وـتـطـبـيقـ بـرـنـامـجـ الـقـادـرـةـ عـلـىـ مـحاـكـاـةـ الـقـدـرـاتـ الـمـعـرـفـيـةـ الـبـشـرـيـةـ. تـظـهـرـ هـذـهـ بـرـنـامـجـ الـخـصـائـصـ الـتـيـ تـصـفـ السـلـوكـ الـبـشـريـ عـادـةـ، مـثـلـ حلـ الـمـشـكـلـاتـ، وـالـتـعـلـمـ، وـصـنـعـ الـقـرـاراتـ، وـالـإـسـتـدـالـلـ، وـالـتـخـطـيطـ، وـاتـخـاذـ الـقـرـاراتـ، إـلـخـ.



شكل 1.1: بعض مجالات الذكاء الاصطناعي

الذكاء الاصطناعي وال مجالات الأخرى AI and Other Fields

يرتبط الذكاء الاصطناعي (AI) ارتباطاً وثيقاً بـ مجالات أخرى تشمل:

الفلسفة (Philosophy): هي أصل العلوم الحديثة، وتُعنى بدراسة المشكلات التي تمثل أُسس الذكاء الاصطناعي، مثل أصل المعرفة وتمثيلها، والاستدلال المستند إلى القواعد والمنطق، والتحليل القائم على الأهداف، والصلة بين المعرفة والتصرف.

الرياضيات (Mathematics): هي جوهر الذكاء الاصطناعي، حيث تقدم له لِبنات البناء الأساسية مثل: المنطق، والحوسبة، ونظرية الاحتمالات.

نظريّة القرارات (Decision Theory): تُعنى بدراسة الخصائص المنطقية والرياضية لعملية صنع القرار، حيث تحلل عملية اتخاذ القرارات في نظام تكون فيه بيئه القرار غير واضحة، وتُطبق الأُطر والأساليب النظرية في هذا المجال باستمرار لحل مشكلات الذكاء الاصطناعي.

علم الأعصاب (Neuroscience): يُعنى بدراسة الجهاز العصبي البشري، وقد توصل علم الأعصاب إلى نتيجة رئيسة عملت كمبدأ إرشادي للذكاء الاصطناعي، وهي أن مجموعة من الخلايا البسيطة يمكن أن تؤدي إلى نتائج مُعقدة مثل: الفكر، والعمل، والوعي. كما أن الشبكات العصبية الاصطناعية تحاكي البنية العصبية الموجودة في الدماغ البشري.

علم النفس المعرفي (Cognitive Psychology): هو أحد فروع علم النفس، ويعنى بدراسة طريقة تفكير البشر. ولطالما كان الفضل في تحقيق الانجازات والتقدم في مجال الذكاء الصناعي راجعاً إلى الاكتشافات التي تم تحقيقها في هذا المجال، والتي ساعدت على توفير الرؤى التي تساعده أجهزة الحاسوب على محاكاة التفكير البشري.

علوم الحاسوب والهندسة (Computer Science and Engineering): تُعدّ علوم الحاسوب والهندسة حجر الأساس لتوفير البرمجيات والأجهزة اللازمة للذكاء الاصطناعي للانتقال من المبادئ النظرية إلى التطبيقات العملية. وقد وَأَكَّبَ التقدم في الذكاء الاصطناعي باستمرار التطورات في أنظمة التشغيل، والبرمجة، واللغات، والسرعة التخزينية، والذاكرة، وقوّة معالجة البيانات.

علم التحكم الآلي (Cybernetics): يُعنى بدراسة الأنظمة التي تحقق الحالة المرجوة باستلام المعلومات من بيئتها وتعديل سلوكها وفقاً لذلك. الفرق الرئيس بين علم التحكم الآلي وبين الذكاء الاصطناعي هو أن الأول يستخدم الرياضيات لنمذجة الأنظمة المغلقة التي يمكن وصفها بالكامل باستخدام متغيرات محددة، بينما يستخدم الذكاء الاصطناعي الاستدلال المنطقي والحوسبة للتغلب على هذه القيود ودراسة المشكلات المعقّدة مثل: فهم اللغة والمعلومات المرئية وتوليدهما.

علم اللغويات (Linguistics): هو الدراسة العلمية لغة البشرية، فلطالما كان فهم اللغة البشرية وتوليدها مجالاً رئيساً في تطبيقات الذكاء الاصطناعي، كما أدى إلى نشوء حقول فرعية مثل: معالجة اللغات الطبيعية (Computational Linguistics) واللغويات الحاسوبية (Natural Language Processing - NLP).

علم الرؤية (Vision Science): هو الدراسة العلمية للإدراك البصري. ويُعدّ تعليم أجهزة الحاسوب كيفية فهم الصور، والرسوم المتحركة، ومقاطع الفيديو وتوليدها أحد أكثر تطبيقات الذكاء الاصطناعي إثارة، وتحديداً في المجالات الفرعية للتعلم العميق ورؤية الحاسوب.

معلومة

استُخدم مصطلح الذكاء الاصطناعي رسمياً للمرة الأولى في عام 1956، مما يجعله أحد أحدث المجالات العلمية نسبياً.

اختبار تورنخ Turing Test

اختبار تورنخ (Turing Test) :
يقيس اختبار تورنخ قدرة الآلة على إظهار سلوك ذكي مكافئ لسلوك الإنسان أو غير قادر للتمييز عنه.

قد يكون اختبار تورنخ هو الطريقة الأكثر شهرة لتعريف الذكاء الاصطناعي، ويعود تاريخ اقتراحه إلى عام 1950، حيث أجرى العالم تورنخ تجربة لمعرفة ما إذا كان الحاسب ذكيًا أم لا.

وأثناء الاختبار، يتوجب على الحاسب أن يجيب عن بعض الأسئلة المكتوبة التي يقدمها **المُوجّه البشري** (Human Respondent). يُعدُّ الاختبار ناجحًا إذا لم يتمكن المُوجّه من معرفة ما إذا كانت الإجابة مكتوبة بواسطة إنسان أم بواسطة الحاسب.

لا جنح إلى الاختبار بنجاح، يجب أن يتمتع الحاسب بالإمكانات الموضحة في الجدول التالي:



شكل 1.2: تمثيل اختبار تورنخ

جدول 1.1: إمكانات الحاسب لا جتياز اختبار تورنخ

1	معالجة اللغات الطبيعية؛ لتمكين الحاسب من فهم الأسئلة والرد عليها.
2	تمثيل المعرفة لتنظيم المعلومات وتخزينها واسترجاعها خلال أداء الاختبار.
3	الاستدلال المؤتمت؛ لاستخدام المعلومات المخزنة للإجابة عن الأسئلة.
4	تعلم الآلة للتكيّف مع هيئات اللغات الجديدة مثل: بناء جمل مختلفة، أو إيجاد مفردات لغوية مختلفة، لم يرها من قبل، أو ليست مخزنة ضمن المعلومات.
5	رؤية الحاسب؛ حتى يتمكن من الاستجابة للإشارات البصرية التي يتلقاها من الموجّه عبر وسائل نقل الصور والفيديو.
6	الروبوتية؛ حتى يتمكّن من استقبال الأشياء التي يتلقاها من الموجّه عبر المنفذ ويعالجها.

تفطّي الإمكانات الموضحة بالأعلى جزءاً كبيراً من مجال الذكاء الاصطناعي الواسع. سنستعرض هذه الإمكانات فيما يلي:

معالجة اللغات الطبيعية (NLP) هو أحد فروع الذكاء الاصطناعي الذي يمنح أجهزة الحاسب القدرة على فهم الإنسان واللغة الطبيعية.

تمثيل المعرفة (Knowledge Representation) في الذكاء الاصطناعي يشير إلى عملية ترميز المعرفة البشرية في شكل مقرؤٍ آلياً لتتمكن الأنظمة المستندة إلى الذكاء الاصطناعي من معالجتها واستخدامها. تأتي هذه المعرفة في صورٍ عدّة تشمل: الحقائق، والقواعد، والمفاهيم، وال العلاقات، والعمليات.

الاستدلال المؤتمت (Automated Reasoning) يُشير إلى قدرة الأنظمة المستندة إلى الذكاء الاصطناعي على استنتاج المعرفة الجديدة وتقديم الاستنتاجات المنطقية وفقاً لمجموعة من القواعد والفرضيات المقدمة.

رؤية الحاسب (Computer Vision) هي مجال الذكاء الاصطناعي الذي يمكن الحاسب من تفسير وفهم المعلومات المرئية من العالم الحقيقي، مثل الصور ومقاطع الفيديو.

الروبوتية (Robotics) هي فرع الذكاء الاصطناعي الذي يعني بتصميم الروبوت، وبنائه، واستخدامه. ويتضمن الجمع بين التقنيات المتعددة مثل: تعلم الآلة، ورؤية الحاسب، وأنظمة التحكم لابتكار آلات ذكية ذاتية التحكم أو تتطلب الحد الأدنى من التوجيه البشري.



الذكاء الاصطناعي: تاريخ ممتد لتسعة عقود

Artificial Intelligence: 9 Decades of History

بالرغم من أن عمر الذكاء الاصطناعي لا يتجاوز 100 عام، إلا أنه يتمتع بتاريخ غني يمتد منذ الأربعينيات من القرن الماضي حتى اليوم. وفيما يلي استعراض للإنجازات البارزة في مجال الذكاء الاصطناعي في كل عقد.

1987-1993: تُعرف هذه الفترة باسم ثاني شتاء للذكاء الاصطناعي. فطبيعة أنظمة الذكاء الاصطناعي في المراحل المبكرة كانت مستندة على القواعد، والتي بدورها قيدت من قابليتها للتطبيق وجعلتها غير قادرة على حل مشاكل الحياة الواقعية الرئيسية.

1997: تحقق الفوز الأول لبرنامج الذكاء الاصطناعي على بطل العالم في الشطرنج، حيث نجح الحاسوب العملاق ديب بلو (Deep Blue) في هزيمة بطل العالم في الشطرنج جاري كاسпарوف (Gary Kasparov).

الألفينيات: فترة الانتشار واسع النطاق، والدعم الكبير للمكونات المادية والبرمجية، وتطورها

2005: طورت جامعة ستانفورد (Stanford University) السيارة ذاتية القيادة ستانلي (STANLEY) التي فازت في تحدي السيارات ذاتية القيادة. كما بدأ الجيش الأمريكي الاستثمار في الروبوتات ذاتية التحكم.

2009: استُخدمت وحدات معالجة الرسومات

(Graphics Processing Units - GPUs) لتدريب الشبكات العصبية للتعلم العميق للمرة الأولى. أدى استخدام المكونات المادية المتخصصة إلى تسارع وتيرة تدريب الشبكات المعقّدة علىمجموعات كبيرة جداً من البيانات، مما أدى بدوره إلى عصرٍ جديد من التعلم العميق والذكاء الاصطناعي.

العقدين الثاني والثالث من القرن الحادي والعشرين: العصر الذهبي

2011: هزم نظام الإجابة على الأسئلة المعروف باسمWatson (Watson) أفضل لاعبين في العالم في برنامج المسابقات الأميركي جيوباردي (Jeopardy)، حيث تمكّنWatson من فهم الأسئلة والإجابة عليها بنجاح، مما شكل طفرة في استخدام الذكاء الاصطناعي لفهم اللغة الطبيعية.

2012: ظهر نظام الذكاء الاصطناعي الذي يترجم فوريًا اللغة الإنجليزية المنطقية إلى اللغة الصينية المنطقية.

2021: ظهر نظام القيادة الذاتية الكامل الذي يستخدم الشبكات العصبية المُدرَّبة على سلوك مئات الآلاف من السائقين.

2022: ظهر روبوت دردشة المُحوّل التوليدى مُسبق التدريب (Generative Pre-trained Transformer - ChatGPT) وهو روبوت الدردشة المبني على مجموعة كبيرة من النماذج اللغوية. هذه النماذج مُهيأة بدقة باستخدام كلٍ من تقنيات التعلم المُوجّه والمُعزّز لمحاكاة المحادثات البشرية.

الأربعينيات: البداية وأول خلية عصبية اصطناعية

1943: أُقترح النموذج الأول المبني على الخلايا العصبية الاصطناعية بحيث يمكن لكل خلية عصبية أن تكون في حالة نشطة (تشغيل) أو غير نشطة (إيقاف) وذلك وفق المحاكاة التي تلقاها من الخلايا العصبية الأخرى المجاورة والمتصلة بها.

1948: في هذا العام ظهر روبوتان: إلمر وإلسie (Elmer and Elsie) وهما روبوتان ذاتياً التحكم، يمكنهما التنقل حول العقبات باستخدام الضوء واللمس.

خمسينيات القرن الماضي: نشأة الذكاء الاصطناعي

1950: ظهر اختبار تورننغ وهو اختبار يحدُّد قدرة الآلة على إظهار سلوك ذكي مكافئ لسلوك الإنسان أو يصعب تمييزه عنه. إلى جانب ظهور العديد من مفاهيم الذكاء الاصطناعي الرئيسية مثل: تعلم الآلة، والخوارزميات الجينية، والتعلم المعزّز.

1951: صُمم حاسب التعزيز التناضري العصبي العشوائي (Stochastic Neural Analog Reinforcement Computer-SNARC) كأول حاسب يعمل بالشبكات العصبية.

1958: طُورت لغة ليسب (Lisp)، وهي لغة برمجة مُصممة خصيصاً للذكاء الاصطناعي. وفي العام نفسه، نُشرت ورقة بحثية حول متلقي المشورة الافتراضي (Hypothetical Advice Taker)، وهو نظام الذكاء الاصطناعي القادر على التعلم من التجربة تماماً مثل البشر.

الستينيات والسبعينيات من القرن الماضي: أول شتاء للذكاء الاصطناعي

1964: ظهر برنامج إليزا (ELIZA) وهو أول برنامج لمعالجة اللغات الطبيعية وهي الأصل الذي تقرّع منه جميع روبوتات الدردشة اليوم.

1974-1980: تُعرف هذه الفترة باسم أول شتاء للذكاء الاصطناعي. حيث انخفض تمويل مشروعات الذكاء الاصطناعي في هذه الفترة نظراً لقلة التقدم المُحرّز في هذا المجال، وانخفاض تأثيره في تطبيقات الحياة اليومية. أحد الانتقادات الرئيسية كانت عدم قدرة تقنيات الذكاء الاصطناعي على معالجة مشكلة الانفجار التوافقي التي جعلت قابلية تطبيقها محدودة على بعض المشكلات ومجموعات البيانات الصغيرة للغاية.


الثمانينيات والتسعينيات من القرن الماضي وثاني شتاء للذكاء الاصطناعي

1980: أُطلق أول نظام خبير تجاري ناجح مُصمم لمحاكاة القدرة على صنع القرار مثل الإنسان.

تطبيقات الذكاء الاصطناعي Applications of AI

الذكاء الاصطناعي هو تكنولوجيا سريعة التطور لديها القدرة على تحويل مجموعة واسعة من القطاعات والصناعات. في هذه الوحدة سنتكلّم عن تطبيقات الذكاء الاصطناعي المختلفة، وكيفية استخدامها في إجراء تحسينات وابتكارات في مجموعة متنوعة من القطاعات والصناعات.

المساعدون الافتراضيون Virtual Assistants



شكل 1.3: المحادثة مع روبوت الدردشة

واحدة من أشهر تطبيقات الذكاء الاصطناعي هي تطبيقات المساعدين الافتراضيين الذين يمكنهم التواصل مع المستخدمين عبر التفاعلات النصية أو الصوتية، ويمكن الوصول إليهم عبر الأجهزة المادية مثل: الهواتف الذكية، والأجهزة اللوحية، أو مكبرات الصوت الذكية، ويمكن استخدامهم لأداء مجموعة واسعة من المهام مثل: إعداد التذكيرات، والإجابة على الأسئلة، وتشغيل الوسائط الصوتية، وطلب المنتجات أو الخدمات. أحد الأمثلة الأكثر شهرة على تطبيقات الذكاء الاصطناعي في هذا المجال هو سيري (Siri) من شركة آبل (Apple). وهناك شركات أخرى طورت مساعدين افتراضيين: مثل أليكسا (Alexa) التابع لشركة أمازون (Amazon)، والمساعد الافتراضي لغوغل (Google's Assistant)، وكورتانا (Cortana) التابع لشركة مايكروسوف特 (Microsoft). وبمرور الوقت تطورت قدرة هذه التطبيقات على الفهم والاستجابة لعدد متزايد من الأوامر والاستفسارات والرد عليها. على سبيل المثال، يمكن استخدام المساعد الافتراضي للتحكم في الأجهزة المنزلية الذكية مثل: التحكم في درجة الحرارة، والإضاءة، والأجهزة الكهربائية. وقد يمثل المساعد الافتراضي في صورة روبوتات الدردشة المتخصصة المصممة عادةً لتقديم المعلومات والإجابة على الأسئلة في مجال محدد، على سبيل المثال، في تطبيقات خدمة العملاء تُستخدم روبوتات الدردشة المبنية على تقنية الذكاء الاصطناعي في الإجابة على أسئلة العملاء حول المنتجات أو الخدمات، وتحديد المشكلات وعلاجها، وتقديم المعلومات حول طلباتهم وحساباتهم. يمكن الوصول إلى روبوتات الدردشة عبر مجموعة واسعة من القنوات مثل: موقع الويب، وتطبيقات المراسلة، ووسائل التواصل الاجتماعي، ويمكنها تقديم خدمات المساعدة على مدار الساعة طوال أيام الأسبوع. يمكنك الاطلاع على مثال لأحد تطبيقات روبوت الدردشة في الشكل 1.3.

الروبوتية Robotics

ارتبط الذكاء الاصطناعي منذ بداياته بالروبوتية، فإذا كان الروبوت هو التصوير المادي للكائن الاصطناعي، فإن الذكاء الاصطناعي يمثل دماغ الروبوت، ويمنحه القدرة على الشعور بالبيئة من حوله، واتخاذ القرارات، والتكيف مع الظروف المتغيرة. كما يمكن للروبوتات الذكية تطبيق هذه الإمكانيات والقدرات لأداء مجموعة واسعة من المهام دون التدخل البشري، مثل: مهام التصنيع، والاستكشاف، والبحث والإنقاذ، والعديد من المهام الأخرى. الشكل 1.4 يوضح خط تجميع روبيتي في مصنع سيارات.



شكل 1.4: خط تجميع روبيتي في مصنع سيارات

إن أحد أقدم الأمثلة على تطبيق الذكاء الاصطناعي في الروبوتية هو تطوير روبوتات المصانع المستخدمة في أداء المهام مثل: اللحام، والدهانات، والتجميع. منذ ذلك الحين، تطور استخدام الذكاء الاصطناعي في الروبوتية إلى حد كبير، مع تطور الخوارزميات المتقدمة واستخدام تعلم الآلة لتحسين أداء الروبوت. وكانت إحدى الإنجازات البارزة في استخدام الذكاء الاصطناعي في الروبوتية تطوير الروبوتات البشرية، مثل: روبوت هوندا آسيمو (Honda's ASIMO) وقد سُمي بذلك اختصاراً لمفهوم الخطوة المتقدمة في النقل الإبداعي (Advanced Step in Innovative Mobility) وقد وُلد في عام 2000 وكان قادرًا على السير وأداء المهام الأساسية.

الروبوتات الشبيهة بالبشر Humanlike Robots

طورت شركة الدبران روبيوكس (Aldebaran Robotics) الروبوتان الشبيهان بالبشر بيبر (Pepper) وناؤ (Nao)، اللذان صُمِّما لأغراض البحث والتطوير في مجال التفاعل بين الإنسان والروبوت، وقد استُخدما على نطاق واسع في مجالات البحث، والتعليم، والترفيه. أمّا بيبر (Pepper) فهو روبوت اجتماعي مُصمَّم للتواصل مع الأشخاص بصورة طبيعية باستخدام كاميرا، وميكروفونات، ومستشعرات اللمس لإدراك البيئة من حوله، والاستجابة لتصرفات وعواطف الأشخاص من حوله. يتمتع هذا الروبوت بالعديد من الخصائص التي تسمح له بالتعرف على الوجه، وفهم الكلام، والاستجابة للإيماءات. الشكل 1.5 يعرض صورة للروبوت بيبر. أمّا ناؤ (Nao) فهو روبوت مُدمج أصغر حجمًا مُصمَّم للتواصل مع البشر، ويحتوي هذا الروبوت مثل السابق على مجموعة من المستشعرات التي تسمح له بإدراك البيئة من حوله، إلى جانب الكاميرات، والميكروفونات للتعرف على الكلام والوجه. ويتميز هذا الروبوت بأنه قابل للتخصيص والبرمجة بدرجة توافقية عالية، مما يجعله الخيار الأمثل للباحثين والدارسين الذين يرغبون في دراسة وتطوير تطبيقات جديدة للروبوتات الشبيهة بالبشر.



شكل 1.5: الروبوت بيبر

في عام 2017 كانت الروبوت صوفيا (Sophia) أول روبوت يحصل على الجنسية السعودية، وفي عام 2023 طورت المملكة العربية السعودية سارة (Sarah)، وهي الروبوت التفاعلي الأول من نوعه.

السيارات ذاتية القيادة Self-Driving Cars

كان الإنجاز المهم الآخر هو تطوير السيارات ذاتية القيادة كما في الشكل 1.6 وهي سيارات تُستخدم الذكاء الاصطناعي للانتقال عبر الطرق واتخاذ القرارات حول كيفية التفاعل الآمن مع المركبات الأخرى ومع المشاة. أحد المتطلبات الرئيسية لهذه التطبيقات هو القدرة على معالجة البيانات المرئية مثل الصور ومقاطع الفيديو وفهمها، ويشار إلى ذلك عادة باسم رؤية الحاسب (Computer Vision)، ويمكن استخدام خوارزميات رؤية الحاسب للتعرف على الكائنات، والأشخاص، والأشياء الأخرى في الصور ومقاطع الفيديو، إلى جانب فهم سياق المحتوى ومعناه. ولهذا المجال العديد من التطبيقات غير الروبوتية مثل: التعرف على الوجه، وإدارة المحتوى، وتحليل الوسائل. وكان أحد الإنجازات البارزة في استخدام الذكاء الاصطناعي في تحليل الصور ومقاطع الفيديو تطوير خوارزميات التعلم العميق، التي يمكنها تحليل كميات كبيرة من البيانات وتحديد الأنماط المُعَدَّدة في الصور ومقاطع الفيديو.



شكل 1.6: سيارة ذاتية القيادة

المجالات التي تأثرت بالذكاء الاصطناعي

التعليم

مزايا الذكاء الاصطناعي في التعليم

AI benefits in education

- يوفر وقت المُعلّمين والأساتذة الجامعيين.
- يمكن لـ AI Tutors (AI Tutors) مساعدة الطلبة.
- يساعد المُعلّم على أن يصبح معلماً محفزاً.
- تقدّم الوظائف المستندة على الذكاء الاصطناعي الملاحظات لكل من الطلبة والمُعلّمين.

على مدى العقود القليلة الماضية، كانت هناك العديد من الإنجازات الرئيسة لاستخدام الذكاء الاصطناعي في التعليم. بما في ذلك تطوير أنظمة التدريس القائمة على الذكاء الاصطناعي التي تستخدم تقنيات معالجة اللغات الطبيعية للتفاعل مع الطلبة وتقديم الملاحظات حول أعمالهم. ثم ظهرت منصّات التعلم التكيفي التي تستخدم خوارزميات تعلم الآلة لشخصيّة التعليمية لكل طالب استناداً إلى نقاط قوته وضعفه. بعدها، طُورت أنظمة التصحيح القائمة على الذكاء الاصطناعي التي تستخدم خوارزميات معالجة اللغات الطبيعية وتعلم الآلة لتصحيح الواجبات المكتوبة وتقديم الملاحظات. وفي الآونة الأخيرة، حدث دمج بين المساعدين الافتراضيين وروبوتات الدردشة في مجال التعليم لتقديم الدعم الشخصي للطلبة والإجابة على أسئلتهم بشكل فوري. يمكن استخدام الذكاء الاصطناعي لتحليل البيانات حول أداء الطلبة، وخياراتهم المفضلة في التعليم، وغيرها من العوامل الأخرى الضرورية لوضع خطط تعليمية مخصصة للطلبة، وتقديم التوصيات بشأن المواد أو الأنشطة التي من المرجح أن تفيدهم بفعالية.

الرعاية الصحية

الرعاية الصحية هي مجال آخر حقّق تقدماً كبيراً بفضل الذكاء الاصطناعي. كانت الابتكارات الأولى في صورة الأنظمة التشخيصية القائمة على الذكاء الاصطناعي واستخدامه في اكتشاف الأدوية. ثم دمجه مع السجلات الصحية الإلكترونية لاستخراج المعلومات ذات الصلة، وفي العقد الثاني من القرن الحادي والعشرين، طُورت أنظمة التطبيقات عن بعد القائمة على الذكاء الاصطناعي. واليوم، يُساعد الذكاء الاصطناعي الحديث في إنشاء خطط علاجية مُخصصة للمريض، واستخدام أجهزة تقنية يرتديها لمتابعة حالة الصحية. ويلعب الذكاء الاصطناعي دوراً كبيراً في مجال الرعاية الصحية، فهو يُمكن الأطباء ومقدمي خدمات الرعاية الصحية الآخرين من تحليل كميات كبيرة من البيانات واتخاذ القرارات حول رعاية المرضى. قد تأتي البيانات من مصادر متعددة مثل: السجلات الطبية، والفحوصات المعملية، وكذلك الصور مثل: الأشعة السينية أو الأشعة المقطعيّة، كما تُستخدم خوارزميات رؤية الحاسوب الحديثة بصورة متكررة للكشف عن التشوهات والمساعدة في التشخيص الطبي.



شكل 1.7: تحليل البيانات الصحية

الزراعة والنمذجة المناخية

يُستخدم الذكاء الاصطناعي في الزراعة لتحسين إنتاج المحاصيل الزراعية ورفع كفاءة الممارسات الزراعية. ويتحقق ذلك بالتحليل المستمر للبيانات حول حالة التربة، وأنماط الطقس، والعوامل الأخرى للتنبؤ بأفضل وقت لزراعة المحاصيل الزراعية وريها وحصادها. كما يُستخدم الذكاء الاصطناعي في مراقبة المحاصيل طوال الوقت وتحديد المشكلات التي قد تصيبها مثل: الآفات أو الأمراض، مما يسمح للمزارعين باتخاذ اللازم قبل أن تؤثر تلك المشكلات على جودة المحاصيل الزراعية، وأحد الأمثلة المبتكرة على تطبيقات الذكاء الاصطناعي في الزراعة هو استخدام خوارزمية صنع القرارات البسيطة لتحسين مواقيت الري. ومن الإنجازات الرئيسية الأخرى استخدام شبكات المستشعرات لمراقبة المحاصيل الزراعية، ومعايرة التطبيقات العلاجية الرئيسية مثل الأسمدة والمبادات. وفي الآونة الأخيرة، استُخدمت الصور الملتقطة بالطائرات المسيرة والأقمار الصناعية لتحليل المحاصيل الزراعية على نطاق واسع، كما في الشكل 1.8 الذي يعرض طائرة مسيرة تُستخدم لتسميد أحد الحقول.



شكل 1.8: التسميد باستخدام الطائرات المسيرة

أما النمذجة المناخية فهي مجال آخر يرتبط ارتباطاً وثيقاً بالزراعة، وقد تأثر كثيراً بالذكاء الاصطناعي الذي بدأ تطبيقاته في هذا المجال في وقت مبكر، مع تطوير أنظمة التنبؤ بالطقس القائمة عليه. لاحقاً، استُخدم الذكاء الاصطناعي لتحليل كميات كبيرة من البيانات حول التغيرات المناخية والتنبؤ بالأمطار المستقبلية، وتأتي هذه البيانات من مصادر متنوعة، بما في ذلك صور الأقمار الصناعية، وملحوظات محطات الطقس، والمحاكاة الحاسوبية. واليوم، يُستخدم الذكاء الاصطناعي في مجموعة واسعة من تطبيقات النمذجة المناخية مثل: التنبؤ بأثار التغيرات المناخية على مناطق محددة، وتحليل وفهم أسباب الظواهر الجوية المتطرفة وفهمها، ووضع الاستراتيجيات الفعالة للتخفيف من التغيرات المناخية أو التكيف معها.

الطاقة Energy

أثر الذكاء الاصطناعي كثيراً على مجال الطاقة، وذلك عن طريق تمكين الشركات من ترشيد استخدامها وتقليل الهدر، وتحسين الكفاءة. أحد الأمثلة على ذلك استخدام خوارزميات تعلم الآلة لتحليل البيانات حول استخدامات الطاقة وتحديد طرائق تقليل الهدر وترشيد الاستهلاك. في التسعينيات من القرن الماضي، استُخدم الذكاء الاصطناعي للتنبؤ بموارد الطاقة المتجددة وتحسين استخدامها. وكان تطوراً رئيساً ممكّناً شركات الطاقة من التخطيط بصورة أفضل لدمج موارد الطاقة المتجددة في عملياتها.




شكل 1.9: الطاقة الكهربائية النظيفة من الألواح الكهروضوئية الشمسية

شهد العقد الأول من القرن الحادي والعشرين دمج الذكاء الاصطناعي في الشبكات الذكية، التي تستخدم خوارزميات تعلم الآلة في تحليل البيانات حول استخدام الطاقة وضبط العرض والطلب طوال الوقت، حيث ساهم ذلك في تحسين كفاءة توزيع الطاقة والحد من الهدر، وفي العقد الثاني من القرن الحادي والعشرين، استُخدم الذكاء الاصطناعي لتطوير أنظمة تخزين الطاقة التي يمكنها تخزين الطاقة الزائدة واستخدامها عند الحاجة. وكان تطوراً رئيساً ممكّناً شركات الطاقة من إدارة الاستخدام المتقطّع بشكل أفضل لموارد الطاقة المتجددة مثل: الطاقة الشمسية وطاقة الرياح. يعرض الشكل 1.9 الألواح الكهروضوئية الشمسية، وفي السنوات الأخيرة، استُخدم الذكاء الاصطناعي لزيادة كفاءة استخدام الطاقة بتحليل البيانات حول استخدام الطاقة وتحديد طرائق الحد من الهدر، وشمل ذلك تطوير الأنظمة المستندة على الذكاء الاصطناعي التي تُستخدم في تحسين استخدام الطاقة في المباني، والمصانع، ومن قبل كبار مستهلكي الطاقة. كما استُخدم الذكاء الاصطناعي في صناعة النفط والغاز لتحليل البيانات حول الحفر والإنتاج وتحسين العمليات.

تطبيق القانون Law Enforcement

يُستخدم الذكاء الاصطناعي بكثافة في مجال تطبيق القانون للتنبؤ بالجرائم والحيولة دون وقوعها. وعلى وجه التحديد، يُستخدم الذكاء الاصطناعي لتحليل البيانات من مصادر مختلفة، مثل: سجلات الجرائم، ووسائل التواصل الاجتماعي، وكاميرات المراقبة لتحديد أنماط وتوجهات الأنشطة الإجرامية والتنبؤ بها. على سبيل المثال طُور الذكاء الاصطناعي في التعرف على الوجوه (شكل 1.10). ولاحقاً، دُمج في أنظمة إرسال قوات الشرطة واستُخدم لمراقبة منصات وسائل التواصل الاجتماعي بحثاً عن التهديدات المحتملة. وفي الآونة الأخيرة، استُخدم الذكاء الاصطناعي لتطوير طائرات مُسيرة لمراقبة وتحليل تسجيلات الفيديو من الكاميرات التي يرتديها ضباط تطبيق القانون. كما لعب الذكاء الاصطناعي دوراً كبيراً في تمكين الجهات المسؤولة من تحليل كميات كبيرة من البيانات، وتحديد الأنماط والتوجهات، واتخاذ القرارات المستنيرة حول كيفية منع الجريمة والتصدي لها.



شكل 1.10: تقنيات التعرف على الوجه وتحديد الهوية الشخصية

تمرينات

1

خاطئة	صحيحة	حدد الجملة الصحيحة والجملة الخاطئة فيما يلي:
<input type="radio"/>	<input checked="" type="radio"/>	1. وضع علماء الرياضيات الأسس لفهم الحوسبة والمنطق حول الخوارزميات.
<input type="radio"/>	<input checked="" type="radio"/>	2. يُحدد اختبار تورننغ ما إذا كان الحاسب يتمتع بسلوك شبيه بالإنسان أم لا.
<input type="radio"/>	<input checked="" type="radio"/>	3. كان إلمر (Elmer) وإلسي (Elsie) أول روبوتين يتقاضان حول العقبات باستخدام الضوء واللمس.
<input type="radio"/>	<input checked="" type="radio"/>	4. استُخدم الذكاء الاصطناعي فقط في الروبوتات المستخدمة في الصناعات التحويلية.
<input type="radio"/>	<input checked="" type="radio"/>	5. لم يكن للذكاء الاصطناعي أي تأثير يُذكر في مجال الطاقة.

ما الذكاء الاصطناعي (AI)؟ 2

اشرح بإيجاز بعض تطبيقات الذكاء الاصطناعي المستخدمة في الحياة اليومية. 3

4

وضح بعض الأحداث التاريخية الرئيسة التي أثرت في تطور الذكاء الاصطناعي في الأربعينيات والخمسينيات من القرن الماضي.

5

اشرح كيف استُخدمت التطبيقات التجارية تقنيات الذكاء الاصطناعي للمرة الأولى في العقد الثاني من القرن الحادي والعشرين.

6

لخص كيفية استخدام تطبيقات الذكاء الاصطناعي في التصدي للتغيرات المناخ عبر النمذجة المناخية والتحسينات في مجال الطاقة.

هيكل البيانات في الذكاء الاصطناعي

رابط الدرس الرقمي



www.ien.edu.sa

أهمية هيكل البيانات في الذكاء الاصطناعي

The Importance of Data Structures in AI

هيكل البيانات (Data Structure)

هيكل البيانات هي تقنية لتخزين وتنظيم البيانات في الذاكرة لاستخدامها بكفاءة.


للبيانات أهمية كبرى في مجالات الذكاء الاصطناعي؛ لأنها الأساس المستخدم في تدريب نماذج تعلم الآلة، حيث تُحدّد جودة البيانات وكميتها المتاحة دقة وفعالية نماذج الذكاء الاصطناعي. ودون بيانات كافية وذات صلة، لن تتعلم خوارزميات الذكاء الاصطناعي الأنماط، ولن تقوم بالتنبؤات، ولن تتمكن من أداء المهام بفاعلية. وبالتالي، تلعب البيانات دوراً رئيساً في تشكيل قدرات وامكانيات صنع القرار لدى أنظمة الذكاء الاصطناعي. هيكل البيانات لها أهمية كبيرة في الذكاء الاصطناعي؛ لأنها توفر طريقة فعالة لتنظيم وتخزين البيانات، كما تسمح باسترجاع ومعالجة البيانات بكفاءة. وكذلك، تُحدّد مدى تعقيد وكفاءة الخوارزميات المستخدمة في معالجة البيانات، وبالتالي تؤثر مباشرة على أداء أنظمة الذكاء الاصطناعي. على سبيل المثال، يمكن تحسين سرعة وقابلية خوارزميات الذكاء الاصطناعي للتتوسيع باستخدام هيكل البيانات المناسبة، مما يجعلها أكثر ملائمة للتطبيقات في العالم الحقيقي. وكذلك، تساعد هيكل البيانات المصممة جيداً في تقليل استخدام الذاكرة وزيادة كفاءة الخوارزميات، لتمكينها من معالجة مجموعات أكبر من البيانات. تخزنُ أجهزة الحاسوب البيانات وتعالجها بسرعة ودقة فائقتين. لذلك، من الضروري تخزين البيانات بكفاءة، وتوفير الوصول إليها بطريقة سريعة. يمكن تصنيف هيكل البيانات على النحو التالي:

يُطلق على البيانات البسيطة كذلك
البيانات الأولية، أو الخام، أو الأساسية.

- هيكل البيانات الأولية.

- هيكل البيانات غير الأولية.

يوضح المخطط في الشكل 1.11 تصنيف هيكل البيانات.



شكل 1.11: مخطط هيكل البيانات

هياكل البيانات الأولية Primitive Data Structures

يُشار إلى هياكل البيانات الأولية باسم هياكل البيانات الأساسية في لغة البايثون، ويحتوي هذا النوع من الهياكل على قيم بسيطة للبيانات. تُخبر أنواع البيانات البسيطة المترجم بنوع البيانات التي يُخزنها. هياكل البيانات الأولية في لغة البايثون هي:

تُستخدم أنواع مختلفة من هياكل البيانات لتطبيقات الحاسب ومهامه المختلفة بناءً على ما يتطلبه المشروع والقيود المفروضة على الذاكرة.

- الأرقام (Numbers): تُستخدم الأرقام لتمثيل البيانات الرقمية وهي:

- الأعداد الصحيحة

- الأرقام العشرية


- السلاسل النصية (Strings): السلاسل النصية هي مجموعات من الأحرف والكلمات.

- البيانات المنطقية (Boolean): تكون قيم البيانات المنطقية إما صحيحة أو خاطئة.

هياكل البيانات غير الأولية Non-Primitive Data Structures

هياكل البيانات غير الأولية هي هياكل متخصصة تخزن مجموعة من القيم. يكتبها المبرمج ولا تُعرف بلغة البايثون مثل هياكل البيانات الأولية.

يمكن تقسيم هياكل البيانات غير الأولية كذلك إلى نوعين:



شكل 1.12: كومة من الكتب كمثال واقعي على المكّدس

- هياكل البيانات الخطية أو المتسلسلة (Linear or Sequential Data Structures): تخزن هياكل البيانات الخطية عناصر البيانات في تسلسل معين.

- هياكل البيانات غير الخطية (Non-linear Data Structures): لا تحتوي هياكل البيانات غير الخطية على ارتباط تسلسلي بين عناصر البيانات، ويمكن ربط أي زوج أو مجموعة من عناصر البيانات معًا، والوصول إليها دون تسلسل مُحدد.

هياكل البيانات الخطية Linear Data Structures

تخزن هياكل البيانات الخطية عناصر البيانات في تسلسل معين. في هذا الدرس ستتعلم بعض هياكل البيانات الخطية مثل: المكّدس (Stack) والطابور (Queue)، وهما نوعان من هياكل البيانات الأكثر استخدامًا في الحياة اليومية.

المكّدس Stack

يمكن تمثيل المكّدس في الواقع بمجموعة من الكتب رُصّت فوق بعضها البعض، كما هو موضح في الشكل 1.12. فلإنشاء تلك المجموعة، عليك أن تضع الكتب فوقها البعض، وعندما تريد استخدام أحد الكتب، عليك أخذ الكتاب من أعلى المجموعة. وللوصول إلى الكتب الأخرى عليك إنزال الكتب من أعلى المجموعة.

قاعدة المُضاف آخرًا يخرج أولاً
Last In First Out (LIFO) Rule):
آخر عنصر مُضاف يمكن الوصول إليه أولاً.

قد يكون حجم المكّدس ثابتًا أو متغيرًا ديناميكيًا.
تطبق لغة البايثون المكّدّسات باستخدام القوائم.

العمليات في المُكَدَّس Operations on the stack

هناك عمليتان رئيستان في المُكَدَّس:


- إضافة عنصر (Push): تُستخدم العملية لإضافة عنصر في قمة المُكَدَّس.
- حذف عنصر (Pop): تُستخدم العملية لحذف عنصر من قمة المُكَدَّس.

عملية إضافة عنصر Push operation

يُطلق على عملية إضافة عنصر جديد إلى المُكَدَّس اسم إضافة عنصر (Push).

يُستخدم المُكَدَّس مؤشراً يُطلق عليه مؤشر الأعلى (Top)، ويُشير إلى العنصر الموجود في قمة المُكَدَّس، وعند إضافة عنصر جديد إلى المُكَدَّس:

- تزداد قيمة مؤشر الأعلى بقيمة واحدة لإظهار الموقع الجديد الذي سيُضاف العنصر فيه.
- يُضاف العنصر الجديد إلى قمة المُكَدَّس.



شكل 1.13: عملية إضافة عنصر إلى المُكَدَّس

فيض المُكَدَّس Stack Overflow


يتميز المُكَدَّس بسعة تخزينية مُحددة تعتمد على ذاكرة الحاسب. إذا كانت الذاكرة ممتلئة، فإن إضافة عنصر جديد سينتج عنها مشكلة فيض المُكَدَّس (Stack Overflow). ويقصد بها تجاوز السعة؛ لذا يجب التحقق من امتلاء ذاكرة المُكَدَّس قبل إضافة أي عنصر جديد.

عملية حذف عنصر Pop operation

يُطلق على عملية حذف عنصر من المُكَدَّس اسم حذف عنصر (Pop).

عند حذف عنصر من المُكَدَّس:

- يُحذف العنصر من قمة المُكَدَّس.
- تنخفض قيمة مؤشر الأعلى بقيمة واحد لإظهار العنصر التالي عند قمة المُكَدَّس.



شكل 1.14: عملية حذف عنصر من المُكَدَّس

غَيْض المُكَدَّس Stack Underflow

إذا كنت ترغب في حذف عنصر من المُكَدَّس، عليك التَّتحقق أولاً من أن المُكَدَّس يحتوي على عنصر واحد على الأقل؛ فإذا كان المُكَدَّس فارغاً، سينتج عن ذلك مشكلة غَيْض المُكَدَّس (Stack Underflow) ويقصد بها الانخفاض عن الحد الأدنى للسعة.

المُكَدَّس في لغة البايثون Stack in Python

تُمثّل المُكَدَّسات في لغة البايثون باستخدام القوائم التي يُمكن تطبيقها مباشرةً على المُكَدَّسات.


جدول 1.2: طرائق المُكَدَّس

الوصف	الطريقة
إضافة العنصر x إلى نهاية القائمة.	<code>listName.append(x)</code>
حذف العنصر الأخير من القائمة.	<code>listName.pop()</code>

تطبّق عملية إضافة عنصر
لمُكَدَّس في لغة البايثون
باستخدام دالة `.append`.

ستشاهد مثلاً على تطبيق المُكَدَّس في لغة البايثون:

- 1 أنشئ المُكَدَّس لتخزين مجموعة من الأرقام (1, 21, 32, 45).
- 2 استخدم عملية حذف عنصر (Pop) من المُكَدَّس مرتين لحذف العنصرين الأخيرين (32, 45) من المُكَدَّس.
- 3 استخدم عملية إضافة عنصر (Push) إلى المُكَدَّس لإضافة عنصر جديد (78) إلى المُكَدَّس.



شكل 1.15: مثال على المُكَدَّس



jupyter ANACONDA.



مفكرة جوبيتور


في هذه الوحدة ستكتب ببرنامجاً بلغة البايثون باستخدام مفكرة جوبيتور (Jupyter Notebook). وهي تطبيق الويب المستخدم لإنشاء المستندات الحاسوبية ومشاركتها. كل مستند يُسمى مفكرة، ويحتوي على المقطع البرمجي الذي كتبه، والتعليقات، والبيانات الأولية والمُعالجة، وتصورات البيانات. ستستخدم الإصدار غير المتصل بالإنترنت (Offline) من مفكرة جوبيتور، وأسهل طريقة لتنسيقه محلياً هي من خلال أناكوندا (Anaconda) وهي منصة توزيع مفتوحة المصدر للطلبة والهواة، ويمكنك تزييلها وتنسيقها من الرابط التالي:

<https://www.anaconda.com/products/distribution>

وسيتم تنسيق لغة البايثون ومفكرة جوبيتور تلقائياً.

فتح مفكرة جوبيتور (Jupyter Notebook)

- < اضغط على Start (بدء)، ① ثم اضغط على Anaconda3 (أناكوندا3).
- < اختر Jupyter Notebook (مفكرة جوبيتور). ③
- < ستظهر الصفحة الرئيسية لمفكرة جوبيتور في المتصفح.




شكل 1.16: الصفحة الرئيسية لمفكرة جوبيتور

لإنشاء مفكرة جupyter جديدة:

< في الزاوية اليمنى العلوية من شاشتك، اضغط على New (جديد). ①

< حدد Python 3 (ipykernel) (بايثون 3). ②

< سيتم فتح المفكرة الخاصة بك في علامة تبويب جديدة في المتصفح الخاص بك. ③




شكل 1.17: إنشاء مفكرة جوبير جديدة



الآن وبعد أن أصبحت مفkerتك جاهزة، حان الوقت لكتابة برنامجك الأول وتشغيله فيها.

يمكنك الحصول على العديد من الخلايا المختلفة التي تحتاجها في نفس المفكرة حيث تحتوي كل خلية على مقطعها البرمجي الخاص.




شكل 1.18: إنشاء برنامج في مفكرة جوبيتر

يمكنك تشغيل برنامجك بالضغط على Enter + Shift

حان الوقت لحفظ مفkerتك.

لحفظ المفكرة الخاصة بك:



شكل 1.19: حفظ المفكرة الخاصة بك

لتشاهد المثال في الشكل 1.15 في مفكرة جوبيتر:

1. أنشئ المُكَدَّس لتخزين مجموعة من الأرقام (1, 21, 32, 45).

2. استخدم عملية حذف عنصر (Pop) من المُكَدَّس مرتين لحذف العنصرين الآخرين منه.

3. استخدم عملية إضافة عنصر (Push) إلى المُكَدَّس لإضافة عنصر جديد إليه.

```
myStack=[1,21,32,45]
print("Initial stack: ", myStack)
print(myStack.pop())
print(myStack.pop())
print("The new stack after pop: ", myStack)
myStack.append(78)
print("The new stack after push: ", myStack)
```

تُستخدم الدالة print(myStack.pop()) لعرض القيم المسترجعة من دالة myStack.pop().

```
Initial stack: [1, 21, 32, 45]
45
32
The new stack after pop: [1, 21]
The new stack after push: [1, 21, 78]
```

```
myStack=[1,21,32,45]
print("Initial stack:", myStack)
a=len(myStack)
print("size of stack",a)
#empty the stack
for i in range(a):
    myStack.pop()
print(myStack)
myStack.pop()
```

تُستخدم الدالة len لعرض طول المُكَدَّس.

يُستخدم هذا الأمر لحذف كل العناصر من المُكَدَّس.

```
Initial stack: [1, 21, 32, 45]
size of stack 4
[]
-----
IndexError
Input In [3], in <cell line: 9>()
    7     myStack.pop()
    8 print(myStack)
----> 9 myStack.pop()
-----
```

Traceback (most recent call last)

IndexError: pop from empty list

يظهر الخطأ لأن المُكَدَّس فارغ وأنت كتبت أمر حذف عنصر منه.

خطأ الفهرس IndexError

ستلاحظ ظهور خطأ عندما كتبت أمر حذف عنصر من المُكَدَّس الفارغ وتسبب هذا في غيْض المُكَدَّس (Stack Underflow). عليك دوماً التحقق من وجود عناصر في المُكَدَّس قبل محاولة حذف عنصر منه.

في البرنامج التالي ستنشئ مُكَدِّسًا جديداً وتضيف العناصر إليه، أو تزحفها منه، سيظهر بالبرنامج قائمة تطلب منك تحديد الإجراء الذي تود القيام به في كل مرة.

- لإضافة عنصر إلى المُكَدِّس، اضغط على الرقم 1 من قائمة البرنامج.
- لحذف عنصر من المُكَدِّس، اضغط على الرقم 2 من قائمة البرنامج.
- للخروج من البرنامج، اضغط على الرقم 3 من قائمة البرنامج.

```
def push(stack,element):
    stack.append(element)
def pop(stack):
    return stack.pop()
def isEmpty(stack):
    return len(stack)==0
def createStack():
    return []

newStack=createStack()
while True:
    print("The stack so far is:",newStack)
    print("-----")
    print("Choose 1 for push")
    print("Choose 2 for pop")
    print("Choose 3 for end")
    print("-----")
    choice=int(input("Enter your choice: "))
    while choice!=1 and choice!=2 and choice!=3:
        print ("Error")
        choice=int(input("Enter your choice: "))
    if choice==1:
        x=int(input("Enter element for push: "))
        push(newStack,x)
    elif choice==2:
        if not isEmpty(newStack):
            print("The pop element is:",pop(newStack))
        else:
            print("The stack is empty")
    else:
        print("End of program")
        break;
```

```
The stack so far is: []
```

```
-----  
Choose 1 for push
```

```
Choose 2 for pop
```

```
Choose 3 for end
```

```
-----  
Enter your choice: 1
```

```
Enter element for push: 26
```

```
The stack so far is: [26]
```

```
-----  
Choose 1 for push
```

```
Choose 2 for pop
```

```
Choose 3 for end
```

```
-----  
Enter your choice: 1
```

```
Enter element for push: 18
```

```
The stack so far is: [26, 18]
```

```
-----  
Choose 1 for push
```

```
Choose 2 for pop
```

```
Choose 3 for end
```

```
-----  
Enter your choice: 1
```

```
Enter element for push: 23
```

```
The stack so far is: [26, 18, 23]
```

```
Choose 1 for push
```

```
Choose 2 for pop
```

```
Choose 3 for end
```

```
-----  
Enter your choice: 2
```

```
The pop element is: 23
```

```
The stack so far is: [26, 18]
```

```
-----  
Choose 1 for push
```

```
Choose 2 for pop
```

```
Choose 3 for end
```

```
-----  
Enter your choice: 2
```

```
The pop element is: 18
```

```
The stack so far is: [26]
```

```
-----  
Choose 1 for push
```

```
Choose 2 for pop
```


```
Choose 3 for end
```

```
-----  
Enter your choice: 3
```

```
End of program
```


نُفذ البرنامج السابق كما يلي:

- أنشئ مُكَدّساً من ثلاثة أرقام.
- أضف العناصر إلى المُكَدّس.



شكل 1.20: إضافة العناصر

يمكنك الآن حذف عناصر من المُكَدّس، ثم الخروج من البرنامج.



شكل 1.21: حذف العناصر

قاعدة المُضاف أولاً يخرج أولًا
(First In First Out - FIFO Rule)
 العنصر الأول المُضاف إلى القائمة يُعالج أولاً، والعنصر الأحدث يُعالج آخرًا.

الفرق بين المكَّدس والطابور هو أنه في المكَّدس تتم إضافة وحذف العنصر من نفس الجانب، وفي الطابور تتم الإضافة من جانب، بينما يتم الحذف من الجانب الآخر. وهكذا، عند الحذف في المكَّدس، يُحذف العنصر المُضاف آخرًا، بينما في الطابور، يُحذف العنصر المُضاف أولاً.

هيكل البيانات التالي الذي سنستعرضه هو الطابور. تصادف عادةً طوابير في حياتك اليومية. الطابور الأكثر شيوعاً هو طابور انتظار السيارات عند إشارة المرور. عندما تتحول إشارة المرور إلى اللون الأخضر، ستكون السيارة التي دخلت إلى الطابور أولاً هي نفسها التي تخرج منه أولاً. الطابور هو هيكل البيانات الذي يتبع قاعدة المُضاف أولاً يخرج أولًا (First In First Out - FIFO)، مما يعني أن كل عنصر في الطابور يُقدم بالترتيب نفسه الذي وصل به إلى الطابور.



المؤشر (Pointer)

المؤشر هو مُتغير يُخزن أو يُشير إلى عنوان مُتغير آخر. المؤشر يشبه رقم الصفحة في فهرس الكتاب الذي يُسهّل على القارئ الوصول إلى المحتوى المطلوب.

الفهرس (Index)

الفهرس هو رقم يُحدد موضع العنصر في هيكل البيانات.

العمليات في الطابور Operations on the Queue

هناك عمليتان رئستان في الطابور:

- إضافة عنصر للطابور (Enqueue): تُستخدم العملية لإضافة عنصر في آخر الطابور.
- حذف عنصر من الطابور (Dequeue): تُستخدم العملية لحذف عنصر من مقدمة الطابور.

مؤشرات الطابور Queue Pointers

يحتوي الطابور على مؤشرين:

- المؤشر الأمامي (Front Pointer): يُشير إلى العنصر الأول في الطابور.
- المؤشر الأخير (Rear Pointer): يُشير إلى العنصر الأخير في الطابور.




شكل 1.22: العمليات في الطابور

عملية إضافة عنصر للطابور Enqueue Operation

لا يمكنك إضافة عنصر أو حذفه من وسط الطابور.

يُطلق على عملية إضافة عنصر جديد إلى الطابور اسم إضافة عنصر للطابور (Enqueue). لإضافة عنصر جديد إلى الطابور:

- تم زيادة قيمة المؤشر الخلفي بقيمة واحد بحيث يشير إلى موضع العنصر الجديد الذي سيضاف.
- تم إضافة العنصر.




شكل 1.23: عملية إضافة عنصر للطابور

عملية حذف عنصر من الطابور Dequeue Operation

قبل أي إجراء عليك التتحقق مما إذا كانت هناك مساحة فارغة في الطابور لإضافة عنصر جديد، أو توافر عنصر واحد على الأقل لتصديره.

يُطلق على عملية حذف عنصر من الطابور اسم حذف عنصر من الطابور (Dequeue). لحذف عنصر من الطابور:

- يُحذف العنصر المشار إليه بالمؤشر الأمامي.
- تم زيادة قيمة المؤشر الأمامي بقيمة واحد بحيث يشير إلى العنصر الجديد التالي في الطابور.



شكل 1.24: عملية حذف عنصر من الطابور

الطابور في لغة البايثون Queue in Python

يمكن تمثيل الطابور بعدة طرائق متعددة في لغة البايثون منها القوائم (Lists). ويرجع ذلك إلى حقيقة أن القائمة تمثل مجموعة من العناصر الخطية، كما يمكن إضافة عنصر في نهاية القائمة وحذف عنصر من بداية القائمة. ستعلم فيما يلي الصيغ العامة لبعض العمليات التي يمكن تفزيذها على الطابور:

جدول 1.3: طرائق الطابور

الوصف	الطريقة
تضيف العنصر x إلى القائمة التي تمثل الطابور.	<code>listName.append(x)</code>
تحذف العنصر الأول من القائمة.	<code>listName.pop(0)</code>


تُستخدم طريقة `listName.pop()` لكل من هياكل بيانات المكّدس والطابور. عندما تُستخدم مع المكّدس، لا تتطلب الطريقة أي مُعامل. بينما تتطلب الطريقة إضافة صفر إلى المُعامل عندما تُستخدم مع الطابور: `listName.pop(0)`. الفرق بين الدالتين مُوضح في الجدول 1.4 أدناه.

جدول 1.4: طريقة `listName.pop()` مقابل طريقة `listName.pop(0)`

الوصف	الطريقة
إذا كان مُعامل الدالة فارغاً، يُحذف العنصر الأخير من نهاية القائمة التي تمثل المكّدس.	<code>listName.pop()</code>
إذا كان مُعامل الدالة صفرًا، يُحذف العنصر الأول من القائمة التي تمثل الطابور.	<code>listName.pop(0)</code>

سنستعرض لك مثلاً على تطبيق الطابور في لغة البايثون:

- أنشئ طابوراً لتخزين مجموعة من الأرقام (1, 21, 32, 45).
- استخدم عملية حذف عنصر من الطابور مرتين لحذف العنصرين الأولين منه.
- استخدم عملية إضافة عنصر إلى الطابور لإضافة عنصر جديد إليه.



لبرمجة الخطوات الموضحة بالأعلى بلغة البايثون، سَتُستخدِّم قائمة البايثون لتنفيذ هيكل الطابور، كما فعلت في المكّدس.

```
myQueue=[1,21,32,45]
print("Initial queue: ", myQueue)
myQueue.pop(0)
myQueue.pop(0)
print("The new queue after pop: ", myQueue)
myQueue.append(78)
print("The new queue after push: ", myQueue)
```

```
Initial queue: [1, 21, 32, 45]
The new queue after pop: [32, 45]
The new queue after push: [32, 45, 78]
```

لكي تشاهد ما قد يحدث عندما تحاول حذف عنصر من طابور فارغ، عليك أولاً أن تُقرِّع الطابور من العناصر.

```
myQueue=[1,21,32,45]
print("Initial queue: ", myQueue)
a=len(myQueue)
print("size of queue ",a)
#empty the queue
for i in range(a):
    myQueue.pop(0)
print(myQueue)
myQueue.pop(0)
```

```
Initial queue: [1, 21, 32, 45]
size of queue 4
[]

-----
IndexError Traceback (most recent call last)
Input In [6], in <cell line: 9>()
      7     myQueue.pop()
      8 print(myQueue)
----> 9 myQueue.pop()

IndexError: pop from empty list
```

عليك أن تتحقق دوماً من وجود عناصر في
الطابور قبل محاولة حذف عنصر منه.

ظهر الخطأ: لأنك حاولت
حذف عنصر من طابور فارغ.

تطبيقات على الطابور Queue Applications

أحد الأمثلة على تطبيقات الطابور في علوم الحاسوب هو طابور الطباعة. على سبيل المثال، لديك معمل حاسب به 30 جهاز حاسب متصلين بطاقة واحدة. عندما يرغب الطلبة في طباعة المستندات، ستتشكل مهام الطباعة طابوراً لمعالجتها وفق قاعدة المضاف أولاً يخرج أولاً (FIFO)، أي أن تلك المهام ستُتجزء بالترتيب الزمني الذي أرسلت به إلى الطابعة. المهمة المرسلة أولاً ستُطبع قبل المهمة المرسلة بعدها ولن تُطبع المهمة في نهاية الطابور قبل طباعة كل المهام التي قبلها. عندما تنتهي الطابعة من أحد الأوامر، ستبحث في الطابور لمعرفة ما إن كانت هناك أوامر أخرى لمعالجتها.

المكّدس والطابور باستخدام وحدة الطابور النمطية Stack and Queue Using Queue Module

يمكن اعتبار القائمة في لغة البايثون بمثابة طابور وكذلك مكّدس. تُقدم لغة البايثون الوحدة النمطية للطابور (Queue Module) وهي طريقة أخرى لتنفيذ هيكل البيانات الموضعين. تتضمن الوحدة النمطية للطابور بعض الدوال الجاهزة للاستخدام التي يمكن تطبيقها على كل من المكّدس والطابور.

جدول 1.5: طرائق الوحدة النمطية للطابور

الوصف	الطريقة
تُنشئ طابوراً جديداً اسمه <code>.queueName</code> .	<code>queueName=queue.Queue()</code>
تضيف العنصر <code>x</code> إلى الطابور.	<code>queueName.put(x)</code>
تعود بقيمة حجم الطابور.	<code>queueName.qsize()</code>
تعرض وتحذف العنصر الأول من الطابور والعنصر الأخير من المكّدس.	<code>queueName.get()</code>
تعود بقيمة <code>True</code> (صحيح) إن كان الطابور ممتلئاً، وقيمة <code>False</code> (خطأ) إن كان الطابور فارغاً، ويمكن تطبيقها على المكّدس كذلك.	<code>queueName.full()</code>
تعود بقيمة <code>True</code> (صحيح) إن كان الطابور فارغاً والقيمة <code>False</code> (خطأ) إن كان الطابور ممتلئاً، ويمكن تطبيقها على المكّدس كذلك.	<code>queueName.empty()</code>

```
from queue import *
myQueue = Queue()
# add the elements in the queue
myQueue.put("a")
myQueue.put("b")
myQueue.put("c")
myQueue.put("d")
myQueue.put("e")
# print the elements of the queue
for element in list(myQueue.queue):
    print(element)
```

a
b
c
d
e

تُستخدم طرائق الوحدة النمطية للطابور مع كلِّ من المكّدس والطابور.

ستُستخدم وحدة الطابور النمطية لإنشاء طابور.

في هذا المثال عليك:

- استيراد الوحدة النمطية للطابور (`Queue`) لاستخدام طرائق الطابور.
- إنشاء طابور فارغ باسم `myQueue` (طابوري).
- إضافة العناصر `a`, `b`, `c`, `d`, `e` إلى الطابور `myQueue` (طابوري).
- طباعة عناصر الطابور.

عليك استيراد الوحدة النمطية للطابور في بداية المقطع البرمجي.

أنشئ طابوراً مكوناً من خمس قيم يقوم المستخدم بإدخالها أثنتاء تنفيذ البرنامج، ثم اطبع هذه القيم، وفي النهاية اطبع حجم الطابور.

```
from queue import *
myQueue = Queue()
# the user enters the elements of the queue for i in range(5):
for i in range(5):
    element=input("enter queue element: ")
    myQueue.put(element)
# print the elements of the queue
for element in list(myQueue.queue):
    print(element)
print ("Queue size is: ",myQueue.qsize())
```

```
enter queue element: 5
enter queue element: f
enter queue element: 12
enter queue element: b
enter queue element: 23
5
f
12
b
23
Queue size is: 5
```

أنشئ برنامجاً للتحقق مما إذا كان الطابور فارغاً أم ممتلئاً.

```
from queue import *
myQueue = Queue()
myQueue.put("a")
myQueue.put("b")
myQueue.put("c")
myQueue.put("d")
myQueue.put("e")
checkFull=myQueue.full()
print("Is the queue full? ", checkFull)
checkEmpty= myQueue.empty()
print("Is the queue empty? ", checkEmpty)
```

```
Is the queue full? False
Is the queue empty? False
```

كما ذُكر من قبل فإن الوحدة النمطية للطابور تحتوي على بعض الوظائف الجاهزة للاستخدام مع المُكدّس أو الطابور.

الجدول 1.6 يوضح وظائف الوحدة التي يمكن استخدامها مع هيكل بيانات المُكدّس.

جدول 1.6: طرائق الوحدة المستخدمة للمُكدّس

الوصف	الطريقة
تتشيّع مُكدّسًا جديداً اسمه <code>.stackName</code> .	<code>stackName=queue.LifoQueue()</code>
تحذف العنصر الأخير من المُكدّس.	<code>stackName.get()</code>

ستستخدم وحدة الطابور لإنشاء مُكدّس فارغ.

```
from queue import *
myStack = LifoQueue()
myStack.put("a")
myStack.put("b")
myStack.put("c")
myStack.put("d")
myStack.put("e")

for i in range(5):
    k=myStack.get()
    print(k)

# empty the stack
checkEmpty= myStack.empty()
print("Is the stack empty?", checkEmpty)
```

تذكّر أن العمليات في المُكدّس تعمل وفقاً لقاعدة المُضاف آخرًا يخرج أولاً (LIFO).

عند استخدام دالة `get` مع الطابور، ستستند عمليات الاستدعاء والطباعة إلى قاعدة المُضاف أولاً يخرج أولاً (FIFO).

```
e
d
c
b
a
Is the stack empty? True
```


مثال: الطباعة Print

يظهر أمامك في المثال التالي محاكاة لطابور الطباعة في الطابعة. عندما يُرسّل المستخدمون أوامر طباعة، تُضاف إلى طابور الطباعة. تستخدم الطابعة هذا الطابور لتحديد الملف الذي سيطبع أولاً.


- افتراض أن سعة الطابعة هي فقط 7 ملفات، ولكن في الوقت نفسه، تحتاج إلى طباعة 10 ملفات من الملف A إلى الملف J.
- اكتب برنامجاً يمثل طابور الطباعة منذ بدء أمر الطباعة الأول A حتى الانتهاء من كل أوامر الطباعة.
- أضف اللبنة التي تؤكّد أن طابور أوامر الطباعة فارغ.

يمكنك استخدام الخوارزمية الآتية:

1 أنشئ طابور أوامر الطباعة.



2 أدرج الملفات من A إلى G في طابور أوامر الطباعة.



3 أخرج الملف A وأدرج الملف H.



4 أخرج الملف B وأدرج الملف I.



5 أخرج الملف C وأدرج الملف J.



6 أخرج الملفات التي تمت طباعتها واحداً تلو الآخر. (D-E-F-G-H-I-J)

```
# import the queue library
from queue import *
# import the time library to use the sleep function
import time
# initialize the variables and the queue
printDocument = " "
printQueueSize = 0
printQueueMaxSize = 7
printQueue = Queue(printQueueMaxSize)
# add a document to print the queue
def addDocument(document):
    printQueueSize = printQueue.qsize()
    if printQueueSize == printQueueMaxSize:
        print("!! ", document, " was not sent to print queue.")
        print("The print queue is full.")
        print()
        return
    printQueue.put(document)
    time.sleep(0.5) #Wait 5.0 seconds
    print(document, " sent to print queue.")
    printQueueSizeMessage()
# print a document from the print queue
def printDocument():
    printQueueSize = printQueue.qsize()
    if printQueueSize == 0:
        print("!! The print queue is empty.")
```

```

        print()
        return
    printDocument = printQueue.get()
    time.sleep(1) # wait one second
    print ("OK - ", printDocument, " is printed.")
    printQueueSizeMessage()
# print a message with the size of the queue
def printQueueSizeMessage():
    printQueueSize = printQueue.qsize()
    if printQueueSize == 0:
        print ("There are no documents waiting for printing.")
    elif printQueueSize == 1:
        print ("There is 1 document waiting for printing.")
    else:
        print ("There are ", printQueueSize, " documents waiting for printing.")
    print()
# the main program
# send documents to the print queue for printing
addDocument("Document A")
addDocument("Document B")
addDocument("Document C")
addDocument("Document D")
addDocument("Document E")
addDocument("Document F")
addDocument("Document G")
printDocument()
addDocument("Document H")
printDocument()
addDocument("Document I")
printDocument()
addDocument("Document J")
addDocument("Document K")
printDocument()
printDocument()
printDocument()
printDocument()
printDocument()
printDocument()
printDocument()
printDocument()
printDocument()

```

Document A sent to print queue.
There is 1 document waiting for printing.

Document B sent to print queue.
There are 2 documents waiting for printing.

Document C sent to print queue.
There are 3 documents waiting for printing.

Document D sent to print queue.
There are 4 documents waiting for printing.

Document E sent to print queue.
There are 5 documents waiting for printing.

Document F sent to print queue.
There are 6 documents waiting for printing.

Document G sent to print queue.
There are 7 documents waiting for printing.

OK - Document A is printed.
There are 6 documents waiting for printing.

Document H sent to print queue.
There are 7 documents waiting for printing.

OK - Document B is printed.
There are 6 documents waiting for printing.

Document I sent to print queue.
There are 7 documents waiting for printing.

OK - Document C is printed.
There are 6 documents waiting for printing.

Document J sent to print queue.
There are 7 documents waiting for printing.

!! Document K was not sent to print queue.
The print queue is full.

OK - Document D is printed.
There are 6 documents waiting for printing.

OK - Document E is printed.
There are 5 documents waiting for printing.

OK - Document F is printed.
There are 4 documents waiting for printing.

OK - Document G is printed.
There are 3 documents waiting for printing.

OK - Document H is printed.
There are 2 documents waiting for printing.

OK - Document I is printed.
There is 1 document waiting for printing.

OK - Document J is printed.
There are no documents waiting for printing.

!! The print queue is empty.

هيأكل البيانات الثابتة والمتحيرة

سبق توضيح أن هيأكل البيانات هي طريقة فعالة لتخزين البيانات وتنظيمها، وبالإضافة إلى ما تعلمنته حول تصنيف هيأكل البيانات إلى أولية وغير أولية، فإنه يمكن تصنيفها أيضاً إلى ثابتة (Static) ومتحيرة (Dynamic).

هيأكل البيانات الثابتة

في البيانات الثابتة، يكون حجم الهيكل ثابتاً، وتُخزن عناصر البيانات في مواقع الذاكرة المجاورة. تُعد المصفوفة (Array) المثال الأبرز لهيأكل البيانات الثابتة.

هيأكل البيانات المتحيرة


في هيأكل البيانات المتحيرة، لا يكون حجم الهيكل ثابتاً ولكن يمكن تعديله أثناء تنفيذ البرنامج، حسب العمليات المنفذة عليه. تُصمم هيأكل البيانات المتحيرة لتسهيل تغيير حجم هيأكل البيانات أثناء التشغيل. وتُعد القائمة المترابطة (Linked List) المثال الأبرز لهيأكل البيانات المتحيرة.

جدول 1.7: مقارنة بين هيأكل البيانات الثابتة والمتحيرة

المتحيرة	الثابتة	حجم الذاكرة
يمكن تغيير حجم الذاكرة أثناء التشغيل.	حجم الذاكرة ثابت.	حجم الذاكرة
تُخزن العناصر في مواقع عشوائية في الذاكرة الرئيسية.	تُخزن العناصر في مواقع متجاورة في الذاكرة الرئيسية.	أنواع ذاكرة التخزين
أبطأ.	أسرع.	سرعة الوصول إلى البيانات

تخصيص الذاكرة

تنتمي القوائم المترابطة (Linked Lists) إلى هيأكل البيانات المتحيرة، وهذا يعني أن عقد القائمة المترابطة لا تُخزن في مواقع الذاكرة المجاورة مثل البيانات في المصفوفات. ولهذا السبب، تحتاج إلى تخزين المؤشر من عقدة إلى أخرى.



شكل 1.26: مثال على تخصيص الذاكرة الثابتة والمتحيرة

القائمة المترابطة Linked List

القائمة المترابطة (Linked List) :

القائمة المترابطة هي نوع من هيئات البيانات الخطية التي تشبه سلسلة من العقد.


العقدة (Node) :

العقدة هي البناء الفردية المكونة لهيكل البيانات وتحتوي على البيانات ورابط واحد أو أكثر من الروابط التي تربطها بالعقد الأخرى.

القائمة المترابطة هي نوع من هيئات البيانات الخطية، وهي واحدة من هيئات البيانات الأكثر شهرة في البرمجة. القائمة المترابطة تشبه سلسلة من العقد. تحتوي كل عقدة على حقلين: حقل البيانات حيث تخزن البيانات، وحقل يحتوي على المؤشر الذي يُشير إلى العقدة التالية. يُستثنى من هذا العقدة الأخيرة التي لا يحمل فيها حقل العنوان أي بيانات. إحدى مزايا القائمة المترابطة هي أن حجمها يزداد أو يقل بإضافة أو حذف العقد.



شكل 1.27: رسم توضيحي للقائمة المترابطة



شكل 1.28: رسم توضيحي للعقد

العقدة Node


ت تكون كل عقدة في القائمة المترابطة من جزئين:

- الجزء الأول يحتوي على البيانات.
- الجزء الثاني يحتوي على مؤشر يُشير إلى العقدة التالية.

لقراءة محتوى عقدة محددة، عليك المرور على كل العقد السابقة.

لتشاهد مثلاً على القائمة المترابطة للأعداد الصحيحة.

ت تكون القائمة المترابطة من خمس عقد.




شكل 1.29: رسم توضيحي يمثل قائمة مترابطة للأعداد الصحيحة

العقد في القائمة لا يكون لها اسم، وما تعرفه عنها هو عنوانها (الموقع الذي تخزن فيه العقدة في الذاكرة). للوصول إلى أي عقدة بالقائمة، تحتاج فقط إلى معرفة عنوان العقدة الأولى. ثم تتبع سلسلة العقد للوصول إلى العقدة المطلوبة.

على سبيل المثال، إن كنت ترغب في الوصول إلى العُقدة الثالثة في القائمة لمعالجة البيانات التي تحتوي عليها، عليك البدء من العُقدة الأولى في القائمة، ومن العُقدة الأولى للوصول إلى الثانية، ومن الثانية للوصول إلى الثالثة.

- عنوان العُقدة الأولى مُخزن في متغير خاص (مستقل) يُطلق عليه عادةً الرأس (Head).
- قيمة مؤشر العُقدة الأخيرة في القائمة قيمة فارغة (Null)، ويعتبر بالرمز ●.
- عندما تكون القائمة فارغة، يشير مؤشر الرأس إلى القيمة الفارغة (Null).





شكل 1.30: الوصول إلى العُقدة الثالثة في القائمة المترابطة

إليك مثلاً توضيحاً على القائمة المترابطة في الشكل 1.31، كما ذكر من قبل فإن كل عُقدة تتكون من بيانات ومؤشر يشير إلى العُقدة التالية، بحيث تخزن كل عُقدة في الذاكرة في عنوان مُحدد.

مثال على العُقدة:

- بيانات العُقدة هي الرقم 15.
- عنوان العُقدة في الذاكرة هو 10.
- عنوان العُقدة التالية هو 20.

لتربط العُقدة السابقة بالعقدة التالية بقيمة بيانات 42، التي بدورها تُشير إلى العُقدة الثالثة والأخيرة عند عنوان 30 بقيمة بيانات 37.



شكل 1.31: المؤشرات في القائمة المترابطة

جدول 1.8: الاختلافات بين القائمة والقائمة المترابطة


القائمة المترابطة	القائمة	الاختلافات
الموقع عشوائي في الذاكرة.	الموقع متوازي في الذاكرة.	طريقة تخزين الذاكرة
يمكن الوصول إلى العناصر من خلال المؤشر (Pointer).	يمكن الوصول إلى كل عنصر برقم الفهرس (Index).	الهيكل
تخزن العناصر في صورة عقد تحتوي على البيانات وعنوان العنصر التالي.	يُخزن كل عنصر تلو الآخر.	الحجم
تخزن البيانات والمؤشرات في الذاكرة.	تخزن البيانات وحدها في الذاكرة.	استخدام الذاكرة
الوصول المتسلسل إلى العناصر.	الوصول العشوائي إلى أي عنصر بالقائمة.	نوع الوصول إلى البيانات
سرعة إضافة العناصر وحذفها.	بطء إضافة العناصر وحذفها.	سرعة الإضافة والحذف

الفئة (Class) :

الفئة هي هيكل بيانات معروف بواسطة المستخدم، ويحتوي على أعضاء البيانات (السمات)، والطراائق (السلوك) الخاصة بها. وتُستخدم الفئات كقوالب لإنشاء الكائنات.

القائمة المترابطة في لغة البايثون

لا تتوفر لغة البايثون نوع بيانات مُحدّد مُسبقًا للقوائم المترابطة. عليك إنشاء نوع البيانات الخاص بك، أو استخدام مكتبات البايثون التي توفر تمثيلًا لهذا النوع من البيانات. لإنشاء قائمة مترابطة، استخدم فئات البايثون. في المثال الموضح بالشكل 1.32، ستُنشئ قائمة مترابطة مكونة من ثلاثة عقد، كل واحدة تضم يومًا من أيام الأسبوع.



شكل 1.32: مثال على القائمة المترابطة.

ستُنشئ أولًا عقدة باستخدام الفئة.

```
# single node
class Node:
    def __init__(self, data, next=None):
        self.data = data # node data
        self.next = next # Pointer to the next node

# Create a single node
first = Node("Monday")
print(first.data)
```

Monday

الخطوة التالية هي إنشاء قائمة مترابطة تحتوي على عقدة واحدة، وهذه المرة ستُستخدم مؤشر الرأس للإشارة إلى العقدة الأولى.

```
# single node
class Node:
    def __init__(self, data = None, next=None):
        self.data = data
        self.next = next

# linked list with one head node
class LinkedList:
    def __init__(self):
        self.head = None

# list linked with a single node
Linkedlist1 = LinkedList()
Linkedlist1.head = Node("Monday")
print(Linkedlist1.head.data)
```

Monday

أضف الآن المزيد من العقد إلى القائمة المترابطة.

```
# single node
class Node:
    def __init__(self, data = None, next=None):
        self.data = data
        self.next = next


# an empty linked list with a head node.
class LinkedList:
    def __init__(self):
        self.head = None

# the main program
linked_list = LinkedList()
# the first node
linked_list.head = Node("Monday")
# the second node
linked_list.head.next = Node("Tuesday")
# the third node
linked_list.head.next.next = Node("Wednesday")

# print the linked list
node = linked_list.head
while node:
    print(node.data)
    node = node.next
```

تُستخدم عبارة while للتنتقل من عقدة إلى أخرى.

Monday
Tuesday
Wednesday



2. اربط العقدة 37 بالعقدة 99.

3. اربط العقدة 12 بالعقدة 37 (تمت إضافة العقدة الجديدة).

إضافة العقدة إلى القائمة المترابطة

Add a Node to a Linked List

لتمكن من إضافة عقدة جديدة، اتبع الخطوات التالية:

- يجب أن يشير مؤشر العقدة الأولى إلى عنوان العقدة الجديدة، حتى تصبح العقدة الجديدة هي العقدة الثانية.
- يجب أن يشير مؤشر العقدة الجديدة (الثانية) إلى عنوان العقدة الثالثة. بهذه الطريقة، لن تحتاج إلى تغيير العناصر عند إضافة عنصر جديد في المنتصف. تقتصر العملية على تغيير قيم العناوين في العقدة التي تسرع من عملية الإضافة في حالة القوائم المترابطة، مقارنة بحالة القوائم المترتبة.

مثال:

لديك قائمة مترابطة من عنصرين: 12 و 99، وتريد إدراج العنصر 37 كعنصر ثانٍ في القائمة. في النهاية، سيكون لديك قائمة من ثلاثة عناصر: 12 و 37 و 99.

```

# single node
class Node:
    def __init__(self, data = None, next=None):
        self.data = data
        self.next = next

# linked list with one head node
class LinkedList:
    def __init__(self):
        self.head = None

    def insertAfter(new, prev):
        # create the new node
        new_node = Node(new)
        # make the next of the new node the same as the next of the previous node
        new_node.next = prev.next
        # make the next of the previous node the new node
        prev.next = new_node

    # create the linked list
    L_list = LinkedList()

    # add the first two nodes
    L_list.head = Node(12)
    second = Node(99)
    L_list.head.next = second

    # insert the new node after node 12 (the head of the list)
    insertAfter(37, L_list.head)

    # print the linked list
    node = L_list.head
    while node:
        print (node.data)
        node = node.next

```

12
37
99

حذف العُقدة من القائمة المترابطة Delete a Node from a Linked List

لحذف عُقدة، عليك تغيير مؤشر العُقدة التي تسبق العُقدة المراد حذفها إلى مؤشر العُقدة التي تلي العُقدة المحذوفة. أصبحت العُقدة المحذوفة (الثانية) عبارة عن بيانات غير مفيدة (Useless Data) وستُخَصِّص مساحة الذاكرة التي تشغله لاستخدامات أخرى.

مثال:

لديك قائمة مترابطة من ثلاثة عناصر: 12 و 37 و 99، وترغب في حذف العنصر 37. في النهاية، سيكون لديك قائمة من عنصرين: 12 و 99.



```

# single node
class Node:
    def __init__(self, data = None, next=None):
        self.data = data
        self.next = next

# linked list with one head node
class LinkedList:
    def __init__(self):
        self.head = None

    def deleteNode(key, follow):

        # store the head node
        temp = follow.head

        # find the key to be deleted,
        # the trace of the previous node to be changed
        while(temp is not None):
            if temp.data == key:
                break
            prev = temp
            temp = temp.next

        # unlink the node from the linked list
        prev.next = temp.next
        temp = None

    # create the linked list
    L_list = LinkedList()


    # add the first three nodes
    L_list.head = Node(12)
    second = Node(37)
    third = Node(99)
    L_list.head.next = second
    second.next = third

    # delete node 37
    deleteNode(37, L_list)

    # print the linked list
    node = L_list.head
    while node:
        print (node.data)
        node = node.next


```

12
99




1. اربط مؤشر العقدة 12 بالعقدة 99.

2. احذف العقدة 37.



3. النتيجة النهائية



إذا كنت تريده حذف العقدة الأولى من القائمة المترابطة، عليك نقل مؤشر الرأس إلى العقدة الثانية من القائمة.

تمرينات

1

خاطئة	صحيحة	حدد الجملة الصحيحة والجملة الخاطئة فيما يلي:
<input type="radio"/>	<input type="radio"/>	1. لغة البايثون تُعرف هيكل البيانات غير الأولية.
<input type="radio"/>	<input type="radio"/>	2. هيكل البيانات الخطية تخزن عناصر البيانات في ترتيب عشوائي فقط.
<input type="radio"/>	<input type="radio"/>	3. إضافة العناصر وحذفها من القائمة المترابطة (Linked List) أبطأ من القائمة .(List)
<input type="radio"/>	<input type="radio"/>	4. يمكن الوصول إلى العناصر في القائمة باستخدام رقم الفهرس فقط.
<input type="radio"/>	<input type="radio"/>	5. يمكن تغيير حجم هيكل البيانات الثابتة أثناء تنفيذ البرنامج.

2

حدد الاختلافات بين هيكل البيانات الثابتة والمتحركة.

هيكل البيانات المتجورة	هيكل البيانات الثابتة

3

اكتب مثالين لاستخدامات القوائم المترابطة.

المخرج النهائي	المكدس
5	5
4	4
3	3
2	2
1	1
0	0

لديك مُكدس به ست مساحات فارغة.

4

- سُتضيف الحروف الآتية C و E و B و A و D في الموضع من 0 إلى 4.
- املأ المكدس الذي يُشير إلى موقع المؤشر الأعلى.

• تَفَذ العمليات التالية:

pop → push K → push X → pop → pop →

اظهر المُخرج النهائي بعد تنفيذ العمليات السابقة للإشارة إلى موقع المؤشر العلوي.

اكتب البرنامج الذي ينشئ المكدس الموضح بالأعلى، ثم تَفَذ العمليات المذكورة أعلاه باستخدام مكتبة الطابور القياسية.

لديك التسلسل الرقمي الآتي: 4 و 8 و 2 و 5 و 9 و 13.

5

- ما العملية المستخدمة لإضافة العناصر الموضحة بالأعلى إلى الطابور؟
-
-

- أكمل الطابور بعد إضافة العناصر.

0	1	2	3	4	5





- ما العملية المستخدمة لحذف العناصر من الطابور؟
-
-

- كم مرة يجب تنفيذ العملية الموضحة بالأعلى لحذف العنصر الذي قيمته 5.
-
-

- أكتب المقطع البرمجي بلغة البايثون لإنشاء الطابور السابق.

باستخدام العُقد التالية ارسم القائمة المتراقبة، ثم اكتب القيم في القائمة بالترتيب السليم.

6




الرأس = 3

أنشئ قائمة تضم الأرقام التالية: 5 و 20 و 45 و 8 و 1.

7

- ارسم العقد في القائمة المترابطة.

- صف عملية إضافة الرقم 7 بعد الرقم 45.



- ## • ارسم القائمة الجديدة.

- صُف العمليات المطلوبة لحذف العقدة الثانية من القائمة.



- ارسم القائمة المترابطة النهائية.


هيأكل البيانات غير الخطية



في الدرس السابق تعلّمت بعض هيأكل البيانات الخطية، وفيها كل عنصر يتبع العنصر السابق له بطريقة خطية. هل يمكنك التفكير في حالة لا تسير فيها الأشياء بسلسل خطٍّ؟ على سبيل المثال، هل يمكن لعنصر واحد أن يتبعه أكثر من عنصر؟

هيأكل البيانات غير الخطية Non-Linear Data Structures

هي نوع من هيأكل البيانات يتميز بإمكانية ربط عنصر بأكثر من عنصر واحد في الوقت نفسه. ومن الأمثلة التوضيحية على هيأكل البيانات غير الخطية: الأشجار ومُخطّطات البيانات. الشكل 1.33 يوضح هيأكل البيانات الخطية وهيأكل البيانات غير الخطية.




شكل 1.33: الرسم التوضيحي لهياكل البيانات الخطية وغير الخطية

جدول 1.9: الفرق بين هيأكل البيانات الخطية وغير الخطية

هيأكل البيانات غير الخطية	هيأكل البيانات الخطية
يمكن ربط عناصر البيانات بالعديد من العناصر الأخرى.	تُرتَب عناصر البيانات في ترتيب خطٍّ يرتبط فيه كل عنصر بالعنصرين السابق والتالي له.
لا تُستعرض عناصر البيانات في مسار واحد.	تُستعرض عناصر البيانات في مسار واحد.
معقد التنفيذ.	سهل التنفيذ.

الأشجار Trees



شكل 1.34: العلاقات في الشجرة

الأشجار هي نوع من هيئات البيانات غير الخطية، وتكون الشجرة من مجموعة من العقد المرتبة في ترتيب هرمي. ترتبط كل عقدة بوحدة أو أكثر من العقد، وترتبط العقد مع الحواف في نموذج علاقة يربط بين الأصل (Parent) والفرع (Child). تُستخدم الأشجار في العديد من مجالات علوم الحاسوب، بما في ذلك أنظمة التشغيل، والرسوميات، وأنظمة قواعد البيانات، والألعاب، والذكاء الاصطناعي، وشبكات الحاسوب.

مُصطلحات تقنية الشجرة المستخدمة في هيكل بيانات الشجرة

Tree Terminology Used in the Tree Data Structure

- الجذر (Root): العقدة الأولى والوحيدة في الشجرة التي ليس لها أصل وتأتي في المستوى الأول من الشجرة، مثل: العقدة A في الشكل 1.35.
- الفرع (Child): العقدة المرتبطة مباشرةً بعقدة في المستوى أعلى، مثل: العقدة H هي فرع العقدة D، والعقدتان C و B هما فرعين للعقدة A.
- الأصل (Parent): العقدة التي لها فرع أو أكثر في المستوى الأقل، مثل: العقدة B هي أصل العقدتين D و E.
- الورقة (Leaf): العقدة التي ليس لها أي عقدة فرعية، مثل: الورقة F.
- الأشقاء (Siblings): كل العقد الفرعية التي تنبثق من الأصل نفسه، مثل: العقدتان D و E شقيقتان.
- الحافة (Edges): الروابط التي تصل بين العقد والشجرة.
- الشجرة الفرعية (Sub-Tree): الشجيرات التي توجد داخل الشجرة الأكبر حجمًا، مثل: الشجرة التي بها العقدة D هي الأصل والعقدتان H و I هما فرعيان.


الشجرة (Tree) :

الشجرة هي نوع من هيئات البيانات غير الخطية، وتكون من مجموعة من العقد المرتبة في ترتيب هرمي.

الحافة (Edge) :

الحافة تصل بين عقد هيكل بيانات الشجرة.


قد يكون لديك شجرة بسيطة تتكون من عقدة واحدة. تكون هذه العقدة في الوقت نفسه جذر هذه الشجرة البسيطة؛ لأنها ليس لها أصل.



شكل 1.35: هيكل بيانات الشجرة

قد تكون العُقدة فرعاً وأصلًا في الوقت نفسه: فرع للعُقدة السابقة وأصل للعُقدة التالية.

وفيما يلي مثال على هيكل بيانات الشجرة:




شكل 1.36: مثال على هيكل بيانات الشجرة

Tree Data Structure Features

- يُستخدم لتمثيل المُخطّط الهرمي.
- يتَّمِيز بالمرنة، فمن السهل إضافة عنصر من الشجرة أو حذفه.
- سهولة البحث عن العناصر فيه.
- يعكس العلاقات الهيكلية بين البيانات.

مثال

تنظيم الملفات في نظام التشغيل هو مثال عملي على الشجرة. كما يتضح في الشكل 1.37، يوجد داخل مجلد Documents (المستندات) مجلد آخر اسمه Python Projects (مشروعات البايثون) يحتوي على ملفين آخرين.




شكل 1.37: تنظيم الملفات في نظام التشغيل

هيكل بيانات الشجرة في لغة البايثون

Tree Data Structure in Python

لا تُتوفر لغة البايثون نوعاً محدداً مسبقاً من البيانات لهيكل بيانات الشجرة. ومع ذلك، تُصمّم الأشجار من القوائم والقواميس بسهولة. يوضح الشكل 1.38 تطبيقاً بسيطاً للشجرة باستخدام القاموس.




شكل 1.38: شجرة قاموس البايثون

في هذا المثال، سُتُنشئ شجرة باستخدام قاموس البايثون. ستمثل عقد الشجرة مفاتيح القاموس، وستكون القيمة المقابلة لكل مفتاح هي قائمة تحتوي على العقد المتصلة بحافة مباشرة من هذه العقدة.

```
myTree = {  
    "a": ["b", "c"], # node  
    "b": ["d", "e"],  
    "c": [None, "f"],  
    "d": [None, None],  
    "e": [None, None],  
    "f": [None, None],  
}  
print(myTree)
```

```
{'a': ['b', 'c'], 'b': ['d', 'e'], 'c': [None, 'f'],  
'd': [None, None], 'e': [None, None], 'f': [None, None]}
```

في المثال التالي سُتُنشئ شجرة مثل تلك الموضحة في الشكل 1.39:



شكل 1.39: شجرة هيكل البيانات


الأصل الفرع
myTree = {"Data Structures": ["Linear", "Non-linear"],
 "Linear": ["Stack", "Queue", "Linked List"],
 "Non-linear": ["Tree", "Graph"]}

```
for parent in myTree:  
    print(parent, "has", len(myTree[parent]), "nodes")  
    for children in myTree[parent]:  
        print(" ", children)
```

```
Data structures has 2 nodes  
Linear  
Non-linear  
Linear has 3 nodes  
Stack  
Queue  
Linked List  
Non-linear has 2 nodes  
Tree  
Graph
```

الشجرة الثنائية

الشجرة الثنائية هي نوع خاص من الأشجار، يكون لكل عقدة فيها فرعان على الأكثر: الفرع الأيمن والفرع الأيسر. الشكل 1.40 يعرض مثالاً يوضح الشجرة والشجرة الثنائية.



شكل 1.40: الشجرة والشجرة الثنائية

جدول 1.10: أنواع هياكل بيانات الشجرة الثنائية

النوع	الوصف	رسم توضيحي للهيكل
الشجرة الثنائية التامة (Full Binary Tree)	يكون لكل عقدة إما 0 أو 2 من الفروع (Leaves) بخلاف الأوراق (Children).	
الشجرة الثنائية الكاملة (Complete Binary Tree)	يكون كل مستوى من مستويات الشجرة ممتلاً بالكامل، ربما باستثناء المستوى الأخير، حيث تكون كل العقد فيه مملوءة من اليسار إلى اليمين.	
الشجرة الثنائية المثالية (Perfect Binary Tree)	يكون لكل عقد الداخلي فرعان وتكون كل الأوراق عند المستوى نفسه.	


أمثلة على تطبيقات هياكل بيانات الشجرة Examples of Applications of Tree Data Structures

- تخزين البيانات الهرمية مثل: هياكل المجلدات.
- تعريف البيانات في لغة ترميز النص التشعبي (HTML).
- تنفيذ الفهرسة في قواعد البيانات.

شجرة القرار Decision Tree

عبارة القرار `if a: else b` هي واحدة من العبارات الأكثر استخداماً في لغة البايثون. ومن خلال تداخل وتجميع هذه العبارات، يمكنك تصميم شجرة القرار.

تُستخدم أشجار القرارات في الذكاء الاصطناعي من خلال إحدى تقنيات تعلم الآلة وتُعرف باسم: **تعلم شجرة القرار Decision Tree Learning**). العقد الأخيرة في هذه التقنية تُسمى أيضاً الأوراق، وتحتوي على الحلول المحتملة للمشكلة. كل عقدة باستثناء الأوراق تُسمى أيضاً العقد، وهي تتكون من العقد والفرع. كل عقدة باستثناء العقد ترتبط بحالة منطقية يتفرع منها احتمالاً الإيجابة بنعم أو لا. أشجار القرارات تُعد سهلة الفهم، والاستخدام، والتوصير، ويسهل التحقق منها. على سبيل المثال، الشكل 1.41 يوضح شجرة القرار التي تُحدد ما إذا كنت ستتقاضى بطلب الالتحاق بجامعة محددة أم لا بناءً على معيارين: المقررات الدراسية التي تدرس في الجامعة، واستيفاء متطلبات القبول.




شكل 1.41: مثال على شجرة القرار

المُخطّط (Graph)

المُخطّط هو هيكل البيانات المكوّن من مجموعة من العُقد ومجموعة من الخطوط التي تصل بين جميع العُقد، أو بعضها.

كل الأشجار مُخطّطات، ولكن ليست كل المُخطّطات أشجاراً.

السمة الأكثر أهمية لهياكل البيانات غير الخطية هي أن البيانات الخاصة بها لا تتبع أي نوع من أنواع التسلسل، وذلك على خلاف المصفوفات والقوائم المتراكبة، كما يمكن ربط عناصرها بأكثر من عنصر واحد. الشجرة الجذرية (Rooted Tree) تبدأ بعقدة جذرية يمكن ربطها بالعقد الأخرى. تتبع الأشجار قواعد محددة: وهي أن تكون عقد الشجرة متصلة، وأن تكون الشجرة خالية من الحلقات (Loops) والحلقات الذاتية (Self Loops)، كما أن بعض أنواع الأشجار قواعدها الخاصة (جدول 1.10)، مثلاً في حالة الأشجار الثنائية. ولكن ماذا سيحدث إذا لم تتبع قواعد الأشجار؟ في هذه الحالة أنت لا تتحدث عن الأشجار، بل عن نوع جديد من هياكل البيانات المُتغيرة التي تُسمى المُخطّطات. في الحقيقة، الأشجار هي نوع من المُخطّطات حيث أن المُخطّط هو الشكل العام لهيكل البيانات، بمعنى أن كل هياكل البيانات السابقة يمكن اعتبارها حالات خاصة من المُخطّطات. الشكل 1.42 يعرض مُخطّطاً به ست عُقد وعشرين حوار.




شكل 1.42: مثال على مُخطّط به ست عُقد وعشرون حوار

جدول 1.11: الفرق بين الأشجار والمُخطّطات

المُخطّطات	الأشجار
تشكل العقد المتصلة فيها نموذجاً شبكيّاً.	تشكل العقد المتصلة فيها نموذجاً هرمياً.
لا توجد فيها عقدة فريدة أو جذرية.	في الأشجار الجذرية توجد عقدة فريدة تُسمى الجذر.
لا تتطابق علاقه الأصل والفرع بين العقد.	ترتبط العقد في صورة علاقه بين الأصل والفرع.
تركيب المُخطّطات أكثر تعقيداً.	تتميز ببساطة التركيب.
قد تحتوي على حلقات.	لا يُسمح فيها بالحلقات.

أنواع المُخْطَّطات Types of Graphs

- **المُخْطَّط المُوجَّه (Directed Graph):** ترتبط العقد بالحواف الموجهة في المُخْطَّط المُوجَّه، بحيث يكون للحافة اتجاه واحد.
- **المُخْطَّط غير المُوجَّه (Undirected graphs):** لا تحتوي الوصلات على اتجاه في المُخْطَّط غير المُوجَّه، وهذا يعني أن الحواف تشير إلى علاقة ثنائية الاتجاه يمكن من خلالها عرض البيانات في كلا الاتجاهين.
الشكل 1.43 يعرض مُخْطَّطاً موجَّهاً، ومُخْطَّطاً غير موجَّهاً يتكونان من ست عقد وست حواف.



شكل 1.43: المُخْطَّط المُوجَّه والمُخْطَّط غير المُوجَّه

المُخْطَّطات في الحياة اليومية Graphs in Everyday Life

شبكة الويب العالمية World Wide Web


تُعد شبكة الويب العالمية من أبرز الأمثلة للمُخْطَّطات، ويمكن اعتبارها بمثابة أحد أنواع المُخْطَّطات المُوجَّحة حيث تمثل الرؤوس (Vertices) صفحات الويب، وتتمثل الارتباطات التشعبية الحواف الموجَّحة. تنقيب بنية الويب (Web Structure Mining) هو اكتشاف المعرفة المفيدة من هيكل شبكة الويب الممثلة من خلال الارتباطات التشعبية، ويمكن أن يمثل المُخْطَّط الارتباطات التشعبية وال العلاقات التي تشتهر بها بين صفحات الويب المختلفة. يعرض الشكل 1.44 رسمياً توضيحاً لشبكة الويب العالمية. باستخدام هذه المُخْطَّطات يمكنك حساب الأهمية النسبية لصفحات الويب.



شكل 1.44: شبكة الويب العالمية

يستخدم محرك البحث قوقل (Google Search Engine) منهجية مماثلة لتحديد الأهمية النسبية لصفحات الويب ومن ثم ترتيب نتائج البحث حسب أهميتها. الخوارزمية المستخدمة بواسطة قوقل هي خوارزمية تصنيف الصفحة أو بيج رانك (PageRank) التي ابتكرها مؤسس قوقل.

فيسبوك




شكل 1.45: مُخطط فيسبوك غير الموجّه

فيسبوك هو مثال آخر على المخططات غير الموجّة. يظهر بالشكل 1.45 العقد التي تمثل مستخدمي فيسبوك، بينما تمثل الحواف علاقات الصداقة. عندما تريدين إضافة صديق، يجب عليه قبول طلب الصداقة. ولن يكون ذلك الشخص صديقك على الشبكة دون قبول طلب الصداقة. العلاقة هنا بين اثنين من المستخدمين (عقدتين) هي علاقة ثنائية الاتجاه. تُستخدم خوارزمية مقتربات الأصدقاء في فيسبوك نظرية المخططات. تدرس تحليلات الشبكات الاجتماعية العلاقات الاجتماعية باستخدام نظرية المخططات أو الشبكات من علوم الحاسوب.

خرائط قوقل


يستخدم تطبيق خرائط قوقل وكل التطبيقات المشابهة له المخططات لعرض أنظمة النقل والمواصلات لحساب المسار الأقصر بين موقعين. تُستخدم هذه التطبيقات المخططات التي تحتوي على عدد كبير جدًا من العقد والحواف التي لا يمكن تمييزها بالعين المجردة.



شكل 1.46: خرائط قوقل


الشبكة العصبية Neural Network

الشبكة العصبية هي نوع مخطط تعلم الآلة الذي يحاكي الدماغ البشري. الشبكات العصبية يمكن أن تكون شبكات موجّهة أو غير موجّهة وفقاً للغرض من التعلم، وتكون هذه الشبكات من الخلايا العصبية والأوزان الموزعة في الطبقات المختلفة. تمثل الخلايا العصبية بالعقد، بينما تمثل الأوزان بالحواف. يتم حساب تدفقات الإشارة وتحسينها في جميع أنحاء بنية الشبكات العصبية لتقليل الخطأ. تُستخدم الشبكات العصبية في العديد من التطبيقات الذكية مثل: الترجمة الآلية، وتصنيف الصور، وتحديد الكائنات، والتعريّف عليها. الشكل 1.47 يوضح مثلاً على هيكل الشبكات العصبية.



شكل 1.47: هيكل الشبكات العصبية

المُخْطَّطات في لغة البايثن Graphs in Python



شكل 1.48: مثال على المُخْطَّط

لا تُوفِّر لغة البايثن نوعاً محدداً مسبقاً من البيانات للأشجار، كما أنها لا توفِّر نوعاً محدداً مسبقاً من البيانات للمُخْطَّطات، (تذكَّر أن الأشجار هي نوع خاص من المُخْطَّطات). ومع ذلك، يُمكِّن بناء المُخْطَّطات باستخدام القوائم والقواميس.

في المثال التالي، ستقوم بتنفيذ التالي:

1. إنشاء مُخْطَّط مُوجَّه مثل المُوضِّح بالشكل 1.48.
2. إنشاء دالة لإضافة عُقدة إلى المُخْطَّط.
3. إنشاء كائن يحتوي على كل مسارات المُخْطَّط.

```
myGraph = { "a" : ["b", "c"],  
            "b" : ["c", "d"],  
            "c" : ["d", "e"],  
            "d" : [],  
            "e" : [],  
        }  
print(myGraph)
```

```
{'a': ['b', 'c'], 'b': ['c', 'd'], 'c': ['d', 'e'],  
'd': [], 'e': []}
```

وسينتولى البرنامج الرئيسي:

1. إنشاء المُخْطَّط.
2. طباعة المُخْطَّط.
3. استدعاء دالة الإضافة.
4. طباعة كل مسارات المُخْطَّط.

ستُستخدِّم القاموس الذي تمثِّل مفاتيحه العُقد بالمُخْطَّط. تكون القيمة المقابلة لكل مفتاح هي قائمة تحتوي على العُقد المتصلة بحافة مباشرة من هذه العُقدة.

```
# function for adding an edge to a graph  
def addEdge(graph,u,v):  
    graph[u].append(v)  
  
# function for generating the edges of a graph  
def generate_edges(graph):  
    edges = []  
  
    # for each node in graph  
    for node in graph:
```

```

# for each neighbouring node of a single node
for neighbour in graph[node]:
    # if edge exists then append to the list
    edges.append((node, neighbour))
return edges

# main program
# initialisation of graph as dictionary
myGraph = {"a" : ["b", "c"],
            "b" : ["c", "d"],
            "c" : ["d", "e"],
            "d" : [],
            "e" : [],
            }

# print the graph contents
print("The graph contents")
print(generate_edges(myGraph))

# add more edges to the graph
addEdge(myGraph, 'a', 'e')
addEdge(myGraph, 'c', 'f')

# print the graph after adding new edges
print("The new graph after adding new edges")
print(generate_edges(myGraph))

```

The graph contents
[('a', 'b'), ('a', 'c'), ('b', 'c'), ('b', 'd'), ('c', 'd'), ('c', 'e')]
The new graph after adding new edges
[('a', 'b'), ('a', 'c'), ('a', 'e'), ('b', 'c'), ('b', 'd'), ('c', 'd'),
 ('c', 'e'), ('c', 'f')]

تمرينات

1

خاطئة	صحيحة	حدد الجملة الصحيحة والجملة الخاطئة فيما يلي:
<input type="radio"/>	<input checked="" type="radio"/>	1. يمكن ربط العنصر في هياكل البيانات غير الخطية بأكثر من عنصر واحد.
<input type="radio"/>	<input checked="" type="radio"/>	2. تنفيذ هياكل البيانات الخطية يكون أكثر تعقيداً من تنفيذ هياكل البيانات غير الخطية.
<input type="radio"/>	<input checked="" type="radio"/>	3. الأوراق في تعلم شجرة القرار تحتوي على حلول المشكلة.
<input type="radio"/>	<input checked="" type="radio"/>	4. تُحسب خوارزمية قوقل تصنيف الصفحة (PageRank) الأهمية النسبية لصفحة ويب على شبكة الويب العالمية.
<input type="radio"/>	<input checked="" type="radio"/>	5. الشبكات العصبية هي نوع المخططات المستخدمة لتصوير المشكلات الأخرى.

2


المخططات	الأشجار

3

صف كيف تُستخدم خوارزميات المخططات في التطبيقات التجارية.

املا الفراغات بالأسماء الصحيحة لأجزاء الشجرة.



4



5

يظهر أمامك في الصورة التالية صفحة محتويات الكتاب.

- أكمل تمثيل الشجرة.




- هل هي شجرة ثنائية؟ علّ إجابتك.

6

ارسم الشجرة الناتجة عن المعطيات التالية:

- العُقدة A لها فرعان C و B.
- العُقدتان D و E لهما الأصل نفسه وهو العُقدة B.
- العُقدتان F و G شقيقتان، ولهمما الأصل نفسه وهو العُقدة C.
- العُقدة H لها عُقدتان فرعيتان اولاً ولها عُقدة أصل F.



ما نوع الشجرة المرسومة في الأعلى؟

باستخدام القاموس في لغة البايثون اكتب البرنامج المناسب لتمثيل هذه الشجرة، ثم أضف العقدة الأصل والعقد الفرعية.

المشروع

تُقدم الخدمة للعملاء في أحد البنوك بناءً على وقت وصولهم إلى فرع البنك. يعمل بالبنك موظف واحد، ومتوسط وقت الخدمة لكل عميل هو دقيقان.

لا يُسمح بأن يتجاوز الطابور في البنك 40 عميلاً.

1

أنشئ برنامجاً بلغة البايثون يستدعي إحدى قيم الاستيراد: ENTRY (دخول) أو NEXT (التالي).

- إن أدخلت القيمة ENTRY (دخول)، سيقرأ البرنامج اسم العميل وبعدها مباشرةً يُظهر عدد الأشخاص في قائمة الانتظار أمامه. إن كان الطابور مُمتلئاً، تظهر رسالة The branch is full. Come another day (الفرع مُمتلئ. الرجاء العودة في يوم آخر).
- إن أدخلت القيمة NEXT (التالي)، لابد أن يظهر اسم العميل التالي الذي ستُقدم له الخدمة.

2

كرر العملية الموضحة أعلاه حتى لا يكون هناك عملاء في قائمة الانتظار.

3

في النهاية، سيعرض البرنامج على الشاشة:

- عدد العملاء الذين قدّمت لهم الخدمة.
- متوسط وقت انتظار العميل.

ماذا تعلمت

- < مفهوم الذكاء الاصطناعي.
- < تصنیف تطبيقات الذكاء الاصطناعي.
- < تصنیف هياكل البيانات.
- < تحديد الاختلافات بين هيكل بيانات المكدس و هيكل بيانات الطابور.
- < تحديد الاختلافات بين هيكل بيانات القائمة و هيكل بيانات القائمة المترابطة.
- < تحديد الاختلافات بين هيكل بيانات الشجرة و هيكل بيانات المخطّط.
- < تطبيق هياكل البيانات المعقّدة باستخدام لغة برمجة البايثون.

المصطلحات الرئيسية

Binary Tree	الشجرة الثنائية	غير أولي
Child	فرع (ابن)	قيمة فارغة
Data Structure	هيكل البيانات	مؤشر
Decision Tree	شجرة القرار	حذف عنصر
Dequeue	حذف عنصر من الطابور	أولي
Directed Graph	المخطّط الموجّه	إضافة عنصر
Dynamic	متغير	آخر
Front	الأمامي	الجذر
Graph	مُخطّط	أشقاء
Index	فهرس	المكدس
Head	رأس	شجرة فرعية
Leaf	ورقة	أعلى
Linear	خطي	غيض المكدس
Linked List	قائمة مترابطة	المخطّط غير الموجّه
Non-Linear	غير خطوي	

٢. خوارزميات الذكاء الاصطناعي

سيتعرف الطالب في هذه الوحدة على بعض الخوارزميات الأساسية المستخدمة في الذكاء الاصطناعي (AI). كما سيتعلم كيف يُنشئ نظام تشخيص طبي بسيط مستند إلى القواعد بطرائق برمجية متعددة ثم يقارن النتائج. وفي الختام سيتعلم خوارزميات البحث وطرائق حل الغاز المتاحة معأخذ معايير معينة في الاعتبار.

أهداف التعلم

بنهاية هذه الوحدة سيكون الطالب قادرًا على أن :

- < يُنشئ مقطعاً برمجياً تكرارياً.
- < يقارن بين خوارزمية البحث بأولوية الاتساع وخوارزمية البحث بأولوية العمق.
- < يصف خوارزميات البحث وتطبيقاتها.
- < يقارن بين خوارزميات البحث.
- < يصف النظام القائم على القواعد.
- < يدرب نماذج الذكاء الاصطناعي حتى تتعلم حل المشكلات المعقدة.
- < يقيِّم نتائج المقطع البرمجي وكفاءة البرنامج الذي أنشأه.
- < يطور البرامج لمحاكاة حل مشكلات الحياة الواقعية.
- < يقارن بين خوارزميات البحث.

الأدوات

- < مفكرة جوبيتير (Jupyter Notebook)



الدرس الأول الاستدعاء الذاتي

تقسيم المشكلة *Dividing the Problem*

في هذا الدرس، ستعلّم استخدام الدوال التكرارية لتبسيط البرنامج وزيادة كفاءته. تخيل أن والدك قد أحضر لك هدية، وكنت مُتلهفًا لمعرفتها، ولكن عندما فتحت الصندوق، وجدت صندوقًا جديداً بداخله، وعندما فتحته، وجدت آخر بداخله، وهكذا حتى عجزت أن تعرف في أي صندوق توجد الهدية.

الاستدعاء الذاتي *Recursion*

الاستدعاء الذاتي هو أحد طرائق حل المشكلات في علوم الحاسوب، ويتم عن طريق تقسيم المشكلة إلى مجموعة من المشكلات الصغيرة المشابهة للمشكلة الأصلية حتى يُمكنك استخدام الخوارزمية نفسها لحل تلك المشكلات. يُستخدم الاستدعاء الذاتي بواسطة أنظمة التشغيل والتطبيقات الأخرى، كما تدعمه معظم لغات البرمجة.



شكل 2.1: مثال على الاستدعاء الذاتي

للتُّلُّق نظرة على مثال لدالة تستدعي دالة أخرى.

```
def mySumGrade (gradesList):
    sumGrade=0
    l=len(gradesList)
    for i in range(l):
        sumGrade=sumGrade+gradesList[i]
    return sumGrade

def avgFunc (gradesList):
    s=mySumGrade(gradesList)
    l=len(gradesList)
    avg=s/l
    return avg

# program section
grades=[89,88,98,95]
averageGrade=avgFunc(grades)
print ("The average grade is: ",averageGrade)
```

استدعاء الدالة
.mySumGrade


تستخدم دالة len() قائمة
كمُعامل مُدخل، لحساب وتحديد
عدد العناصر في القائمة.

The average grade is: 92.5

دالة الاستدعاء التكرارية

في بعض الحالات تستدعي الدالة نفسها وهذه الخاصية تُسمى الاستدعاء التكراري (Recursive Call).

يكون بناء الجملة العام لدالة الاستدعاء التكرارية على النحو التالي:



شكل 2.2: تمثيل الاستدعاء التكراري

```
# recursive function
def recurseFunction():
    if (condition): # base case
        statement
    else:
        #recursive call
        recurseFunction()

# main program
.....
# normal function call
recurseFunction()
.....
```

الاستدعاء التكراري هو عملية
استدعاء الدالة لنفسها.

ت تكون دالة الاستدعاء التكرارية من حالتين:

الحالة الأساسية Base Case

وفي هذه الحالة تتوقف الدالة عن استدعاء نفسها، ويتأكد الوصول إلى هذه الحالة من خلال الأمر المشروط. بدون الحالة الأساسية، ستتكرّر عملية الاستدعاء الذاتي إلى ما لا نهاية.


حالة الاستدعاء التكرارية Recursive Case

وفي هذه الحالة تستدعي الدالة نفسها عندما لا تتحقق شرط التوقف، وتظل الدالة في حالة الاستدعاء الذاتي حتى تصل إلى الحالة الأساسية.

أمثلة شائعة على الاستدعاء الذاتي Recursion Common Examples

أحد الأمثلة الأكثر شيوعاً على استخدام الاستدعاء الذاتي هو عملية حساب مضروب رقم معين. مضروب الرقم هو ناتج ضرب جميع الأعداد الطبيعية الأقل من أو تساوي ذلك الرقم. يُعبر عن المضروب بالرقم متبوعاً بالعلامة "!"، على سبيل المثال، مضروب الرقم 5 هو $5! = 1*2*3*4*5$.

ستلاحظ أن عملية حساب المضروب تستند إلى القاعدة أدناه:



جدول 2.1: مضروب الأرقام من 0 إلى 5

	$0! = 1$	$0!$
$1! = 0! * 1$	أو	$1! = 1*1 = 1$
$2! = 1! * 2$	أو	$2! = 2*1 = 2$
$3! = 2! * 3$	أو	$3! = 3*2*1 = 6$
$4! = 3! * 4$	أو	$4! = 4*3*2*1 = 24$
$5! = 4! * 5$	أو	$5! = 5*4*3*2*1 = 120$

لإنشاء برنامج يقوم باحتساب مضروب العدد باستخدام حلقة التكرار for، اتبع ما يلي:

```
# calculate the factorial of an integer using iteration


def factorialLoop(n):
    result = 1
    for i in range(2,n+1):
        result = result * i

    return result

# main program
num = int(input("Type a number: "))
f=factorialLoop(num)
print("The factorial of ", num, " is:", f)
```

Type a number: 3
The factorial of 3 is:6

الآن احسب مضروب العدد باستخدام دالة المضروب.



شكل 2.4: شجرة الاستدعاء الذاتي

جدول 2.2: مزايا الاستدعاء الذاتي وعيوبه

العيوب	المزايا
• في بعض الأحيان، يصعب تتبع منطق دوال الاستدعاء التكرارية.	• تقلل دوال الاستدعاء التكرارية من عدد التعليمات في المقطع البرمجي.
• يتطلب الاستدعاء الذاتي مزيداً من الذاكرة والوقت.	• يمكن تقسيم المهمة إلى مجموعة من المشكلات الفرعية باستخدام الاستدعاء الذاتي.
• لا يسهل تحديد الحالات التي يمكن فيها استخدام دوال الاستدعاء التكرارية.	• في بعض الأحيان، يسهل استخدام الاستدعاء الذاتي لاستبدال التكرارات المتداخلة.

الاستدعاء الذاتي والتكرار

يُستخدم كلٌّ من الاستدعاء الذاتي والتكرار في تنفيذ مجموعة من التعليمات لعدة مرات، والفارق الرئيس بين الاستدعاء الذاتي والتكرار هو طريقة إنهاء الدالة التكرارية. دالة الاستدعاء التكرارية تستدعي نفسها وتنتهي التنفيذ عندما تصل إلى الحالة الأساسية. أما التكرار فينفذ لبنة المقطع البرمجي باستمرار حتى يتحقق شرط محدد أو ينقضي عدد محدد من التكرارات.

الجدول التالي يعرض بعض الاختلافات بين الاستدعاء الذاتي والتكرار.

جدول 2.3: التكرار والاستدعاء الذاتي

الاستدعاء الذاتي	التكرار
بطيء التنفيذ مقارنة بالتكرار.	سرع التنفيذ.
يتطلب حجم ذاكرة أكبر.	يتطلب حجم ذاكرة أقل.
حجم المقطع البرمجي أصغر.	حجم المقطع البرمجي أكبر.
ينتهي بمجرد الوصول إلى الحالة الأساسية.	ينتهي باستكمال العدد المحدد من التكرارات أو تحقيق شرط معين.

متى تُستخدم الاستدعاء الذاتي؟


- يُعدُّ الاستدعاء الذاتي الطريقة الأكثر ملائمة للتعامل مع المشكلة في العديد من الحالات.
- يَسْهُل استكشاف بعض هيئات البيانات باستخدام الاستدعاء الذاتي.
- بعض خوارزميات التصنيف (Sorting Algorithms)، تُستخدم الاستدعاء الذاتي، مثل: التصنيف السريع (Quick Sort).

في المثال التالي، سترجع أكبـر رقم موجود في قائمة مكونة من الأرقـام باستخدـام دالة الاستـدعاء التـكرارـية. كما يـظهر في السـطر الآخـير من المـثال دـالة آخـرى للتـكرار لـغرض المـقارـنة.

```
def findMaxRecursion(A,n):  
  
    if n==1:  
        m = A[n-1]  
    else:  
        m = max(A[n-1],findMaxRecursion(A,n-1))  
    return m  
  
def findMaxIteration(A,n):  
  
    m = A[0]  
    for i in range(1,n):  
        m = max(m,A[i])  
    return m  
  
# main program  
myList = [3,73,-5,42]  
l = len(myList)  
myMaxRecursion = findMaxRecursion(myList,l)  
print("Max with recursion is: ", myMaxRecursion)  
myMaxIteration = findMaxIteration(myList,l)  
print("Max with iteration is: ", myMaxIteration)
```

تـرجـع الدـالة `max()` العـنـصـر ذـا الـقـيمـة الأـكـبـر (الـعنـصـر ذـو الـقـيمـة الأـكـبـر في myList).

```
Max with recursion is: 73  
Max with iteration is: 73
```



شكل 2.5: شجرة الاستـدعاء الذـاتـي لـدـالة استـرجـاع أكبـر رقم في قائـمة مـكونـة من الأـرقـام

في البرنامج التالي، ستُنشئ دالة استدعاء تكرارية لحساب مضاعف الرقم. ستقوم بإدخال رقمًا (الأس) وفهرسًا (الأس أو القوّة) يقبلهما البرنامج، ومن ثم ستستخدم دالة الاستدعاء التكرارية `powerFunRecursive()` التي ستستخدم هذين المدخلين لحساب مضاعف الرقم. يمكن تحقيق الأمر نفسه باستخدام التكرار، والمثال التالي يوضح ذلك:

```
def powerFunRecursive(baseNum,expNum):
    if(expNum==1):
        return(baseNum)
    else:
        return(baseNum*powerFunRecursive(baseNum,expNum-1))

def powerFunIteration(baseNum,expNum):

    numPower = 1
    for i in range(exp):
        numPower = numPower*base
    return numPower

# main program
base = int(input("Enter number: "))
exp = int(input("Enter exponent: "))
numPowerRecursion = powerFunRecursive(base,exp)
print( "Recursion: ", base, " raised to ", exp, " = ",numPowerRecursion)
numPowerIteration = powerFunIteration(base,exp)
print( "Iteration: ", base, " raised to ", exp, " = ",numPowerIteration)
```

```
Enter number: 10
Enter exponent: 3
Recursion: 10 raised to 3 = 1000
Iteration: 10 raised to 3 = 1000
```

دالة الاستدعاء التكرارية اللانهائية Infinite Recursive Function

يجب أن تكون حذرًا للغاية عند تنفيذ الاستدعاء التكراري، كما يجب عليك استخدام طريقة معينة لإيقاف التكرار عند تحقيق شرط محدد لتجنب حدوث الاستدعاء التكراري اللانهائي، الذي يسبب توقف النظام عن الاستجابة بسبب كثرة استدعاءات الدالة، مما يؤدي إلى **فيض الذاكرة** (Memory Overflow) وإناء التطبيق.

تمرينات

1

خاطئة	صحيحة	حدد الجملة الصحيحة والجملة الخاطئة فيما يلي:
<input type="radio"/>	<input checked="" type="radio"/>	1. تكون دالة الاستدعاء التكرارية من حالتين.
<input type="radio"/>	<input checked="" type="radio"/>	2. تستدعي دالة الاستدعاء التكرارية دالة أخرى.
<input type="radio"/>	<input checked="" type="radio"/>	3. دوال الاستدعاء التكرارية أسرع في التنفيذ.
<input type="radio"/>	<input checked="" type="radio"/>	4. استدعاء الدوال يجعل لغة المقطع البرمجي أصغر حجماً.
<input type="radio"/>	<input checked="" type="radio"/>	5. كتابة مقطع برمجي متكرر يتطلب استدعاء ذاتياً أقل.

ما الاختلافات بين التكرار والاستدعاء الذاتي؟ 2

متى يجب استخدام الاستدعاء الذاتي؟ 3

4

وضح مزايا استخدام الاستدعاء الذاتي وعيوبه.

5

اكتب دالة استدعاء تكرارية بلغة البايثون تقوم بحساب الرقم الأكبر بترتيب محدد (مثلاً ثاني أكبر رقم) في قائمة من الأرقام.

6


اكتب دالة استدعاء تكرارية بلغة البايثون لحساب مجموع كل الأرقام الزوجية في قائمة معينة.

خوارزمية البحث بأولوية العمق والبحث بأولوية الاتساع


البحث في المخططات Searching in Graphs

هناك بعض الحالات التي تحتاج فيها إلى البحث عن عقدة محددة في المخطط، أو تفحص كل عقدة في المخطط لإجراء عملية بعينها مثل طباعة عقد المخطط، فتكون حالتك كشخص يبحث عن المدينة التي يريد السفر إليها؛ ولتحقيق هذا، تحتاج إلى فحص كل عقدة في المخطط حتى تجد تلك التي تحتاج إليها. يطلق على هذا الإجراء: البحث في المخطط أو مسح المخطط، وهناك العديد من خوارزميات البحث التي تساعده على تفديه، مثل:


- خوارزمية البحث بأولوية الاتساع (Breadth-First Search - BFS).
- خوارزمية البحث بأولوية العمق (Depth-First Search - DFS).



مثال على خوارزمية البحث بأولوية العمق (DFS) : حل المأهنة



مثال على خوارزمية البحث بأولوية الاتساع (BFS) : البث الشبكي



شكل 2.6: خوارزمية البحث بأولوية الاتساع (BFS)

خوارزمية البحث بأولوية الاتساع Breadth-First Search (BFS) Algorithm



تستكشف خوارزمية البحث بأولوية الاتساع (BFS) المخطط بحسب المستوى واحداً تلو الآخر، حيث تبدأ بفحص عقدة الجذر (عقدة البداية)، ثم تفحص جميع العقد المرتبطة بها بشكل مباشر واحدة تلو الأخرى. بعد الانتهاء من فحص كل العقد في المستوى، تنتقل إلى المستوى التالي، وتتبع الإجراءات نفسها الموضحة في الشكل 2.6.

يُستخدم الطابور لتتبع العقد التي تم فحصها، وبمجرد استكشاف العقدة، ستم إضافة العقد الفرعية إلى الطابور، ثم تزحف العقدة التالية الموجودة في أول الطابور التي تم استكشافها سابقاً.

المثال التالي يوضح طريقة عمل خوارزمية البحث بأولوية الاتساع (BFS). باستخدام المُخطل التالي، حدد العقد التي يجب فحصها للانتقال من عقدة الجذر A إلى عقدة F:

ملاحظة: استخدم هيكل البيانات المناسب.



عليك فحص كل العقد في المستوى 1 قبل الانتقال إلى العقد في المستوى 2.



3 احذف العقدة من مقدمة الطابور (العقدة B) لمعالجتها، ثم أضف فروع هذه العقدة إلى الطابور (العقدتين D و E).


2 احذف العقدة الجذرية من الطابور لمعالجتها، ثم أضف فروع هذه العقدة إلى الطابور (العقدتين B و C).

1 البداية من العقدة الجذرية (العقدة A). أضف العقدة الجذرية إلى الطابور.




6 احذف العقدة E لمعالجتها.

(ليس لديها فروع).




5 احذف العقدة D لمعالجتها.

(ليس لديها فروع).




4 احذف العقدة C ومعالجتها،

ثم أضف فرعها إليها.



7 احذف العقدة F لمعالجتها، وبذلك أصبح الطابور الآن فارغاً وانتهت عملية البحث.

العقد التي فحصت باستخدام خوارزمية البحث بأولوية الاتساع (BFS) هي: F, E, D, C, B, A.



لاحظ كيف يمكنك تطبيق خوارزمية البحث بأولوية الاتساع (BFS) بلغة الباليتون (Python) في المثال التالي:

```

graph = {
    "A" : ["B", "C"],
    "B" : ["D", "E"],
    "C" : ["F"],
    "D" : [],
    "E" : [],
    "F" : []
}

visitedBFS = [] # List to keep track of visited nodes
queue = [] # Initialize a queue

# bfs function
def bfs(visited, graph, node):
    visited.append(node)

```

```

queue.append(node)

while queue:
    n = queue.pop(0)
    print (n, end = " ")

    for neighbor in graph[n]:
        if neighbor not in visited:
            visited.append(neighbor)
            queue.append(neighbor)

# main program
bfs(visitedBFS, graph, "A")

```

A B C D E F


التطبيقات العملية لخوارزمية البحث بأولوية الاتساع

Practical Applications of the BFS Algorithm

تُستخدم في شبكات النَّظير للنَّظير (Peer-to-Peer Networks) للعثور على كل العُقد المجاورة من أجل تأسيس الاتصال.



تُستخدم في وسائل التواصل الاجتماعي (Social Media) لربط عُقد المستخدمين المُرتبطين، مثل أولئك الذين لهم اهتمامات نفسها أو الموقع نفسه.



تُستخدم في نُظم الملاحة باستخدام مُحدَّد المواقع العالمي (GPS Navigation Systems) للبحث عن الأماكن المجاورة حتى تُحدَّد الاتجاهات التي يتبعها المستخدم.



تُستخدم للحصول على البث الشبكي (Network Broadcasting) لبعض الحُزم.




معلومة

يمكن تطوير خوارزمية البحث بأولوية الاتساع (BFS) بتحديد نقطة البداية (الحالة الأولية) ونقطة الهدف (الحالة المستهدفة) لزيادة المسار بينهما.

خوارزمية البحث بأولوية العمق

Depth-First Search (DFS) Algorithm

في البحث بأولوية العمق (DFS)، ستقوم باتباع الحواف، وتعمق أكثر وأكثر في المُخطّط. يستخدم البحث بأولوية العمق إجراء استدعاء تكراري للتنقل عبر العقد. عند الوصول إلى عقدة لا تحتوي على حواف لأي عقدة جديدة، ستعود إلى العقدة السابقة وتستمر العملية. تستخدم خوارزمية البحث بأولوية العمق هيكل بيانات المُكّدس لتبّع مسار الاستكشاف. بمجرد استكشاف عقدة، ستضاف إلى المُكّدس. عندما ترغب في العودة، ستحذف العقدة من المُكّدس كما هو موضح في الشكل 2.7.





شكل 2.7: خوارزمية البحث بأولوية العمق (DFS)


المثال التالي يوضح طريقة عمل خوارزمية البحث بأولوية العمق (DFS)، باستخدام المُخطّط التالي، تتبع ترتيب استكشاف العقد (Traversal) بحسب خوارزمية البحث بأولوية العمق.

ملاحظة: استخدام هيكل البيانات المناسب.


١ عالج الجذر A ثم أضفه إلى المُكّدس.




٣ عالج العقدة D ثم أضفها إلى المُكّدس. ستحذف العقدة التي فُحصت وليس لها فروع من المُكّدس. (احذف العقدة D).



٢ عالج العقدة B ثم أضفها إلى المُكّدس.




٤ عالج العقدة E ثم أضفها إلى المُكّدس. ستحذف العقدة التي فُحصت وليس لها فروع من المُكّدس. (احذف العقدة E).




لحة تاريخية

طورت النسخة الأولى من خوارزمية البحث بأولوية العمق (DFS) في القرن التاسع عشر بواسطة عالم رياضيات فرنسي كاستراتيجية لحل المذاهات.


٦ عالِج العُقدة C ثم أضفها إلى المُكَدَّس.



٥ احذف العُقدة B.




٨ المُكَدَّس خالي وبالتالي ستتوقف خوارزمية البحث بأولوية العمق (DFS).



العقد التي فُحصت باستخدام خوارزمية البحث بأولوية العمق (DFS) هي: F, C, E, D, B, A.

٧ عالِج العُقدة F ثم أضفها إلى المُكَدَّس.



والآن سنتعلم طريقة تفاصيل خوارزمية البحث بأولوية العمق (DFS) في لغة البايثون.

```
graph = {
    "A" : ["B", "C"],
    "B" : ["D", "E"],
    "C" : ["F"],
    "D" : [],
    "E" : [],
    "F" : []
}

visitedDFS = [] # list to keep track of visited nodes

# dfs function
def dfs(visited, graph, node):
    if node not in visited:
        print(node, end = " ")
        visited.append(node)
        for neighbor in graph[node]:
            dfs(visited, graph, neighbor)

# main program
dfs(visitedDFS, graph, "A")
```


يُستخدم المُكَدَّس بصورة غير مباشرة عبر مُكَدَّس أثناء التشغيل (Runtime Stack) لتنبيه الاستدعاءات التكرارية.

A B D E C F


التطبيقات العملية لخوارزمية البحث بأولوية العمق

Practical Applications of the DFS Algorithm


تُستخدم خوارزمية البحث بأولوية العمق في إيجاد المسارات (Path Finding) لاستكشاف المسارات المختلفة في العمق للخرائط والطرق والبحث عن المسار الأفضل.



تُستخدم خوارزمية البحث بأولوية العمق في حل المazes (Solve Mazes) من خلال اجتياز كل الطريق الممكن.



يمكن تحديد الدورات (Cycles) في المخطط باستخدام خوارزمية البحث بأولوية العمق من خلال وجود حافة خلفية (Back Edge)، تمر من خلال العقدة نفسها مرتين.



جدول 2.4: مقارنة بين خوارزمية البحث بأولوية الاتساع (BFS) و خوارزمية البحث بأولوية العمق (DFS)

معايير المقارنة	خوارزمية البحث بأولوية الاتساع (BFS)	خوارزمية البحث بأولوية العمق (DFS)
طريقة التنفيذ	التنقل حسب مستوى الشجرة.	التنقل حسب عمق الشجرة.
هيكل البيانات	تستخدم هيكل بيانات المكدس لتتبع الموقع التالي لفحصه.	تستخدم هيكل بيانات الطابور لتتبع الموقع التالي لفحصه.
الاستخدام	يُفضل استخدامها عندما يكون هيكل المخطط ضيقاً وطويلاً.	يُفضل استخدامها عندما يكون هيكل المخطط واسعاً وقصيراً.
طريقة البحث	يتجه البحث إلى قاع الشجرة الفرعية، ثم يتراجع.	تبحث عن مسار الوجهة باستخدام أقل عدد من الحواف.
العقد التي تُفحص في البداية	فحص عقد الفروع قبل الأشقاء.	فحص عقد الأشقاء قبل الفروع.

تمرينات

1

خاطئة	صحيحة	حدد الجملة الصحيحة والجملة الخاطئة فيما يلي:
<input type="radio"/>	<input checked="" type="radio"/>	1. تُنفذ خوارزمية البحث بأولوية الاتساع (BFS) وخوارزمية البحث بأولوية العمق (DFS) باستخدام الاستدعاء الذاتي.
<input type="radio"/>	<input checked="" type="radio"/>	2. لا يمكن استخدام خوارزمية البحث بأولوية الاتساع (BFS) وخوارزمية البحث بأولوية العمق (DFS) في هيكل بيانات الشجرة.
<input type="radio"/>	<input checked="" type="radio"/>	3. تُنفذ خوارزمية البحث بأولوية الاتساع (BFS) بمساعدة هيكل بيانات القائمة المترابطة.
<input type="radio"/>	<input checked="" type="radio"/>	4. يمكن تنفيذ خوارزمية البحث بأولوية العمق (DFS) بمساعدة هيكل بيانات المكدّس.
<input type="radio"/>	<input checked="" type="radio"/>	5. لا يمكن استخدام خوارزمية البحث بأولوية الاتساع (BFS) في البث الشبكي.

2


اشرح كيف تعمل خوارزمية البحث بأولوية الاتساع (BFS) وخوارزمية البحث بأولوية العمق (DFS).

3

قارن بين خوارزمية البحث بأولوية الاتساع (BFS) وخوارزمية البحث بأولوية العمق (DFS).

4

في المخطط على اليسار، انتقل من عقدة البداية A إلى عقدة الهدف G. طبق خوارزمية البحث بأولوية الاتساع (BFS) وخوارزمية البحث بأولوية العمق (DFS) باستخدام هيكل البيانات المناسب (المكدس أو الطابور)، مع الإشارة إلى العقد التي فحصت.



5

اكتب دالة بلغة البايثون تستخدم خوارزمية البحث بأولوية الاتساع (BFS) في مخطط للتحقق مما إذا كان هناك مسارٌ بين عقدتين مُعطاتين.

6

اكتب دالة بلغة البايثون تستخدم خوارزمية البحث بأولوية العمق (DFS) لإيجاد المسار الأقصر في مخطط غير موزون.

اتخاذ القرار القائم على القواعد



الأنظمة القائمة على القواعد Rule-Based Systems

تُركّز أنظمة الذكاء الاصطناعي القائمة على القواعد المحددة مُسبقاً لاتخاذ القرارات وحل المشكلات. **الأنظمة الخبيرة (Expert Systems)** هي المثال الأكثر شهرة للذكاء الاصطناعي القائم على القواعد، وهي إحدى صور الذكاء الاصطناعي الأولى التي طُورت وانتشرت في فترة الثمانينيات والتسعينيات من القرن الماضي. وغالباً ما كانت تُستخدم لأتمتة المهام التي تتطلب عادةً خبرات بشرية مثل: تشخيص الحالات الطبية أو تحديد المشكلات التقنية وإصلاحها. واليوم لم تَعُد الأنظمة القائمة على القواعد التقنية هي الأحدث، حيث تفوقت عليها منهجيات الذكاء الاصطناعي الحديثة. ومع ذلك، لا تزال الأنظمة الخبيرة شائعة الاستخدام في العديد من المجالات نظراً لقدرتها على الجمع بين الأداء المعقول وعملية اتخاذ القرار البديهية والقابلة للتفسير.

الأنظمة الخبيرة (Expert Systems)

النظام الخبير هو أحد أنواع الذكاء الاصطناعي الذي يحاكي قدرة اتخاذ القرار لدى الخبير البشري. يستخدم النظام قاعدة المعرفة المكونة من قواعد وحقائق ومحركات الاستدلال لتقديم المشورة أو حل المشكلات في مجال معين محدد.

قاعدة المعرفة Knowledge Base

أحد المكونات الرئيسية لأنظمة الذكاء الاصطناعي القائمة على القواعد هي قاعدة المعرفة، وهي مجموعة من الحقائق والقواعد التي يستخدمها النظام لاتخاذ القرارات. تدخل هذه الحقائق والقواعد في النظام بواسطة الخبراء البشريين المسؤولين عن تحديد المعلومات الأكثر أهمية وتحديد القواعد التي يتبعها النظام. لاتخاذ القرار أو حل المشكلة، يبدأ النظام الخبير بالتحقق من الحقائق والقواعد في قاعدة البيانات وتطبيقاتها على الموقف الحالي. إن لم يتمكن النظام من العثور على تطابق بين الحقائق والقواعد في قاعدة المعرفة، فقد يتطلب من المستخدم معلومات إضافية أو إحالة المشكلة إلى خبير بشري لمزيد من المساعدة، وأليك بعض مزايا وعيوب الأنظمة القائمة على القواعد موضحة في الجدول 2.5:


جدول 2.5: المزايا والعيوب الرئيسية لأنظمة القائمة على القواعد

المزايا	العيوب
<ul style="list-style-type: none"> يمكنها اتخاذ القرارات وحل المشكلات بسرعة وبدقة أفضل من البشر، خاصةً عندما يتعلق الأمر بالمهام التي تتطلب قدرًا كبيرًا من المعرفة أو البيانات. تعمل هذه الأنظمة باستمرار، دون تحييز أو أخطاء قد تؤثر في بعض الأحيان على اتخاذ القرار البشري. 	<ul style="list-style-type: none"> تعمل هذه الأنظمة بكفاءة طالما كانت مدخلات المعرفة والقواعد جيدة، وقد لا تستطيع التعامل مع المواقف التي تقع خارج خبراتها. لا يمكنها التعلم أو التكيف بالطريقة نفسها مثل البشر، وهذا يجعلها أقل قابلية للتطبيق على الأحداث المتغيرة حيث تتغير مدخلات البيانات والمنطق كثيراً بمرور الوقت.

في هذا الدرس ستعلم المزيد حول الأنظمة القائمة على القواعد في سياق أحد تطبيقاتها الرئيسية، وهو: التشخيص الطبي. سيعرض النظام تشخيصاً طبياً وفقاً للأعراض التي تظهر على المريض، كما هو موضح في الشكل 2.8. بدءاً بنظام تشخيص بسيط مستند إلى القواعد، وستكتشف بعض الأنظمة الأكثر ذكاءً وكيف يتحقق كل تكرار نتائج أفضل.

الإصدار 1

في الإصدار الأول ستبني نظاماً بسيطاً قائماً على القواعد يمكنه تشخيص ثلاثة أمراض محتملة: KidneyStones (حصى الكلى)، Appendicitis (التهاب الزائدة الدودية)، وFood Poisoning (التسمم الغذائي). ستكون المدخلات إلى النظام هي قاعدة معرفة بسيطة تربط كل مرض بقائمة من الأعراض المحتملة. يتوفّر ذلك في ملف بتنسيق JSON (جيeson) يمكنك تحميله وعرضه كما هو موضح بالأعلى.



شكل 2.8: التشخيص الطبي بواسطة نظام الذكاء الاصطناعي القائم على القواعد

```
import json # a library used to save and load JSON files

# the file with the symptom mapping
symptom_mapping_file='symptom_mapping_v1.json'

# open the mapping JSON file and load it into a dictionary
with open(symptom_mapping_file) as f:
    mapping=json.load(f)

# print the JSON file
print(json.dumps(mapping, indent=2))
```

```
{
    "diseases": {
        "food poisoning": [
            "vomiting",
            "abdominal pain",
            "diarrhea",
            "fever"
        ],
        "kidney stones": [
            "lower back pain",
            "vomiting",
            "fever"
        ],
        "appendicitis": [
            "abdominal pain",
            "vomiting",
            "fever"
        ]
    }
}
```

سيتبع الإصدار الأول القائم على القواعد قاعدة بسيطة ألا وهي: إذا كان لدى المريض على الأقل ثلاثة من جميع الأعراض المحتملة للمرض، فيجب إضافة المرض كتشخيص محتمل. يمكنك العثور أدناه على دالة Python (البايثون) التي تستخدم هذه القاعدة لإجراء التشخيص، بالاستناد إلى قاعدة المعرفة المذكورة أعلاه وأعراض المرض الظاهرة على المريض.

```
def diagnose_v1(patient_symptoms:list):

    diagnosis=[] # the list of possible diseases

    if "vomiting" in patient_symptoms:

        if "abdominal pain" in patient_symptoms:

            if "diarrhea" in patient_symptoms:

                # 1:vomiting, 2:abdominal pain, 3:diarrhea
                diagnosis.append('food poisoning')

        elif 'fever' in patient_symptoms:

            # 1:vomiting, 2:abdominal pain, 3:fever
            diagnosis.append('food poisoning')
            diagnosis.append('appendicitis')

        elif "lower back pain" in patient_symptoms and 'fever' in patient_symptoms:

            # 1:vomiting, 2:lower back pain, 3:fever
            diagnosis.append('kidney stones')

        elif "abdominal pain" in patient_symptoms and\
            "diarrhea" in patient_symptoms and\
            "fever" in patient_symptoms:\

            # 1:abdominal pain, 2:diarrhea, 3:fever
            diagnosis.append('food poisoning')

    return diagnosis
```

في هذه الحالة، تكون قاعدة المعرفة محددة بتعليمات برمجية ثابتة (Hard-Coded) داخل الدالة في شكل عبارات IF. تستخدم هذه العبارات الأعراض الشائعة بين الأمراض الثلاثة للتوصل تدريجياً إلى التشخيص في أسرع وقت ممكن. على سبيل المثال، عَرض Vomiting (القيء) مشترك بين جميع الأمراض. لذلك، إذا كانت عبارة IF الأولى صحيحة فقد تم بالفعل حساب أحد الأعراض الثلاثة المطلوبة لجميع الأمراض. بعد ذلك، ستبدأ في البحث عن Abdominal Pain (ألم البطن) المرتبط بمرضين وتستمر بالطريقة نفسها حتى يتم النظر في جميع مجموعات الأعراض الممكنة.

يمكنك بعد ذلك اختبار هذه الدالة على ثلاثة مرضى مختلفين:

Patient 1

```
my_symptoms=['abdominal pain', 'fever', 'vomiting']
diagnosis=diagnose_v1(my_symptoms)
print('Most likely diagnosis:',diagnosis)
```

Patient 2

```
my_symptoms=['vomiting', 'lower back pain', 'fever' ]
diagnosis=diagnose_v1(my_symptoms)
print('Most likely diagnosis:',diagnosis)
```

Patient 3

```
my_symptoms=['fever', 'cough', 'vomiting']
diagnosis=diagnose_v1(my_symptoms)
print('Most likely diagnosis:',diagnosis)
```

Most likely diagnosis: ['food poisoning', 'appendicitis']

Most likely diagnosis: ['kidney stones']

Most likely diagnosis: []

المريض 3	العراض:	المريض 2	العراض:	المريض 1	العراض:
	Fever (الحمى) • Cough (السعال) • Vomiting (القيء) •		Vomiting (القيء) • Lower back pain • (ألم بأسفل الظهر) Fever (الحمى) •		Abdominal pain • (ألم في البطن) Fever (الحمى) • Vomiting (القيء) •
؟	Kidney stones (حصى الكلى)				Food poisoning or Appendicitis (التسمم الغذائي أو التهاب الزائدة الدودية)

التشخيص الطبي باستخدام نظام الذكاء الاصطناعي القائم على القواعد | symptom_mapping_v1.json

شكل 2.9: تمثيل الإصدار الأول

يتضمن التشخيص الطبي للمريض الأول التسمم الغذائي والتهاب الزائدة الدودية؛ لأن الأعراض الثلاثة التي تظهر على المريض ترتبط بكل المرضى. يُشخص المريض الثاني بحصى الكلى، فهو المرض الوحيد الذي تجتمع فيه الأعراض الثلاثة. في النهاية، لا يمكن تشخيص الحالة الطبية للمريض الثالث؛ لأن الأعراض الثلاثة التي ظهرت على المريض لا تجتمع في أي من الأمراض الثلاثة.

يتميز الإصدار الأول القائم على القواعد بالبديهية والقابلية للتفسير، كما يتضمن استخدام قاعدة المعرفة والقواعد في التشخيص الطبي دون تحيز أو انحراف عن الخط المعياري. ومع ذلك، يشوب هذا الإصدار العديد من العيوب: أولاً، أن قاعدة ثلاثة أعراض على الأقل هي تمثيل مبسط للغاية لكيفية التشخيص الطبي على يد الخبرير البشري. ثانياً، أن قاعدة المعرفة داخل الدالة تكون محددة بتعليمات برمجية ثابتة، وعلى الرغم من أنه يسهل إنشاء عبارات شرطية بسيطة لقواعد المعرفة الصغيرة، إلا أن المهمة تصبح أكثر تعقيداً و تستغرق وقتاً طويلاً عند تشخيص الحالات التي تعاني من العديد من الأمراض والأعراض المرضية.

في الإصدار الثاني، ستُعزز مرونة وقابلية تطبيق النظام القائم على القواعد بتمكينه من قراءة قاعدة المعرفة المُتغيرة مباشرةً من ملف JSON (جسون). سيؤدي هذا إلى الحد من عملية الهندسة اليدوية لعبارات IF الشرطية حسب الأعراض ضمن الدالة. وهذا يُعدَّ تحسُّناً كبيراً يجعل النظام قابلاً للتطبيق على قواعد المعرفة الأكبر حجماً مع تزايد عدد الأمراض والأعراض. وفي الأسفل، مثال يوضح قاعدة المعرفة.

```
symptom_mapping_file='symptom_mapping_v2.json'

with open(symptom_mapping_file) as f:
    mapping=json.load(f)

print(json.dumps(mapping, indent=2))
```

```
{
    "diseases": {
        "covid19": [
            "fever",
            "headache",
            "tiredness",
            "sore throat",
            "cough"
        ],
        "common cold": [
            "stuffy nose",
            "runny nose",
            "sneezing",
            "sore throat",
            "cough"
        ],
        "flu": [
            "fever",
            "headache",
            "tiredness",
            "stuffy nose",
            "sneezing",
            "cough",
            "runny nose"
        ],
        "allergies": [
            "headache",
            "tiredness",
            "stuffy nose",
            "sneezing",
            "cough",
            "runny nose"
        ]
    }
}
```



شكل 2.10: الإصدار الثاني لا يحتوي على عبارات IF الشرطية المحددة بتعليمات برمجية ثابتة

قاعدة المعرفة الجديدة هذه أكبر قليلاً من سابقتها. ومع ذلك، يتضح أن محاولة إنشاء عبارات IF الشرطية في هذه الحالة ستكون أصعب بكثير. على سبيل المثال، تضمنت قاعدة المعرفة السابقة ربط أحد الأمراض بأربعة أعراض، ومرضين بثلاثة أعراض. وعند تطبيق قاعدة ثلاثة أعراض على الأقل المُطبقة في الإصدار الأول، تحصل على 6 مجموعات ثلاثة من الأعراض المحتملة التي تؤخذ في الاعتبار. في قاعدة المعرفة الجديدة بالأعلى، تكون للأمراض الأربع 5 و 8 و 6 أعراض، على التوالي. وبهذا، تحصل على 96 مجموعة ثلاثة من الأعراض المحتملة. وفي حال التعامل مع مئات أو حتىآلاف الأمراض، ستجدُ أنه من المستحيل إنشاء نظام مثل الموجود في الإصدار الأول.

وكذلك، لا يوجد سبب طبي وجيه لقصر التشخيص الطبي على مجموعات ثلاثة من الأعراض. ولذلك، ستجعل منطق التشخيص (Diagnosis Logic) أكثر تنوعاً بحساب عدد الأعراض المُطابقة لكل مرض، والسماح للمستخدم بتحديد عدد الأعراض المُطابقة التي يجب توافرها في المرض لتضمينه في التشخيص.

```

def diagnose_v2(patient_symptoms:list,
                symptom_mapping_file:str,
                matching_symptoms_lower_bound:int):

    diagnosis=[]

    with open(symptom_mapping_file) as f:
        mapping=json.load(f)

        # access the disease information
        disease_info=mapping['diseases']

        #for every disease
        for disease in disease_info:

            counter=0

            disease_symptoms=disease_info[disease]

            #for each patient symptom
            for symptom in patient_symptoms:

                # if this symptom is included in the known symptoms for the disease
                if symptom in disease_symptoms:

                    counter+=1

            if counter>=matching_symptoms_lower_bound:
                diagnosis.append(disease)

    return diagnosis

```

لا يحتوي هذا الإصدار على عبارات IF الشرطية المحددة بتعليمات برمجية ثابتة. بعد تحميل مُخطط الأعراض من ملف JSON (جسون)، يبدأ الإصدار فيأخذ كلّ مرض محتمل في الاعتبار باستخدام حلقة التكرار الأولى FOR. تتحقق الحلقة من كل عَرض على حدة بمقارنته بالأعراض المعروفة للمرض وزيادة العَدَاد (Counter) في كل مرة يجد فيها النظام تطابقاً.



```


# Patient 1
my_symptoms=[ "stuffy nose", "runny nose", "sneezing", "sore throat"]
diagnosis=diagnose_v2(my_symptoms,'symptom_mapping_v2.json' , 3)
print('Most likely diagnosis:',diagnosis)

# Patient 2
my_symptoms=[ "stuffy nose", "runny nose", "sneezing", "sore throat"]
diagnosis=diagnose_v2(my_symptoms, 'symptom_mapping_v2.json' , 4)
print('Most likely diagnosis:',diagnosis)

# Patient 3
my_symptoms=[ 'fever', 'cough', 'vomiting']
diagnosis=diagnose_v2(my_symptoms, 'symptom_mapping_v2.json' , 3)
print('Most likely diagnosis:',diagnosis)

```

Most likely diagnosis: ['common cold', 'flu', 'allergies']
 Most likely diagnosis: ['common cold']
 Most likely diagnosis: []



شكل 2.11: تمثيل الإصدار الثاني

لاحظ أن الإصدار الثاني هو نسخة مُعممة من الإصدار الأول. ومع ذلك، يُعدُّ هذا الإصدار أكثر قابلية للتطبيق على نطاق واسع، ويمكن استخدامه كما هو مع أي قاعدة معرفة أخرى بالتنسيق نفسه، حتى لو كانت تشمل الآلاف من الأمراض مع عدد ضخم من الأعراض. كما يسمح للمستخدم بزيادة أو تقليل عدد القيود على التشخيص بضبط المُتغير matching_symptoms_lower_bound. يمكن ملاحظة ذلك في حالة المريض 1 والمريض 2: فعلى الرغم من أنهما يعانيان من الأعراض نفسها، إلا أنه عند ضبط هذا المُتغير، ستحصل على تشخيص مختلف تماماً.

على الرغم من هذه التحسينات، إلا أن بعض العيوب لا تزال موجودة في هذا الإصدار، ولا يُعدُّ تمثيلاً دقيقاً للتشخيص الطبيعي الحقيقي.

في الإصدار الثالث، ستزيد من ذكاء النظام القائم على القواعد بمنحه إمكانية الوصول إلى نوع مفصل من قاعدة المعرفة. هذا النوع الجديد يأخذ بعين الاعتبار الحقيقة الطبية التي تقول: إن بعض الأعراض تكون أكثر شيوعاً من أخرى للمرض نفسه.

```
symptom_mapping_file='symptom_mapping_v3.json'

with open(symptom_mapping_file) as f:
    mapping=json.load(f)

print(json.dumps(mapping, indent=2))
```

```
{
    "diseases": {
        "covid19": {
            "very common": [
                "fever",
                "tiredness",
                "cough"
            ],
            "less common": [
                "headache",
                "sore throat"
            ]
        },
        "common cold": {
            "very common": [
                "stuffy nose",
                "runny nose",
                "sneezing",
                "sore throat"
            ],
            "less common": [
                "cough"
            ]
        },
        "flu": {
            "very common": [
                "fever",
                "headache",
                "tiredness",
                "sore throat",
                "cough"
            ],
            "less common": [
                "stuffy nose",
                "sneezing",
                "runny nose"
            ]
        },
        "allergies": {
            "very common": [
                "stuffy nose",
                "sneezing",
                "runny nose"
            ],
            "less common": [
                "headache",
                "tiredness",
                "cough"
            ]
        }
    }
}
```

لن يُنظر إلى المنطق الذي يقتصر على عدد الأعراض، وسيُستبدل بدالة تسجيل النقاط التي تعطي أوزانًا مُخصصة للأعراض الأكثر والأقل شيوعاً. ستتوفر للمستخدم كذلك المرونة لتحديد الأوزان التي يراها مناسبة. سيتّم تضمين المرض أو الأمراض ذات المجموع الموزون الأعلى في التشخيص.

```
from collections import defaultdict

def diagnose_v3(patient_symptoms:list,
                 symptom_mapping_file:str,
                 very_common_weight:float=1,
                 less_common_weight:float=0.5
                 ):

    with open(symptom_mapping_file) as f:
        mapping=json.load(f)

    disease_info=mapping[ 'diseases' ]

    # holds a symptom-based score for each potential disease
    disease_scores=defaultdict(int)

    for disease in disease_info:

        # get the very common symptoms of the disease
        very_common_symptoms=disease_info[disease][ 'very common' ]

        # get the less common symptoms for this disease
        less_common_symptoms=disease_info[disease][ 'less common' ]

        for symptom in patient_symptoms:

            if symptom in very_common_symptoms:
                disease_scores[disease]+=very_common_weight

            elif symptom in less_common_symptoms:
                disease_scores[disease]+=less_common_weight

    # find the max score all candidate diseases
    max_score=max(disease_scores.values())

    if max_score==0:
        return []

    else:
        # get all diseases that have the max score
        diagnosis=[disease for disease in disease_scores if disease_scores[disease]==max_score]

    return diagnosis, max_score
```

لكل مرض محتمل في قاعدة المعرفة، تُحدّد هذه الدالة الجديدة الأعراض الأكثر والأقل ظهوراً على المريض، ثم تزيد من درجة المرض وفقاً للأوزان المُقابلة، وفي الأخير تدرج الأمراض ذات الدرجة الأعلى في التشخيص. يمكنك الآن اختبار تنفيذ الدالة مع بعض الأمثلة:

Patient 1

```
my_symptoms=[ "headache", "tiredness", "cough"]
diagnosis=diagnose_v3(my_symptoms, 'symptom_mapping_v3.json')
print('Most likely diagnosis:',diagnosis)
```


Patient 2

```
my_symptoms=[ "stuffy nose", "runny nose", "sneezing", "sore throat"]
diagnosis=diagnose_v3(my_symptoms, 'symptom_mapping_v3.json')
print('Most likely diagnosis:',diagnosis)
```

Patient 3

```
my_symptoms=[ "stuffy nose", "runny nose", "sneezing", "sore throat"]
diagnosis=diagnose_v3(my_symptoms, 'symptom_mapping_v3.json', 1, 1)
print('Most likely diagnosis:',diagnosis)
```

Most likely diagnosis: (['flu'], 3)
 Most likely diagnosis: (['common cold'], 4)
 Most likely diagnosis: (['common cold', 'flu'], 4)



شكل 2.12: تمثيل الإصدار الثالث

قد تلاحظ أنه على الرغم من أن الأعراض الثلاثة على المريض 1: Headache (الصداع)، و Tiredness (الإعياء)، و Cough (السعال) تظهر عند الإصابة بكل من Flu (الإنفلونزا)، و Covid19 (كوفيد-19). والحساسية، إلا أن الظاهر في نتائج التشخيص هي الإنفلونزا فقط. هذا لأن جميع الأعراض الثلاثة شائعة جداً في قاعدة المعرفة، مما يؤدي إلى درجة قصوى قدرها 3. وبالمثل، في ظل معاناة المريض الثاني والثالث من الأعراض نفسها، تؤدي مدخلات الأوزان المختلفة للأعراض الأكثر والأقل شيوعاً إلى تشخيصات مختلفة. وعلى وجه التحديد، ينبع عن استخدام وزن متساوٍ لنوعين من الأعراض إضافة الإنفلونزا إلى التشخيص.

يمكن تحسين النظام القائم على القواعد بزيادة كفاءة قاعدة المعرفة وتجربة دوال تسجيل النقاط (Scoring Functions) المختلفة. وعلى الرغم من أن ذلك سيؤدي إلى تحسين النظام، إلا أنه يتطلب الكثير من الوقت والجهد اليدوي. ولحسن الحظ، هناك طريقة آلية لبناء نظام مبني على القواعد يكون ذكيًا بما يكفي لتصميم قاعدة معرفة ودالة تسجيل نقاط خاصة به: باستخدام تعلم الآلة. يُطبق تعلم الآلة القائم على القواعد (Rule-Based Machine Learning) خوارزمية تعلم لتحديد القواعد المقيدة تلقائياً، بدلاً من الحاجة إلى الإنسان لتطبيق المعرفة والخبرات السابقة في المجال لبناء القواعد وتنظيمها يدوياً.

فبدلاً من قاعدة المعرفة ودالة تسجيل النقاط المصممتان يدوياً، تتوقع خوارزمية تعلم الآلة مدخلًا واحدًا فقط وهو مجموعة البيانات التاريخية للحالات المرضية. فالتعلم من البيانات مباشرةً يحول دون حدوث المشكلات المرتبطة باكتساب المعرفة الأساسية والتحقق منها. تكون كل حالة من بيانات أعراض المريض والتشخيص الطبي الذي يمكن أن يقدمه أي خبير بشري مثل الطبيب. وباستخدام مجموعة بيانات التدريب، تعلم الخوارزمية تلقائياً كيف تتنبأ بالتشخيص المحتمل لحالة مريض جديد.

```
import pandas as pd # import pandas to load and process spreadsheet-type data

medical_dataset=pd.read_csv('medical_data.csv') # load a medical dataset.

medical_dataset
```

	fever	cough	tiredness	headache	stuffy nose	runny nose	sneezing	sore throat	diagnosis
0	1	1	1	0	0	0	0	0	covid19
1	0	1	1	1	0	0	0	0	covid19
2	1	1	1	0	0	0	0	0	covid19
3	1	1	1	0	0	0	0	0	covid19
4	1	1	1	0	0	0	0	0	covid19
...
1995	0	1	0	0	1	0	1	1	common cold
1996	0	0	0	1	1	1	1	0	common cold
1997	0	0	1	0	1	0	0	1	common cold
1998	0	0	0	0	1	0	0	1	common cold
1999	0	1	0	0	0	0	1	1	common cold

في المثال أعلاه، تحتوي مجموعة البيانات على 2,000 حالة مرضية، بحيث تكون كل حالة من 8 أعراض محتملة: Fever (الحمى)، وCough (السعال)، وTiredness (الإعياء)، وHeadache (الصداع)، وStuffy nose (انسداد الأنف)، وRunny nose (رشح الأنف)، وSneezing (العطاس)، وSore throat (التهاب الحلق). ترمز كل واحدة من هذه الأعراض في عمود ثالثي مُنفصل. العدد الثاني 1 يشير إلى أن المريض يعاني من الأعراض، بينما العدد الثاني 0 يشير إلى أن المريض لا يعاني من الأعراض.

يحتوي العمود الأخير على تشخيص الخبير البشري، وهناك أربعة تشخيصات محتملة: Covid19 (كوفيد - 19)، وFlu (الإنفلونزا)، وAllergies (الحساسية)، وCommon cold (نزلات البرد). يمكنك التحقق من ذلك بسهولة باستخدام المقطع البرمجي التالي بلغة البايثون:

```
set(medical_dataset['diagnosis'])
```

على الرغم من أن هناك العشرات من خوارزميات تعلم الآلة المحتملة التي يمكن استخدامها مع مجموعة البيانات هذه، إلا أنك ستستخدم تلك التي تتبع المنهجية المستندة على منطق شجرة القرار (Decision Tree)، كما ستستخدم مصنف شجرة القرار (DecisionTreeClassifier) من مكتبة البايثون سكيلر (Sklearn) على وجه التحديد.

```
from sklearn.tree import DecisionTreeClassifier

def diagnose_v4(train_dataset:pd.DataFrame):

    # create a DecisionTreeClassifier
    model=DecisionTreeClassifier(random_state=1)

    # drop the diagnosis column to get only the symptoms
    train_patient_symptoms=train_dataset.drop(columns=['diagnosis'])

    # get the diagnosis column, to be used as the classification target
    train_diagnoses=train_dataset['diagnosis']

    # build a decision tree
    model.fit(train_patient_symptoms, train_diagnoses)

    # return the trained model
    return model
```

يُعد تطبيق البايثون في الإصدار الرابع أقصر وأبسط بكثير من التطبيقات السابقة، فهو ببساطة يقرأ الملف التدريبي، ويستخدمه لبناء نموذج شجرة القرار استناداً إلى العلاقات بين الأعراض والتشخيصات، ومن ثم ينتج نموذجاً مخصصاً. لاختبار هذا الإصدار بشكل صحيح، ابدأ بتقسيم مجموعة البيانات إلى مجموعتين منفصلتين، واحدة للتدريب، وأخرى للاختبار.

```
from sklearn.model_selection import train_test_split

# use the function to split the data, get 30% for testing and 70% for training.
train_data, test_data = train_test_split(medical_dataset, test_size=0.3,
                                         random_state=1)

#print the shapes (rows x columns) of the two datasets
print(train_data.shape)
print(test_data.shape)
```

```
(1400, 9)
(600, 9)
```

لديك الآن 1,400 نقطة بيانات ستستخدم لتدريب النموذج و600 نقطة ستستخدم لاختباره.

ابداً بتدريب نموذج شجرة القرار وتمثيله:

```
from sklearn.tree import plot_tree
import matplotlib.pyplot as plt


my_tree=diagnose_v4(train_data) #train a model

print(my_tree.classes_) #print the possible target labels (diagnoses)

plt.figure(figsize=(12,6)) #size of the visualization, in inches

#plot the tree
plot_tree(my_tree,
          max_depth=2,
          fontsize=10,
          feature_names=medical_dataset.columns[:-1]
         )
```

['allergies' 'common cold' 'covid19' 'flu']



شكل 2.13: نموذج شجرة القرار لمجموعة بيانات medical_data (البيانات-الطبية) بعمق مرتفين

تُستخدم دالة `plot_tree()` لرسم وعرض شجرة القرار. ولعدم توفر مساحة كافية للعرض سيتم تمثيل المستويين الأولين فقط، بالإضافة إلى الجذر. يمكن ضبط هذا الرقم بسهولة باستخدام المُتغير `max_depth`.


```
# plot the tree
```

```
plot_tree(my_tree,
          max_depth=2,
          fontsize=10)
```


عمق
شجرة القرار.

```
fever <= 0.5
gini = 0.75
samples = 1400
value = [354, 345, 358, 343]
```

كل عقدة في الشجرة تمثل مجموعة فرعية من المرضى، فعلى سبيل المثال، تمثل عقدة الجذر إجمالي عدد 1,400 مريض في مجموعة بيانات التدريب. من بينهم، 354، 345، 358، و 343 شخصوا بـ Allergies (الحساسية)، و Common cold (نزلات البرد)، و Covid19 (كوفيد-19)، و Flu (الإنفلونزا)، على التوالي.



بنيت الشجرة باستخدام نمط من الأعلى إلى الأسفل عبر التفرع الثنائي (Binary Splits). يستند التفرع الأول إلى ما إذا كان المريض يعاني من الحمى أم لا. ونظرًا لأن كل خصائص الأعراض ثنائية، يكون التحقق $a \leq 0.5$ صحيحاً إذا لم يكن المريض يعاني من الأعراض. أما المرضى الذين لا يعانون من الحمى (المسار الأيسر) يتفرّعون مرة أخرى بناءً على ما إذا كانوا يعانون من التهاب الحلق أم لا. المرضى الذين لا يعانون من التهاب الحلق يتفرّعون بناءً على ما إذا كانوا يعانون من رشح الأنف أم لا. في هذه المرحلة، تحتوي العقدة على 526 حالة. تم تشخيص 354، 101، و 58، و 13 من بينهم بالحساسية، ونزلات البرد، وكوفيد-19، والإإنفلونزا، على التوالي.



يقيس مؤشر جيني (Gini Index) الشوائب بالعقدة، وبالتالي تحديد احتمالية تصنيف محتويات العقدة بصورة خاصة. يشير انخفاض معامل جيني إلى ارتفاع درجة تأكيد الخوارزمية من التصنيف.

يستمر التفرع حتى تحدّد الخوارزمية الحالات التي انقسمت بالفعل إلى عقد نقيّة تماماً. العقدة النقيّة بالكامل تحتوي على الحالات التي لها التشخيص نفسه. قيم مؤشر gini (جيني) المحددة على كل عقدة، تمثل مؤشرات على مقياس جيني، وهي صيغة شهيرة تُستخدم لتقدير درجة نقائص العقدة.

ستستخدم الآن شجرة القرارات للتنبؤ بالتشخيص الأكثر احتمالاً للمريض في مجموعة الاختبار.

تُستخدم مجموعة الاختبار لتقييم أداء النموذج. تستند طريقة التقييم الدقيقة على ما إذا كان المقصود من المهمة الانحدار (Regression) أم التصنيف (Classification). في مثل مشكلات التصنيف المعروضة هنا، تُستخدم طرائق التقييم الشهيرة مثل: حساب دقة النموذج (Model's Accuracy) ومصفوفة الدقة (Confusion Matrix).

- الدقة هي نسبة التنبؤات الصحيحة التي يقوم بها المصنف. تتحقق دقة عالية قريبة من 100% يعني أن معظم التنبؤات التي يقوم بها المصنف صحيحة.
- مصفوفة الدقة هي جدول يقارن بين القيم الحقيقية (الفعالية) وبين التنبؤات التي يقوم بها المصنف في مجموعة البيانات. يحتوي الجدول على صف واحد لكل قيمة صحيحة وعمود واحد لكل قيمة متوقعة. كل مدخل في المصفوفة يمثل عدد الحالات التي لها قيم فعلية ومتوقعة.

```
# functions used to evaluate a classifier
from sklearn.metrics import accuracy_score,confusion_matrix

# drop the diagnosis column to get only the symptoms
test_patient_symptoms=test_data.drop(columns=['diagnosis'])

# get the diagnosis column, to be used as the classification target
test_diagnoses=test_data['diagnosis']

# guess the most likely diagnoses
pred=my_tree.predict(test_patient_symptoms)

# print the achieved accuracy score
accuracy_score(test_diagnoses,pred)
```

0.8166666666666667

ستلاحظ أن شجرة القرارات تحقق دقة تصل إلى 81.6%， وهذا يعني أنه من بين 600 حالة تم اختبارها، شخصت الشجرة 490 منها بشكل صحيح. يمكنك كذلك طباعة مصفوفة الدقة للنموذج لاستعراض بشكل أفضل الأمثلة المصنفة بشكل خاطئ.

```
confusion_matrix(test_diagnoses,pred)
```

```
array([[143,    3,    0,    0],
       [ 48,   98,    5,    4],
       [  2,    1, 127,   12],
       [  1,    3,   31, 122]])
```

الإنفلونزا المتوقعة	كوفيد-19 المتوقعة	نزلات البرد المتوقعة	الحساسية المتوقعة	
الحساسية الفعلية	143	3	0	0
نزلات البرد الفعلية	48	98	5	4
كوفيد-19 الفعلي	2	1	127	12
الإنفلونزا الفعلية	1	3	31	122

شكل 2.14: مصفوفة الدقة للحالات المتوقعة وال الحالات الفعلية

الأرقام الواقعة في الخط القُطري (المُظللة باللون الوردي) تمثل الحالات المتوقعة بشكل صحيح، أما الأرقام التي تقع خارج الخط القُطري فتمثل أخطاء النموذج.

على سبيل المثال، بالنظر إلى ترتيب التصنيفات الأربع المُحتملة [Allergies (الحساسية)، Common cold (نزلات البرد)، Covid19 (كوفيد-19)، Flu (الإنفلونزا)]، توضح المصفوفة أن النموذج أخطأ في تصنيف 48 حالة من المصابين بنزلات البرد بأنهم مصابون بالحساسية، كما أخطأ في تصنيف 31 حالة من المصابين بالإنفلونزا بأنهم مصابون بكوفيد-19.

وعلى الرغم من أن هذا النموذج ليس مثالياً، فمن المثير للدهشة أنه قادر على تحقيق مثل هذه الدرجة العالية من الدقة بتعلم مجموعة القواعد الخاصة به، دون الحاجة إلى قاعدة معرفة أنشئت يدوياً. بالإضافة إلى تحقيق مثل هذه الدقة دون محاولة ضبط متغيرات الأداء المتوقعة لـ DecisionTreeClassifier (مصنف شجرة القرار). وبالتالي، يمكن تحسين دقة النموذج لأفضل من ذلك. كما يمكن تحسين النموذج بتجاوز قيود النموذج القائم على القواعد وتجربة أنواع مختلفة من خوارزميات تعلم الآلة. وستتعلم بعض هذه الطرائق في الوحدة التالية.

تمرينات

اذكر بعض مزايا وعيوب الأنظمة القائمة على القواعد.

1

ما مزايا وعيوب الإصدار الأول؟

2

أضف إلى المقطع البرمجي الخاص بالإصدار الأول لنظام قائم على القواعد مريضاً يعاني من الأعراض التالية [القيء Vomiting، آلام البطن Abdominal pain، Diarrhea (الإسهال)، Fever (الحمى)، Lower back pain (ألم بأسفل الظهر)]. ما التشخيص الطبي لحالة المريض؟ دون ملاحظاتك بالأمثلة.

3

4

في الإصدار الثاني، كم عدد الأمراض الموضحة في تشخيص كل مريض إذا غيرت قيمة المتغير `matching_symptoms_lower_bound` إلى 2 و 3 و 4؟

5

في الإصدار الثالث، غير كلا الوزنين إلى 1 للمريضين الأول والثاني، تماماً مثل المريض الثالث.
تعديل المقطع البرمجي ثم دون ملاحظاتك.

6

صف بيايجاز كيف يمكن تحسين كل إصدار بالنسبة للإصدار السابق له (الأول إلى الثاني، والثاني إلى الثالث، والثالث إلى الرابع).

خوارزميات البحث المستنيرة



تطبيقات خوارزميات البحث

Applications of Search Algorithms

خوارزميات البحث هي أحد المكونات الرئيسية لأنظمة الذكاء الاصطناعي، فباستخدامها يمكن اكتشاف الاحتمالات المختلفة لإيجاد الحلول المناسبة للمشكلات المعقدة في العديد من التطبيقات السائدة. وفيما يلى أمثلة على بعض تطبيقات خوارزميات البحث:

- **الروبوتية (Robotics)**: قد يستخدم الروبوت خوارزمية البحث لتحديد طريقه عبر المتابعة أو لتحديد موقع أحد الكائنات في نطاق بيته.
 - **مواقع التجارة الإلكترونية (E-Commerce Websites)**: تستخدم مواقع التسوق عبر الإنترنت خوارزميات البحث لـ**لِتُطابق** بين استفسارات العملاء وبين المنتجات المتوفرة، ولتصفيّة نتائج البحث وفق بعض المعايير مثل: السعر، والعلامة التجارية، والتقييمات، واقتراح المنتجات ذات الصلة.
 - **منصات مواقع التواصل الاجتماعي (Social Media Platforms)**: تستخدم مواقع التواصل الاجتماعي خوارزميات البحث لعرض التدوينات، والأشخاص، والمجموعات للمستخدمين وفقاً للكلمات المفتاحية واهتمامات المستخدم.
 - **تمكين الآلة من ممارسة الألعاب بمستوى عالي من المهارة (Enabling a Machine to Play Games at a High Skill Level)**: يستخدم الذكاء الاصطناعي خوارزمية البحث أثناء لعب الشطرنج أو قو (Go) لتقييم الحركات المختلفة و اختيار الخطوات التي من المرجح أن تؤدي إلى الفوز.
 - **نظم الملاحة باستخدام محدد الموقع العالمي (GPS Navigation Systems)**: تستخدم نظم الملاحة القائمة على محدد الموقع العالمي خوارزميات البحث لتحديد أقصر وأسرع طريق بين موقعين، مع مراعاة بيانات حركة المرور في الوقت الحالي.
 - **نظم إدارة الملفات (File Management Systems)**: تستخدم خوارزميات البحث في نظم إدارة الملفات لتحديد موقع الملفات باستخدام اسم، ومحظى الملف، وبعض السمات الأخرى.

أنواع خوارزميات البحث وأمثلتها

هناك نوعان رئيسان من خوارزميات البحث وهما: غير المستنيرة (Uninformed) والمستنيرة (Informed).

خوارزميات البحث غير المستنيرة Uninformed Search Algorithms

خوارزميات البحث غير المستنيرة، وتسمى أيضاً: خوارزميات البحث العميق، وهي تلك التي لا تحتوي على معلومات إضافية حول حالات المشكلة باستثناء المعلومات المستفادة من تعريف المشكلة. وتقوم هذه الخوارزميات بإجراء فحص شامل لمساحة البحث استناداً إلى مجموعة من القواعد المحددة مسبقاً. وتُعد تقنيات البحث بأولوية الاتساع (BFS) والبحث بأولوية العمق (DFS) المشار إليها في الدرس الثاني أمثلة على خوارزميات البحث غير المستنيرة.

على سبيل المثال، تبدأ خوارزمية البحث بأولوية العمق (DFS) عند عُقدة الجذر بالشجرة أو المُخطّط وتتوسّع حتى تصل للعقد الأعمق التي لم تُفحَص. ويستمر الأمر بهذه الطريقة حتى تستنفد الخوارزمية مساحة البحث بأكملها بعد فحص كل العُقد المتاحة. ثم تُخرج الحل الأمثل الذي وجدته أثناء البحث. فالحقيقة أن خوارزمية البحث بأولوية العمق (DFS) تتبع دوماً هذه القواعد ولا يمكن ضبط استراتيجيتها بصرف النظر عن نتائج البحث، وهذا ما يجعلها خوارزمية غير مستنيرة.

ومثال آخر ملحوظ على هذا النوع من الخوارزميات هو خوارزمية البحث بأولوية العمق التكراري المُعمّق (Iterative Deepening Depth-First Search - IDDFS) التي يمكن اعتبارها مزيجاً بين خوارزميتي البحث بأولوية العمق (DFS) والبحث بأولوية الاتساع (BFS)، فهي تُستخدم استراتيجية العُمق أولاً للبحث في جميع الخيارات الموجودة في النطاق الكامل بصورة متكررة حتى تصل إلى عُقدة مُحدّدة.

الدالة الاستدلالية (Heuristic Function)

هي الدالة التي تُصنّف البدائل في خوارزميات البحث عند كل مرحلة فرعية استناداً إلى تقديرات استدلالية مبنية على البيانات المتوفرة لتحديد الفرع الذي ستسلكه.


خوارزميات البحث المستنيرة Informed Search Algorithms

على النقيض من خوارزميات البحث غير المستنيرة، تُستخدم خوارزميات البحث المستنيرة المعلومات حول المشكلة ومساحة البحث لتوجيه عملية البحث. والأمثلة على هذه الخوارزميات تشمل:

- خوارزمية البحث بأولوية الأفضل (A^* search) تُستخدم دالة استدلالية لتقدير المسافة بين كل عُقدة من العُقد المرشحة والعُقدة المستهدفة. ثم توسيع العُقدة المرشحة بالتقدير الأقل. إن فعالية خوارزمية البحث بأولوية الأفضل (A^* search) مرتبطة بجودة دالتها الاستدلالية. على سبيل المثال، إذا كنت تضمن أن الاستدلال لن يتجاوز المسافة الفعلية إلى الهدف، وبالتالي ستتعثر الخوارزمية على الحل الأمثل. بخلاف ذلك، قد لا يكون الحل الناتج من الخوارزمية هو الأفضل.
- خوارزمية ديڪسترا (Dijkstra's Algorithm) توسيع العُقدة بناء على أقصر مسافة فعلية إلى الهدف في كل خطوة. ولذلك، على النقيض من خوارزمية البحث بأولوية الأفضل، تحسب خوارزمية ديڪسترا (Dijkstra) المسافة الفعلية ولا تُستخدم التقديرات الاستدلالية. وبينما يجعل هذا خوارزمية ديڪسترا أبطأ من خوارزمية البحث بأولوية الأفضل، إلا أن ذلك يعني ضمان العثور على الحل الأمثل دوماً (ممثلاً بالمسار الأقصر من البداية حتى الهدف).
- خوارزمية تسلق التلال (Hill Climbing) تبدأ بتوليد حل عشوائي، ثم تحاول تحسين هذا الحل بصورة متكررة بإجراء تغييرات بسيطة تُحسن من دالة استدلالية مُحدّدة. وبالرغم من أن هذه المنهجية لا تضمن إيجاد الحل الأمثل، إلا أنها سهلة التنفيذ وتتميز بفعالية كبيرة عند تطبيقها على أنواع معينة من المشكلات.

الخلايا ذات اللون البنفسجي هي الخلايا التي تم فحصها، والخلية ذات اللون الأخضر وهي موضع البدء، وال الخلية ذات اللون الأحمر هي موقع الهدف، بينما الخلايا ذات اللون الأصفر تمثل المسار الذي تم العثور عليه.

خوارزمية ديڪسترا (Dijkstra's Algorithm)




خوارزمية البحث بأولوية الأفضل (A^* search)



شكل 2.16: حل المتأهله نفسها باستخدام خوارزمية البحث بأولوية الأفضل وخوارزمية ديڪسترا

في هذه الوحدة، ستشاهد بعض الأمثلة المرئية وتطبيقات البالىشون على خوارزمية البحث بأولوية الاتساع (BFS) وخوارزمية البحث بأولوية الأفضل (A* search) لمعرفة الاختلافات بين خوارزميتي البحث المستيرة وغير المستيرة.



شكل 2.17: لُغز متاهة بسيط


إنشاء الغاز المتاهة بواسطة البالىشون

Creating Maze Puzzles in Python

تُعرَّف المتاهة في صورة إطار شبكي 3×3 .

يُحدَّد موضع البداية بنجمة في أسفل يسار المتاهة. الهدف هو الوصول إلى الخلية المستهدفة المُحدَّدة بالعلامة X، ويمكن لللاعب الانتقال إلى أي خلية فارغة مجاورة لموقعه الحالي.

تكون الخلية فارغة إذا لم تحتوي على عائق. على سبيل المثال، المتاهة الموضحة في شكل 2.17 تحتوي على 3 خلايا تشغُّلها الحواجز (Blocks). هذه الحواجز الملونة باللون الرمادي تشكِّل عائقاً يجب على اللاعب تجاوزه للوصول إلى الهدف X، ويمكن لللاعب الانتقال بشكل أفقي أو رأسي أو قطري إلى أي خلية فارغة مجاورة لموقعه الحالي كما يظهر في الشكل 2.18، على سبيل المثال:



شكل 2.18: يمكن لللاعب الانتقال بشكل أفقي أو رأسي أو قطري إلى أي خلية فارغة مجاورة لموقعه الحالي

```
import numpy as np

# create a numeric 3 x 3 matrix full of zeros.
small_maze=np.zeros((3,3))

# coordinates of the cells occupied by blocks
blocks=[(1, 1), (2, 1), (2, 2)]

for block in blocks:
    # set the value of block-occupied cells to be equal to 1
    small_maze[block]=1

small_maze
```

```
array([[0., 0., 0.],
       [0., 1., 0.],
       [0., 1., 1.]])
```

الهدف هو إيجاد المسار الأقصر والأقل عدداً مرات فحص الخلايا. وبالرغم من أن المتاهة الصغيرة 3×3 قد تبدو بسيطة لللاعب البشري، إلا أنه يتوجب على الخوارزمية الذكية إيجاد حلول للتعامل مع المتاهات الكبيرة والمعقدة للغاية، مثل: متاهة $10,000 \times 10,000$ التي تحتوي على ملايين الحواجز الموزعة في أشكال مُعَقَّدة ومتنوعة.

يمكن استخدام المقطع البرمجي التالي بلغة البالىشون لإنشاء مجموعة بيانات تُصور المثال المُوضَّح في الشكل 2.18.

في هذا التمثيل الرقمي للمتاهة، تمثل الخلايا الفارغة بالأصفار (Zeros) والمشغولة بالأحاد (Ones). يمكن تحدث المقطع البرمجي نفسه بسهولة لإنشاء متاهات كبيرة ومحضدة للغاية، مثل:

```
import random

random_maze=np.zeros((10,10))

# coordinates of 30 random cells occupied by blocks
blocks=[(random.randint(0,9),random.randint(0,9)) for i in range(30)]

for block in blocks:
    random_maze[block]=1
```


تُستخدم الدالة التالية لتمثيل المتاهة:

```
import matplotlib.pyplot as plt # library used for visualization

def plot_maze(maze):
    ax = plt.gca()           # create a new figure
    ax.invert_yaxis()        # invert the y-axis to match the matrix
    ax.axis('off')           # hide the axis labels
    ax.set_aspect('equal')   # make sure the cells are rectangular

    plt.pcolormesh(maze, edgecolors='black', linewidth=2,cmap='Accent')
    plt.show()

plot_maze(random_maze)
```



شكل 2.19: تمثيل متاهة 10×10 باستخدام حواجز عشوائية

الربعات السوداء
مشغولة بالحواجز ولا يمكن
اجتيازها.

الربعات الخضراء
فارغة ويمكن
اجتيازها.

يمكن استخدام الدالة التالية لاستدعاء قائمة تحتوي على كل الخلايا الفارغة والمجاورة لخلية محددة في أي متاهة:

```
def get_accessible_neighbors(maze:np.ndarray, cell:tuple):

    # list of accessible neighbors, initialized to empty
    neighbors=[]

    x,y=cell

    # for each adjacent cell position
    for i,j in [(x-1,y-1),(x-1,y),(x-1,y+1),(x,y-1),(x,y+1),(x+1,y-1),(x+1,y),(x+1,y+1)]:

        # if the adjacent cell is within the bounds of the grid and is not occupied by a block
        if i>=0 and j>=0 and i<len(maze) and j<len(maze[0]) and
maze[(i,j)]==0:


            neighbors.append(((i,j),1))

    return neighbors
```

x-1, y-1	x-1, y	x-1, y+1
x, y-1	x, y	x, y+1
x+1, y-1	x+1, y	x+1, y+1


يفترض هذا التطبيق أن كل عملية انتقال من خلية إلى أخرى مجاورة سواءً أفقياً أو رأسياً أو قطرياً يتم بتكلفة مقدارها وحدةً واحدةً فقط. سيتم إعادة النظر في هذه الفرضية في وقت لاحق من هذا الدرس بعرض حالات أكثر تعقيداً مع شروط انتقال مُتغيرة.

تُستخدم كل خوارزميات البحث دالة `get_accessible_neighbors()` في محاولة حل المتاهة. في الأمثلة التالية تُستخدم المتاهة 3×3 المصممة بالأعلى للتحقق من أن الدالة تستدعي الخلية الصحيحة الفارغة والمجاورة للخلية المحددة.



```
# this cell is the northwest corner of the grid and has only 2 accessible neighbors
get_accessible_neighbors(small_maze, (0,0))
```

```
[((0, 1), 1), ((1, 0), 1)]
```



```
# the starting cell (in the southwest corner) has only 1 accessible neighbor
get_accessible_neighbors(small_maze, (2,0))
```

```
[((1, 0), 1)]
```



بعد أن تعلمت كيفية إنشاء المتاهات، وكذلك استدعاء الخلايا المجاورة لأي خلية في المتاهة، فإن الخطوة التالية هي تطبيق خوارزميات البحث التي يمكنها حل المتاهة من خلال إيجاد المسار الأقصر من خلية البداية إلى خلية الهدف المحددة.

شكل 2.20: الخلايا المجاورة

استخدام خوارزمية البحث بأولوية الاتساع في حل الغاز المتجاهة

Using BFS to Solve Maze Puzzles

تُستخدم دالة `bfs_maze_solver()` المشار إليها في هذا الجزء خوارزمية البحث بأولوية الاتساع (BFS) لحل الغاز المتجاهة باستخدام خلية البداية وخليه الهدف. يستخدم هذا النموذج دالة `get_accessible_neighbors()` المحددة بالأعلى لاستدعاء الخلايا المجاورة التي يمكن فحصها عند أي نقطة أثناء البحث، وبمجرد عثور خوارزمية البحث بأولوية الاتساع (BFS) على الخلية الهدف، سُتستخدم دالة `reconstruct_shortest_path()` الموضحة بالأصل لإعادة بناء المسار الأقصر واستدعائه، وذلك بتتبع المسار بصورة عكسية من خلية الهدف إلى خلية البداية:

```
def reconstruct_shortest_path(parent:dict, start_cell:tuple, target_cell:tuple):
    shortest_path = []
    my_parent=target_cell # start with the target_cell
    # keep going from parent to parent until the search cell has been reached
    while my_parent!=start_cell:
        shortest_path.append(my_parent) # append the parent
        my_parent=parent[my_parent] # get the parent of the current parent
    shortest_path.append(start_cell) # append the start cell to complete the path
    shortest_path.reverse() # reverse the shortest path
    return shortest_path
```

ستُستخدم دالة `reconstruct_shortest_path()` أيضاً لإعادة بناء الحل لخوارزمية البحث بأولوية الأفضل (A^* search) المشار إليها سلفاً في هذا الدرس. وبالنظر إلى تعريف الدالتين `get_accessible_neighbors()` و `bfs_maze_solver()` على النحو التالي:

```
from typing import Callable # used to call a function as an argument of another function

def bfs_maze_solver(start_cell:tuple,
                    target_cell:tuple,
                    maze:np.ndarray,
                    get_neighbors: Callable,
                    verbose:bool=False): # by default, suppresses descriptive output text

    cell_visits=0 # keeps track of the number of cells that were visited during the search
    visited = set() # keeps track of the cells that have already been visited
    to_expand = [] # keeps track of the cells that have to be expanded

    # add the start cell to the two lists
    visited.add(start_cell)
    to_expand.append(start_cell)
    # remembers the shortest distance from the start cell to each other cell
    shortest_distance = {}
    # the shortest distance from the start cell to itself, zero
```

```

shortest_distance[start_cell] = 0

# remembers the direct parent of each cell on the shortest path from the start_cell to the cell
parent = {}
#the parent of the start cell is itself
parent[start_cell] = start_cell

while len(to_expand)>0:

    next_cell = to_expand.pop(0) #get the next cell and remove it from the expansion list

    if verbose:
        print('\nExpanding cell', next_cell)

    #for each neighbor of this cell
    for neighbor,cost in get_neighbors(maze, next_cell):

        if verbose:
            print('\tVisiting neighbor cell',neighbor)

        cell_visits+=1

        if neighbor not in visited: # if this is the first time this neighbor is visited

            visited.add(neighbor)
            to_expand.append(neighbor)
            parent[neighbor]= next_cell
            shortest_distance[neighbor]=shortest_distance[next_cell]+cost

            # target reached
            if neighbor==target_cell:

                # get the shortest path to the target cell, reconstructed in reverse.
                shortest_path = reconstruct_shortest_path(parent,
                                                start_cell, target_cell)

                return shortest_path, shortest_distance[target_cell],cell_visits

        else: # this neighbor has been visited before

            # if the current shortest distance to the neighbor is longer than the shortest
            # distance to next_cell plus the cost of transitioning from next_cell to this neighbor
            if shortest_distance[neighbor]>shortest_distance[next_cell]
                +cost:

                parent[neighbor]=next_cell
                shortest_distance[neighbor]=shortest_distance[next_cell]+cost

# search complete but the target was never reached, no path exists
return None,None,None

```

تتبع الدالة منهجية البحث بأولوية الاتساع (BFS) للبحث في كل الخيارات في العمق الحالي قبل الانتقال إلى مستوى العمق التالي، وتستخدم هذه المنهجية مجموعة واحدة تسمى `visited` وقائمة تسمى `.to_expand`.

تضمن المجموعة الأولى كل الخلايا التي فحصت مرة واحدة على الأقل من قبل الخوارزمية، بينما تتضمن القائمة الثانية كل الخلايا التي لم توسيع بعد، مما يعني أن الخلايا المجاورة لم تفحص بعد. تستخدم الخوارزمية كذلك قاموسين `parent` و `shortest_distance`، يحفظ الأول منها طول المسار الأقصر من خلية البداية إلى كل خلية أخرى، بينما يحفظ الثاني عقدة الخلية الأصل في المسار الأقصر.

بمجرد الوصول إلى الخلية الهدف وانتهاء البحث، سيُخزن المتغير `shortest_distance[target_cell]` طول الحل والذي يمثل طول المسار الأقصر من البداية إلى الهدف.

يستخدم المقطع البرمجي التالي دالة `() bfs_maze_solver()` لحل الماتاهة الصغيرة 3×3 الموضحة بالأعلى:

```
start_cell=(2,0) # start cell, marked by a star in the 3x3 maze
target_cell=(1,2) # target cell, marked by an "X" in the 3x3 maze

solution, distance, cell_visits=bfs_maze_solver(start_cell,
                                                target_cell,
                                                small_maze,
                                                get_accessible_neighbors,
                                                verbose=True)

print('\nShortest Path:', solution)
print('Cells on the Shortest Path:', len(solution))
print('Shortest Path Distance:', distance)
print('Number of cell visits:', cell_visits)
```

```
Expanding cell (2, 0)
Visiting neighbor cell (1, 0)


Expanding cell (1, 0)
Visiting neighbor cell (0, 0)
Visiting neighbor cell (0, 1)
Visiting neighbor cell (2, 0)

Expanding cell (0, 0)
Visiting neighbor cell (0, 1)
Visiting neighbor cell (1, 0)

Expanding cell (0, 1)
Visiting neighbor cell (0, 0)
Visiting neighbor cell (0, 2)
Visiting neighbor cell (1, 0)
Visiting neighbor cell (1, 2)


Shortest Path: [(2, 0), (1, 0), (0, 1), (1, 2)]
Cells on the Shortest Path: 4
Shortest Path Distance: 3
Number of cell visits: 10
```

تُتجَح خوارزمية البحث بأولوية الاتساع (BFS) في إيجاد المسار الأقصر بعد فحص 10 خلايا. يمكن تصوير عملية البحث المطبقة بخوارزمية البحث بأولوية الاتساع (BFS) بسهولة عند تصوير المتابهة بالتمثيل المستند إلى مُخطّط. المثال التالي يعرض متابهة 3×3 وتمثيلها بالمُخطّط:



يتضمن تمثيل المُخطّط عُقدة واحدة لكل خلية غير مشغولة. تُوضّح القيمة على العُقد إحداثيات خلية المصفوفة المُقابلة. ستظهر حافة غير موجّهة من عُقدة إلى أخرى في حال كانت الخلايا المُقابلة يُمكن الوصول إليها من خلال الانتقال من واحدة إلى الأخرى. إحدى الملاحظات المهمّة حول خوارزمية البحث بأولوية الاتساع (BFS) هي أنه في حالة المُخطّطات غير الموزونة (Unweighted Graphs) يكون المسار الأول الذي تحدّده الخوارزمية بين خلية البداية وأي خلية أخرى هو المسار الذي يتضمن أقل عدد من الخلايا التي تم فحصها. وهذا يعني أنه إذا كانت كل الحواف في المُخطّط لها الوزن نفسه، أي كان لكل الانتقالات من خلية إلى أخرى التكلفة نفسها، فإن المسار الأول الذي تحدّده الخوارزمية إلى عُقدة محددة يكون هو المسار الأقصر إلى تلك العُقدة. ولهذا السبب، تتوقف دالة `bfs_maze_solver()` عن البحث، وتُعرض نتيجة المرة الأولى التي فحصت فيها العُقدة المستهدفة.

ومع ذلك، لا يمكن تطبيق هذه المنهجية على المُخطّطات الموزونة (Weighted Graphs). المثال التالي يوضّح إصداراً موزوناً (Weighted Version) لتمثيل مُخطّط متابهة 3×3 :



شكل 2.21: المتابهة ومُخطّطها الموزون

في هذا المثال، يكون وزن كل الحواف المُقابلة للحركات الرأسية أو الأفقيّة (جنوباً، شمالاً، غرباً، شرقاً) يساوي 1. ومع ذلك، يكون وزن كل الحواف المُقابلة للحركات القطريّة (جنوبية غربية، جنوبية شرقيّة، شمالية غربيّة، شمالية شرقيّة) يساوي 3. في هذه الحالة الموزونة، سيكون المسار الأقصر هو $[(2,0), (1,0), (0,0), (0,1), (0,2), (1,2)]$ ، بمسافة إجمالية: $5 = 1+1+1+1+1$.

يمكن ترميز هذه الحالة الأكثر تعقيداً باستخدام الإصدار الموزون من الدالة `get_accessible_neighbors()` الموضحة بالأسفل.

```
def get_accessible_neighbors_weighted(maze:np.ndarray,
                                       cell:tuple,
                                       horizontal_vertical_weight:float,
                                       diagonal_weight:float):
```

```

neighbors=[]
x,y=cell

for i,j in [(x-1,y-1), (x-1,y+1), (x+1,y-1), (x+1,y+1)]: #for diagonal neighbors

    #if the cell is within the bounds of the grid and it is not occupied by a block
    if i>=0 and j>=0 and i<len(maze) and j<len(maze[0]) and maze[(i,j)]==0:

        neighbors.append(((i,j), diagonal_weight))

for i,j in [(x-1,y), (x,y-1), (x,y+1), (x+1,y)]: #for horizontal and vertical neighbors

    if i>=0 and j>=0 and i<len(maze) and j<len(maze[0]) and maze[(i,j)]==0:

        neighbors.append(((i,j), horizontal_vertical_weight))

return neighbors

```

تسمح الدالة للمُستخدم بتعيين وزن مُخصص للحركات الأفقية والحركات الرأسية، وكذلك وزن مُخصص مختلف للحركات القُطرية. إذا استُخدم الإصدار الموزون (Weighted Version) المُشار إليه بواسطة أداة الحل في البحث بأولوية الاتساع (BFS solver)، فإن النتائج ستكون كما يلي:

```

from functools import partial

start_cell=(2,0)
target_cell=(1,2)
horz_vert_w=1 # weight for horizontal and vertical moves
diag_w=3 # weight for diagonal moves

solution, distance, cell_visits=bfs_maze_solver(start_cell,
                                                target_cell,
                                                small_maze,
                                                partial(get_accessible_neighbors_weighted,
                                                       horizontal_vertical_weight=horz_vert_w,
                                                       diagonal_weight=diag_w),
                                                verbose=False)

print('\nShortest Path:', solution)
print('Cells on the Shortest Path:', len(solution))
print('Shortest Path Distance:', distance)
print('Number of cell visits:', cell_visits)

```

```

Shortest Path: [(2, 0), (1, 0), (0, 1), (1, 2)]
Cells on the Shortest Path: 4
Shortest Path Distance: 7
Number of cell visits: 6

```


وكما هو متوقع، أخطأت أداة الحل في البحث بأولوية الاتساع (BFS solver) في عرض المسار السابق نفسه بالضبط، على الرغم من أن التكلفة تساوي 7، ومن الواضح أنه ليس المسار الأقصر. ويرجع ذلك إلى الطبيعة غير المستنيرة لخوارزمية البحث بأولوية الاتساع (BFS)، حيث لا تأخذ الخوارزمية الأوزان بعين الاعتبار عند تحديد الخلية المقرّر توسيعها في الخطوة التالية؛ لأنها تُطبّق ببساطة منهجية البحث بالعرض نفسها والتي تؤدي إلى المسار نفسه الذي وجدته الخوارزمية في الإصدار غير الموزون (Unweighted Version) من المتأهله. القسم التالي يصف طريقة معالجة نقطة الضعف هذه باستخدام خوارزمية البحث بأولوية الأفضل (A* search)، وهي خوارزمية مُستنيرة وأكثر ذكاءً تضبط سلوكها وفقاً للأوزان المحددة، وبالتالي يمكنها حل المتأهله باستخدام الانتقالات الموزونة (Weighted Transitions) والانتقالات غير الموزونة (Unweighted Transitions).

استخدام خوارزمية البحث بأولوية الأفضل في حل الغاز المتأهله

Using A* Search to Solve Maze Puzzles

كما في خوارزمية البحث بأولوية الاتساع (BFS)، تَفَحَّص خوارزمية البحث بأولوية الأفضل (A* search) خلية واحدة في كل مرة بفحص كل خلية مجاورة يمكن الوصول إليها. في حينما تستخدم خوارزمية البحث بأولوية الاتساع (BFS) منهجية بحث عميق بأولوية العرض لتحديد الخلية التالية التي ستُفحَص، تَفَحَّص خوارزمية البحث بأولوية الأفضل (A* search) الخلية التي يكون بينها وبين الخلية المستهدفة أقصر مسافة محسوبة بواسطة الدالة الاستدلالية (Heuristic Function). يعتمد التعريف الدقيق للدالة الاستدلالية على التطبيق. في حالة الغاز المتأهله، توفر الدالة الاستدلالية تقديرًا دقيقًا لمدى قرب الخلية المرشحة إلى الخلية المستهدفة. يضمن الاستدلال المُطبّق عدم المبالغة في تقدير (Overestimate) المسافة الفعلية إلى الخلية المستهدفة مثل: عرض مسافة تقديرية أكبر من المسافة الحقيقية إلى الهدف، وبالتالي ستحدد الخوارزمية أقصر مسار محتمل لكلٍ من المُخططين الموزون (Weighted) وغير الموزون (Unweighted). إذا كان الاستدلال يبالغ في بعض الأحيان في تقدير المسافة، ستقدم خوارزمية البحث بأولوية الأفضل (A* search) حلًا، ولكن قد لا يكون الأفضل. الاستدلال المحتمل الأبسط الذي لن يؤدي إلى المبالغة في تقدير المسافة هو دالة بسيطة تعطي دومًا مسافة تقديرية قدرها وحدة واحدة.

```
def constant_heuristic(candidate_cell:tuple, target_cell:tuple):
    return 1
```



على الرغم من أن هذا الاستدلال شديد التفاؤل، إلا أنه لن يقدم أبداً تقديرًا أعلى من المسافة الحقيقية، وبالتالي سيؤدي إلى أفضل حل ممكن. سيتم تقديم استدلال متتطور يُمكّنه العثور على أفضل حل بشكل سريع في هذا القسم لاحقاً.

تُستخدم الدالة التالية دالة استدلالية معطاة للعثور على الخلية التي يجب توسيعها بعد ذلك: شكل 2.22: الاستدلال الثابت

```
def get_best_candidate(expansion_candidates:set,
                      shortest_distance:dict,
                      heuristic:Callable):

    winner = None
    # best (lowest) distance estimate found so far. Initialized to a very large number
    best_estimate= sys.maxsize

    for candidate in expansion_candidates:
        # distance estimate from start to target, if this candidate is expanded next
```

```

candidate_estimate=shortest_distance[candidate]+heuristic(candidate,target_cell)
if candidate_estimate < best_estimate:

    winner = candidate
    best_estimate=candidate_estimate

return winner

```

يستخدم التطبيق المشار إليه بالأعلى حلقة التكرار For لفحص الخلايا المرشحة في المجموعة وتحديد الأفضل. ولتطبيق أكثر كفاءة، قد يستخدم طابور الأولوية (Priority Queue) في تحديد المرشح الأفضل دون الحاجة إلى فحص كل المرشحين بصورة متكررة. تُستخدم دالة get_best_candidate() كدالة مُساعدة بواسطة دالة astar_maze_solver() الموضحة فيما يلي. وبالإضافة إلى الدالة الاستدلالية، يستخدم هذا التطبيق كذلك الدالتين المساعدين reconstruct_shortest_path() وget_accessible_neighbors_weighted() المشار إليهما في القسم السابق.

```

import sys

def astar_maze_solver(start_cell:tuple,
                      target_cell:tuple,
                      maze:np.ndarray,
                      get_neighbors: Callable,
                      heuristic:Callable,
                      verbose:bool=False):

    cell_visits=0

    shortest_distance = {}
    shortest_distance[start_cell] = 0

    parent = {}
    parent[start_cell] = start_cell

    expansion_candidates = set([start_cell])
    fully_expanded = set()

    # while there are still cells to be expanded
    while len(expansion_candidates) > 0:

        best_cell = get_best_candidate(expansion_candidates,shortest_distance,heuristic)

        if best_cell == None: break

        if verbose: print('\nExpanding cell', best_cell)

        # if the target cell has been reached, reconstruct the shortest path and exit
        if best_cell == target_cell:

```

```

shortest_path=reconstruct_shortest_path(parent,start_cell,target_cell)

    return shortest_path, shortest_distance[target_cell],cell_visits

for neighbor,cost in get_neighbors(maze, best_cell):

    if verbose: print('\nVisiting neighbor cell', neighbor)

    cell_visits+=1

    #first time this neighbor is reached
    if neighbor not in expansion_candidates and neighbor not in fully_expanded:

        expansion_candidates.add(neighbor)

        parent[neighbor] = best_cell #mark the best_cell as this neighbor's parent

        #update the shortest distance for this neighbor
        shortest_distance[neighbor] = shortest_distance[best_cell] + cost

    #this neighbor has been visited before, but a better (shorter) path to it has just been found
    elif shortest_distance[neighbor] > shortest_distance[best_cell] + cost:

        shortest_distance[neighbor] = shortest_distance[best_cell] + cost

        parent[neighbor] = best_cell

        if neighbor in fully_expanded:

            fully_expanded.remove(neighbor)

            expansion_candidates.add(neighbor)

    #all neighbors of best_cell have been inspected at this point
    expansion_candidates.remove(best_cell)

    fully_expanded.add(best_cell)

return None, None, None #no solution was found

```

وكما الحال في الدالة `bfs_maze_solver()`، تُستخدم الدالة الموضحة بالأعلى كذلك القاموسين `shortest_distance` و `parent` لحفظ طول المسار الأقصر من خلية البداية إلى أي خلية أخرى، وحفظ عقدة أصل الخلية في هذا المسار الأقصر.

ورغم ذلك، تتبع الدالة `astar_maze_solve()` منهجية مختلفة لفحص الخلايا وتوسيعها، فهي تُستخدم `expansion_candidates` لتتبع كل الخلايا التي يمكن توسيعها بعد ذلك. في كل تكرار، تُستخدم دالة `get_best_candidate()` لتحديد أيٌ من الخلايا المرشحة ستُتوسّعها بعد ذلك.

بعد اختيار الخلية المرشحة `best_cell`، تُستخدم حلقة التكرار `For` لفحص كل الخلايا المجاورة لها. إذا كانت الخلية المجاورة تُفحص للمرة الأولى، فستصبح `best_cell` عقدة الأصل للخلية المجاورة في المسار الأقصر.

يحدث الأمر نفسه إذا تم فحص الدالة المجاورة من قبل، ولكن فقط إذا كان المسار إلى هذه الخلية المجاورة من خلال أقصر من المسار السابق. إذا عثرت الدالة بالفعل على مسار أفضل، فسيتعين على الخلية المجاورة العودة إلى مجموعة `expansion_candidates` لإعادة تقييم المسار الأقصر إلى الخلايا المجاورة لها. يستخدم المقطع البرمجي التالي (Unweighted Case) لحل الحالة غير الموزونة (astar_maze_solver()) للغز المتاهة 3x3:

```
start_cell=(2,0)
target_cell=(1,2)

solution, distance, cell_visits=astar_maze_solver(start_cell,
                                                    target_cell,
                                                    small_maze,
                                                    get_accessible_neighbors,
                                                    constant_heuristic,
                                                    verbose=False)

print('\nShortest Path:', solution)
print('Cells on the Shortest Path:', len(solution))
print('Shortest Path Distance:', distance)
print('Number of cell visits:', cell_visits)
```

```
Shortest Path: [(2, 0), (1, 0), (0, 1), (1, 2)]
Cells on the Shortest Path: 4
Shortest Path Distance: 3
Number of cell visits: 12
```

ستبحث أداة الحل في البحث بأولوية الأفضل (`A* search solver`) عن المسار المحتمل الأقصر والأفضل بعد فحص 12 خلية. وهذا أكثر قليلاً من أداة الحل في البحث بأولوية الاتساع (`BFS solver`) التي وجدت الحل بعد فحص 10 خلايا فقط. هذا يعود إلى بساطة الاستدلال الثابت المستخدم لإرشاد (`astar_maze_solver()`). وكما سيتضح لاحقاً في هذا القسم، يمكن استخدام دالة استدلال أخرى لتمكين الخوارزمية من إيجاد الحل بشكل أسرع. الخطوة التالية هي تقييم ما إذا كانت خوارزمية البحث بأولوية الأفضل (`A* search`) قادرة على حل المتاهة الموزونة التي فشلت خوارزمية البحث بأولوية الاتساع (`BFS`) في العثور على أقصر مسار لها أم لا:

```
start_cell=(2,0)
target_cell=(1,2)

horz_vert_w=1 # weight for horizontal and vertical moves
diag_w=3 # weight for diagonal moves

solution, distance, cell_visits=astar_maze_solver(start_cell,
                                                    target_cell,
                                                    small_maze,
                                                    partial(get_accessible_neighbors_weighted,
                                                        horizontal_vertical_weight=horz_vert_w,
                                                        diagonal_weight=diag_w),
                                                    constant_heuristic,
                                                    verbose=False)
```

```

print('\nShortest Path:', solution)
print('Cells on the Shortest Path:', len(solution))
print('Shortest Path Distance:', distance)
print('Number of cell visits:', cell_visits)


```

```

Shortest Path: [(2, 0), (1, 0), (0, 0), (0, 1), (0, 2), (1, 2)]
Cells on the Shortest Path: 6
Shortest Path Distance: 5
Number of cell visits: 12

```

تُوضّح النتائج قدرة `astar_maze_solver()` على حل الحالة الموزونة بالعثور على المسار الأقصر المحتمل $[(2, 0), (1, 0), (0, 0), (0, 1), (0, 2), (1, 2)]$ بتكلفة إجمالية قدرها 5. وهذا يوضح مزايا استخدام خوارزمية بحث مستنيرة، فهي تُمكّنك من إيجاد الحل الأمثل باستخدام أبسط طريقة ممكنة.



المقارنة بين الخوارزميات

الخطوة التالية هي المقارنة بين خوارزمية البحث بأولوية الاتساع (BFS) وخوارزمية البحث بأولوية الأفضل (A^* search) في متاهة أكبر حجماً وأكثر تعقيداً. يُستخدم المقطع البرمجي التالي بلغة البايثون لإنشاء تمثيل رقمي لهذه المتاهة:

```

big_maze=np.zeros((15,15))

# coordinates of the cells occupied by blocks
blocks=[(2,8), (2,9), (2,10), (2,11), (2,12),
        (8,8), (8,9), (8,10), (8,11), (8,12),
        (3,8), (4,8), (5,8), (6,8), (7,8),
        (3,12), (4,12), (6,12), (7,12)]

for block in blocks:
    # set the value of block-occupied cells to be equal to 1
    big_maze[block]=1

```

هذه المتاهة 15×15 تحتوي على قسم من الحواجز على شكل حرف C ينبغي على اللاعب تجاوزها للوصول إلى الهدف المحدد بالعلامة X. ثم تُستخدم أداة الحل في البحث بأولوية الاتساع (BFS solver) وأداة الحل في البحث بأولوية الأفضل (A^* search solver) لحل الإصدارات الموزونة وغير الموزونة من هذه المتاهة كبيرة الحجم:

```

start_cell=(14,0)
target_cell=(5,10)

solution_bfs_unw, distance_bfs_unw, cell_visits_bfs_unw=bfs_maze_solver(start_cell,
                    target_cell,
                    big_maze,
                    get_accessible_neighbors,

```

الإصدارات غير الموزونة

```

        verbose=False)

print('\nBFS unweighted.')
print('\nShortest Path:', solution_bfs_unw)
print('Cells on the Shortest Path:', len(solution_bfs_unw))
print('Shortest Path Distance:', distance_bfs_unw)
print('Number of cell visits:', cell_visits_bfs_unw)

solution_astar_unw, distance_astar_unw, cell_visits_astar_unw=astar_maze_solver(
    start_cell,
    target_cell,
    big_maze,
    get_accessible_neighbors,
    constant_heuristic,
    verbose=False)

print('\nA* Search unweighted with a constant heuristic.')
print('\nShortest Path:', solution_astar_unw)
print('Cells on the Shortest Path:', len(solution_astar_unw))
print('Shortest Path Distance:', distance_astar_unw)
print('Number of cell visits:', cell_visits_astar_unw)

```

BFS unweighted.

Shortest Path: [(14, 0), (13, 1), (12, 2), (11, 3), (10, 4), (9, 5), (8, 6), (8, 7), (9, 8), (9, 9), (9, 10), (9, 11), (9, 12), (8, 13), (7, 13), (6, 13), (5, 12), (4, 11), (5, 10)]
Cells on the Shortest Path: 19
Shortest Path Distance: 18
Number of cell visits: 1237

A* Search unweighted with a constant heuristic.

Shortest Path: [(14, 0), (13, 1), (12, 2), (11, 3), (10, 4), (10, 5), (10, 6), (9, 7), (9, 8), (10, 9), (9, 10), (9, 11), (9, 12), (8, 13), (7, 13), (6, 13), (5, 12), (6, 11), (5, 10)]
Cells on the Shortest Path: 19
Shortest Path Distance: 18
Number of cell visits: 1272

```

start_cell=(14,0)
target_cell=(5,10)

horz_vert_w=1
diag_w=3

```

الإصدار الموزون

```

solution_bfs_w, distance_bfs_w, cell_visits_bfs_w=bfs_maze_solver(start_cell,
    target_cell,

```

```

        big_maze,
        partial(get_accessible_neighbors_weighted,
                horizontal_vertical_weight=horz_vert_w,
                diagonal_weight=diag_w),
        verbose=False)

print('\nBFS weighted.')
print('\nShortest Path:', solution_bfs_w)
print('Cells on the Shortest Path:', len(solution_bfs_w))
print('Shortest Path Distance:', distance_bfs_w)
print('Number of cell visits:', cell_visits_bfs_w)

solution_astar_w, distance_astar_w, cell_visits_astar_w=astar_maze_solver(start_cell,
                           target_cell,
                           big_maze,
                           partial(get_accessible_neighbors_weighted,
                                   horizontal_vertical_weight=horz_vert_w,
                                   diagonal_weight=diag_w),
                           constant_heuristic,
                           verbose=False)

print('\nA* Search weighted with constant heuristic.')
print('\nShortest Path:', solution_astar_w)
print('Cells on the Shortest Path:', len(solution_astar_w))
print('Shortest Path Distance:', distance_astar_w)
print('Number of cell visits:', cell_visits_astar_w)

```

BFS weighted.

Shortest Path: [(14, 0), (14, 1), (14, 2), (13, 2), (13, 3), (12, 3), (12, 4), (11, 4), (11, 5), (10, 5), (10, 6), (9, 6), (9, 7), (9, 8), (9, 9), (9, 10), (9, 11), (9, 12), (9, 13), (8, 13), (7, 13), (6, 13), (5, 13), (5, 12), (4, 11), (5, 10)]
 Cells on the Shortest Path: 26
 Shortest Path Distance: 30
 Number of cell visits: 1235

A* Search weighted with constant heuristic.

Shortest Path: [(14, 0), (13, 0), (12, 0), (11, 0), (10, 0), (9, 0), (9, 1), (9, 2), (9, 3), (9, 4), (9, 5), (9, 6), (9, 7), (9, 8), (9, 9), (9, 10), (9, 11), (9, 12), (9, 13), (8, 13), (7, 13), (6, 13), (5, 13), (5, 12), (5, 11), (5, 10)]
 Cells on the Shortest Path: 26
 Shortest Path Distance: 25
 Number of cell visits: 1245


توافق النتائج مع تلك التي حصلت عليها في المتأهله الصغيرة وهي كالتالي:

- نجحت خوارزمية البحث بأولوية الاتساع (BFS) والبحث بأولوية الأفضل (A* search) في العثور على المسار الأقصر للإصدار غير الموزون.
- وجدت خوارزمية البحث بأولوية الاتساع (BFS) الحل بعد فحص عدد أقل من الخلايا وهو 1237 مقابل 1272 في خوارزمية البحث بأولوية الأفضل (A* search).
- فشلت خوارزمية البحث بأولوية الاتساع (BFS) في العثور على المسار الأقصر للإصدار الموزون، حيث عثرت على مسار بطول 30 وحدة.
- عثرت خوارزمية البحث بأولوية الأفضل (A* search) على المسار الأقصر للإصدار الموزون، حيث عثرت على مسار بطول 25 وحدة.

يُستخدم المقطع التالي لتمثيل المسار الأقصر الذي وجدته الخوارزميتان: خوارزمية البحث بأولوية الاتساع (BFS) وخوارزمية البحث بأولوية الأفضل (A* search) للإصدار الموزون كالتالي:

```
maze_bfs_w=big_maze.copy()  
  
for cell in solution_bfs_w:  
    maze_bfs_w[cell]=2  
  
plot_maze(maze_bfs_w)
```

```
maze_astar_w=big_maze.copy()  
  
for cell in solution_astar_w:  
    maze_astar_w[cell]=2  
  
plot_maze(maze_astar_w)
```



شكل 2.24: مقارنة بين حلّي خوارزميتى البحث بأولوية الاتساع والبحث بأولوية الأفضل

يؤكد التمثيلان أن الطبيعة المستنيرة لخوارزمية البحث بأولوية الأفضل (A* search) تسمح لها بتجنب الحركة القطرية؛ لأن تكلفتها أعلى من الحركتين الأفقية والرأسية. ومن ناحية أخرى، تتجاهل خوارزمية البحث بأولوية الأفضل (BFS) غير المستنيرة تكلفة كل حركة وتعطي حلاً أعلى تكلفه. وفيما يلي مقارنة عامة بين الخوارزميات المستنيرة وغير المستنيرة كما هو موضح في الجدول 2.6:


جدول 2.6: مقارنة بين الخوارزميات المستنيرة وغير المستنيرة

غير المستنيرة	المستنيرة	معايير المقارنة
أكثر تعقيداً حسابياً.	أقل تعقيداً.	التعقيد الحسابي (Computational Complexity)
أبطأ من الخوارزميات المستنيرة.	أسرع في عمليات البحث.	الكفاءة (Efficiency)
غير عملية لحل مشكلات البحث واسع النطاق.	أفضل في حل مشكلات البحث واسع النطاق.	الأداء (Performance)
تحقيق الحل الأمثل.	تحقّق حلولاً مناسبةٍ بشكلٍ عام.	الفعالية (Effectiveness)

ومع ذلك، تُظهر النتائج أن خوارزمية البحث بأولوية الاتساع (BFS) يمكنها العثور على الحل الأمثل بشكلٍ سريع بفحص عدد أقل من الخلايا في الحالة غير الموزونة. يمكن معالجة ذلك بتوفير استدلال أكثر ذكاءً لخوارزمية البحث بأولوية الأفضل (A^* search). والاستدلال الشهير في التطبيقات المستنيرة إلى المسافة هو مسافة مانهاتن (Manhattan Distance)، وهي مجموع الفروقات المطلقة بين إحداثي نقطتين معطياتين. يوضح الشكل أدناه مثلاً على كيفية حساب مسافة مانهاتن:

مسافة مانهاتن Manhattan Distance

$$\text{Manhattan } (A, B) = |x_1 - x_2| + |y_1 - y_2|$$



شكل 2.25: مسافة مانهاتن

يمكن تطبيق هذا بسهولة في صورة دالة البايثون كما يلي:

```
def manhattan_heuristic(candidate_cell:tuple,target_cell:tuple):  
  
    x1,y1=candidate_cell  
    x2,y2=target_cell  
    return abs(x1 - x2) + abs(y1 - y2)
```

يُستخدم المقطع البرمجي التالي لاختبار إمكانية استخدام هذا الاستدلال الذكي لدعم (astar_maze_solver()) في البحث بشكل أسرع في كلٍ من الحالات الموزونة وغير الموزنة:

```
start_cell=(14,0)  
target_cell=(5,10)  
  
solution_astar_unw_mn, distance_astar_unw_mn, cell_visits_astar_unw_mn=astar_  
maze_solver(start_cell,  
            target_cell,  
            big_maze,  
            get_accessible_neighbors,  
            manhattan_heuristic,  
            verbose=False)  
  
print('\nA* Search unweighted with the Manhattan heuristic.')  
print('\nShortest Path:', solution_astar_unw_mn)  
print('Cells on the Shortest Path:', len(solution_astar_unw_mn))  
print('Shortest Path Distance:', distance_astar_unw_mn)  
print('Number of cell visits:', cell_visits_astar_unw_mn)  
  
horz_vert_w=1 # weight for horizontal and vertical moves  
diag_w=3 # weight for diagonal moves  
  
solution_astar_w_mn, distance_astar_w_mn, cell_visits_astar_w_mn=astar_maze_  
solver(start_cell,  
       target_cell,  
       big_maze,  
       partial(get_accessible_neighbors_weighted,  
              horizontal_vertical_weight=horz_vert_w,  
              diagonal_weight=diag_w),  
       manhattan_heuristic,  
       verbose=False)  
  
print('\nA* Search weighted with the Manhattan heuristic.')  
print('\nShortest Path:', solution_astar_w_mn)  
print('Cells on the Shortest Path:', len(solution_astar_w_mn))  
print('Shortest Path Distance:', distance_astar_w_mn)  
print('Number of cell visits:', cell_visits_astar_w_mn)
```

A* Search unweighted with the Manhattan heuristic.

Shortest Path: [(14, 0), (13, 1), (12, 2), (11, 3), (10, 4), (9, 5), (8, 6), (8, 7), (9, 8), (9, 9), (9, 10), (9, 11), (9, 12), (8, 13), (7, 13), (6, 13), (5, 12), (5, 11), (5, 10)]

Cells on the Shortest Path: 19

Shortest Path Distance: 18

Number of cell visits: 865

A* Search weighted with the Manhattan heuristic.

Shortest Path: [(14, 0), (14, 1), (13, 1), (12, 1), (12, 2), (12, 3), (12, 4), (12, 5), (12, 6), (12, 7), (11, 7), (11, 8), (10, 8), (9, 8), (9, 9), (9, 10), (9, 11), (9, 12), (9, 13), (8, 13), (7, 13), (6, 13), (5, 13), (5, 12), (5, 11), (5, 10)]

Cells on the Shortest Path: 26

Shortest Path Distance: 25

Number of cell visits: 1033

تؤكد النتائج أن استدلال مسافة مانهاتن (Manhattan Distance) يمكن استخدامه لدعم خوارزمية البحث بأولوية الأفضل (A* search) في العثور على المسارات الأقصر المحتملة بفحص أقل عدد من الخلايا في كلٍ من الحالات الموزونة وغير الموزونة. علماً بأن استخدام هذا الاستدلال الأكثر ذكاءً يفحص عدداً أقل من الخلايا من ذلك المستخدم في خوارزمية البحث بأولوية الاتساع (BFS).

يلخص الجدول 2.7 النتائج حول مُتغيرات الخوارزميات المختلفة في المتابهة الكبيرة:

جدول 2.7: مقارنة بين أداء الخوارزميات

خوارزمية البحث بأولوية الأفضل (A* search) باستدلال مانهاتن	خوارزمية البحث بأولوية الأفضل (A* search) بالاستدلال الثابت	خوارزمية البحث بأولوية الاتساع (BFS)	
المسافة=25، وفحصت 1033	المسافة=25، وفحصت 1245	المسافة=30، وفحصت 1235	الموزونة
المسافة=18، وفحصت 865	المسافة=18، وفحصت 1272	المسافة=18، وفحصت 1237	غير الموزونة

يوضح الجدول مزايا استخدام الطرائق الأكثر ذكاءً لحل المشكلات المستندة إلى البحث مثل تلك الموضحة بهذا الدرس:

- التحول من خوارزمية البحث بأولوية الاتساع (BFS) غير المستنيرة إلى خوارزمية البحث بأولوية الأفضل (A* search) المستنيرة حقق نتائج أفضل، كما أتاح إمكانية حل المشكلات الأكثر تعقيداً.
- يمكن تحسين ذكاء خوارزميات البحث المستنيرة باستخدام دوال الاستدلال الأفضل التي تسمح لها بالعثور على الحل الأمثل بشكل أسرع.

تمرينات

اذكر تطبيقين لخوارزميات البحث.

1

حدد الاختلافات بين خوارزميات البحث المستنيرة وغير المستنيرة، ثم اذكر مثلاً على كل خوارزمية.

2

3

اشرح بيايجاز كيف تعمل خوارزمية البحث بأولوية الأفضل (A* search).

4

عَدِّل المقطع البرمجي بتغيير الوزن القُطري (Diagonal Weight) من 3 إلى 1.5. ماذا تلاحظ؟
هل يتغير المسار الأقصر في حالتي خوارزمية البحث بأولوية الاتساع (BFS) وخوارزمية البحث بأولوية الأفضل (A* search)?

5

عَدِّل المقطع البرمجي بتبديل إحداثيات خلية البداية مع إحداثيات الخلية المستهدفة. ماذا تلاحظ؟
هل المسار هو نفسه كما كان سابقاً للحالات الموزونة من خوارزميتي البحث بأولوية الاتساع (BFS) والبحث بأولوية الأفضل (A* search)?

المشروع

عُدّل المقطع البرمجي لخوارزمية البحث بأولوية الاتساع (BFS) وخوارزمية البحث بأولوية الأفضل (A^* search) الموزونتين بتعديل الأوزان الأفقية والرأسية إلى 3 والأوزان القطرية إلى 5، وكذلك عُدّل نقطة البداية إلى (2, 7).

ما المسار الجديد ذو المسافة الأقصر، وما عدد الخلايا التي فحصت في الإصدارات غير الموزونة لخوارزميتي البحث بأولوية الاتساع (BFS) والبحث بأولوية الأفضل (A^* search) باستخدام دالة الاستدلال الثابت؟ حدد هذه القيم ودون ملاحظاتك.

اتبع الخطوات نفسها للإصدارات الموزونة من خوارزميتي البحث بأولوية الاتساع (BFS) والبحث بأولوية الأفضل (A^* search) باستخدام دالة الاستدلال الثابت.

كرر العملية للإصدارات غير الموزونة والموزونة من خوارزميتي البحث بأولوية الاتساع (BFS) والبحث بأولوية الأفضل (A^* search) باستخدام دالة استدلال مانهاتن (Manhattan Heuristic).

ماذا تعلمت

- > استخدام الاستدعاء الذاتي لحل المشكلات.
- > تطبيق خوارزميات اجتياز المخطط المتقدمة.
- > تطبيق الأنظمة القائمة على القواعد البسيطة والمتقدمة.
- > تصميم نموذج الذكاء الاصطناعي.
- > قياس فعالية نموذج الذكاء الاصطناعي الذي صممته.
- > استخدام خوارزميات البحث لمحاكاة حل مشكلات الحياة الواقعية.

المصطلحات الرئيسية

A* Search	البحث بأولوية الأفضل	Model Training	تدريب النموذج
Algorithm Performance	أداء الخوارزمية	Path Finding	إيجاد المسار
Breadth-First Search (BFS)	البحث بأولوية الاتساع	Recursion	الاستدعاء الذاتي
Confusion Matrix	مصفوفة الدقة	Rule-Based Systems	الأنظمة القائمة على القواعد
Depth-First Search (DFS)	البحث بأولوية العمق	Scoring Function	دالة تسجيل النقاط
Heuristic Function	دالة استدلالية	Search Algorithms	خوارزميات البحث
Informed Search	البحث المستنير	Uninformed Search	البحث غير المستنير
Knowledge Base	قاعدة المعرفة	Unweighted Graph	مخطط غير موزون
Maze Solving	حل المazes	Weighted Graph	مخطط موزون

3. معالجة اللغات الطبيعية

سيتعلم الطالب في هذه الوحدة عملية تدريب شاملة لنموذج التعلم الموجه والتعلم غير الموجه لفهم المعنى الكامن في أجزاء النصوص. وكذلك سيتعلم كيفية استخدام تعلم الآلة (Machine Learning - ML) في دعم التطبيقات ذات الصلة بمعالجة اللغات الطبيعية (Natural Language Processing - NLP).

أهداف التعلم

بنهاية هذه الوحدة سيكون الطالب قادرًا على أن :

- < يُعرف التعلم الموجه.
- < يُدرب نموذج التعلم الموجه على فهم النص.
- < يُعرف التعلم غير الموجه.
- < يُدرب نموذج التعلم غير الموجه على فهم النص.
- < يُنشئ روبوت دردشة بسيط.
- < يُنتج النصوص باستخدام تقنيات توليد اللغات الطبيعية (Natural Language Generation - NLG)

الأدوات

- < مفكرة جوبيتير (Jupyter Notebook)



الدرس الأول

التعلم الموجه

استخدام التعلم الموجه لفهم النصوص

Using Supervised Learning to Understand Text

معالجة اللغات الطبيعية (Natural Language Processing - NLP) هي إحدى مجالات الذكاء الاصطناعي (Artificial Intelligence - AI) التي ترتكز على تمكين أجهزة الحاسب لتصبح قادرة على فهم اللغات البشرية، وتفسيرها، وإنتاجها. حيث تُعنى معالجة اللغات الطبيعية بعدد من المهام، مثل: تصنیف النصوص، وتحليل المشاعر، والترجمة الآلية، والإجابة على الأسئلة. سيركز هذا الدرس بشكل خاص على كيفية استخدام التعلم الموجه الذي يُعد أحد أنواع الرئيسيّة لتعلم الآلة (Machine Learning - ML) في تحقيق الفهم والتنبؤ التلقائي لخصائص النصوص.

لقد تعلّمت في الوحدة الأولى أن الذكاء الاصطناعي هو مصطلح يشمل كلاً من تعلم الآلة والتعلم العميق، كما يتضح في الشكل 3.1، فالذكاء الاصطناعي هو ذلك المجال الواسع من علوم الحاسوب الذي يعني بابتكار آلات ذكية، بينما تعلم الآلة هو أحد فروع الذكاء الاصطناعي الذي يرتكز على تصميم الخوارزميات وبناء النماذج التي تُمكّن الآلة من التعلم من البيانات دون الحاجة إلى برمجتها بشكل صريح.

التعلم العميق (Deep Learning)،

التعلم العميق هو أحد أنواع تعلم الآلة الذي يستخدم الشبكات العصبية العميقه للتعلم تلقائياً من مجموعات كبيرة من البيانات، فهو يسمح لأجهزة الحاسب بالتعرف على الأنماط واتخاذ القرارات بطريقة تحاكي الإنسان، عبر تصميم نماذج مُعقّدة من البيانات.




شكل 3.1: فروع الذكاء الاصطناعي

تعلم الآلة Machine Learning

تعلم الآلة هو أحد فروع الذكاء الاصطناعي المعنى بتطوير الخوارزميات التي تُمكّن أجهزة الحاسب من التعلم من البيانات المدخلة، بدلاً من اتباع التعليمات البرمجية الصريحة، فهو يعمل على تدريب نماذج الحاسب للتعرف على الأنماط والقيام بالتنبؤات وفقاً للبيانات المدخلة مما يسمح للنموذج بتحسين الدقة مع مرور الوقت، وكذلك يتيح للآلة أداء مهام متعددة، مثل: التصنيف، والانحدار، والتجميع، وتقديم التوصيات دون الحاجة إلى برمجة الآلة بشكل صريح للقيام بكل مُهمة على حدة. يمكن تصنیف تعلم الآلة إلى ثلاثة أنواع رئيسية:

التعلم الموجه (Supervised Learning) هو نوع من تعلم الآلة تعلم فيه الخوارزمية من بيانات تدريب مُعنونة (Labelled) بهدف القيام بالتنبؤات حول بيانات جديدة غير موجودة في مجموعة التدريب أو الاختبار كما هو موضح في الشكل 3.2، ومن الأمثلة عليه:

- **تصنيف الصور (Image Classification)**، مثل: التعرف على الكائنات في الصور.
- **كشف الاحتيال (Fraud Detection)**، مثل: تحديد المعاملات المالية المشبوهة.
- **تصفية البريد الإلكتروني العشوائي (Spam Filtering)**، مثل: تحديد رسائل البريد الإلكتروني غير المرغوب فيها.



شكل 3.2: تمثيل التعلم الموجه

التعلم غير الموجه (Unsupervised Learning) هو نوع من تعلم الآلة تعمل فيه الخوارزمية بموجب بيانات غير مُعنونة (Unlabeled) في محاولة لإيجاد الأنماط وال العلاقات بين البيانات، ومن الأمثلة عليه:

- الكشف عن الاختلاف (Anomaly Detection)، مثل: تحديد الأنماط غير العادية في البيانات.
- التجميع (Clustering)، مثل: تجميع البيانات ذات الخصائص المشابهة.
- تقليل الأبعاد (Dimensionality Reduction)، مثل: اختيار الأبعاد المستخدمة للحد من تعقيد البيانات.

التعلم المعزز (Reinforcement Learning) هو نوع من تعلم الآلة تتفاعل فيه الآلة مع البيئة المحيطة وتتعلم عبر المحاولة والخطأ أو تلقي المكافأة والعقاب، ومن الأمثلة عليه:

- لعب الألعاب، مثل: لعبة الشطرنج أو لعبة قو (GO).
- الروبوتية، مثل: تعلم الروبوت كيف ينتقل في البيئة المحيطة به.
- تخصيص الموارد، مثل: تحسين استخدام الموارد في شبكة ما.

جدول 3.1 يلخص مزايا أنواع تعلم الآلة وعيوبها.

جدول 3.1: مزايا أنواع تعلم الآلة، وعيوبها

العيوب	المزايا
<ul style="list-style-type: none"> • يتطلب بيانات مُعنونة، والتي قد تكون مرتفعة التكلفة. • يقتصر استخدامه على المهمة التي تم تدريبيه عليها، وقد لا يمكنه إعطاء التبؤ الصحيح للبيانات الجديدة. • يصعب تكيفه مع المشكلات الأخرى في حالات النماذج المعقّدة جداً. 	<ul style="list-style-type: none"> • أثبت كفاءة وفعالية كبيرة ويُستخدم على نطاق واسع. • سهل الفهم والتطبيق. • يُمكنه التعامل مع البيانات الخطية وغير الخطية على حد سواء.
<ul style="list-style-type: none"> • أصعب من التعلم الموجه من حيث الفهم والتفسير. • يقتصر على التحليل الاستكشافي، وقد لا يناسب عمليات صنع القرار. • يصعب تكيفه مع المشكلات الأخرى في حالات النماذج المعقّدة جداً. 	<ul style="list-style-type: none"> • لا يتطلب بيانات مُعنونة، مما يجعله أكثر مرونة. • يُمكنه اكتشاف الأنماط الخفية في البيانات. • يُمكنه التعامل مع البيانات الضخمة والمعقّدة.
<ul style="list-style-type: none"> • أكثر تعقيداً من التعلم الموجه وغير الموجه. • صعوبة تصميم نظم مكافآت تُحدد السلوك المطلوب بشكل دقيق. • قد يتطلب مجموعات كبيرة من بيانات التدريب والموارد الحاسوبية. 	<ul style="list-style-type: none"> • يُسم بالمرنة، ويُمكنه التعامل مع البيئات المعقّدة والمتغيرة باستمرار. • يُمكنه التعلم من التجارب السابقة وتحسين الكفاءة مع مرور الوقت. • يناسب مع عمليات صنع القرار مثل لعب الألعاب والروبوتية.

التعلم الموجه Supervised Learning

التعلم الموجه (Supervised Learning)

ستستخدم في التعلم الموجه مجموعات البيانات المعنونة والمنظمة بشكل يدوي لتدريب خوارزميات الحاسوب على التنبؤ بالقيم الجديدة.

التعلم الموجه هو أحد أنواع تعلم الآلة الذي يعتمد على استخدام البيانات المعنونة لتدريب الخوارزميات للقيام بالتنبؤات. يتم تدريب الخوارزمية على مجموعة من البيانات المعنونة ثم اختبارها على مجموعة بيانات جديدة لم تكن جزءاً من بيانات التدريب. يستخدم التعلم الموجه عادةً في معالجة اللغات الطبيعية للقيام بمهام مثل: تصنيف النصوص، وتحليل المشاعر، والتعرف على الكيانات المسماة (Named Entity Recognition - NER). في هذه المهام يتم تدريب الخوارزمية على مجموعة من البيانات المعنونة، حيث يتم إدراج كل مثال تحت عنوان التصنيف المناسب أو المشاعر المناسب. يُطلق على عملية التعلم الموجه اسم الانحدار (Regression) عندما تكون القيم التي تنبأ بها الآلة رقمية، بينما يطلق عليها اسم التصنيف (Classification) عندما تكون القيم متقطعة.

الانحدار

على سبيل المثال، قد يستخدم الانحدار في التنبؤ بسعر بيع المنزل وفقاً لمساحته، وموقعه، وعدد غرف النوم فيه. كما يمكن استخدامه في التنبؤ بحجم الطلب على أحد المنتجات استناداً إلى بيانات المبيعات التاريخية وحجم الإنفاق الإعلاني. وفي مجال معالجة اللغات الطبيعية، يستخدم الانحدار النصوص المدخلة المتوفرة للتنبؤ بتقييم الجمهور للفيلم أو مدى التفاعل مع المنشورات الخاصة به على وسائل التواصل الاجتماعي.

التصنيف

من ناحية أخرى، يستخدم التصنيف في التطبيقات مثل: تشخيص الحالات الطبية وفقاً للأعراض ونتائج الفحوصات. وعندما يتعلق الأمر بفهم النصوص، يمكن استخدام التعلم الموجه في تصنيف النصوص المدخلة إلى فئات أو عناوين أو التنبؤ بها بناءً على الكلمات أو العبارات الموجودة في المستند. على سبيل المثال، يمكن تدريب نموذج التعلم الموجه لتصنيف رسائل البريد الإلكتروني إلى رسائل مزعجة أو غير مزعجة وفقاً للكلمات أو العبارات المستخدمة في رسالة البريد الإلكتروني. ويعتبر تصنيف المشاعر أحد التطبيقات الشهيرة كذلك، حيث يمكن التنبؤ بالانطباع العام حول مستند ما سواء كان سلبياً أم إيجابياً. وسيستخدم هذا التطبيق كمثال عملي في هذه الوحدة، لشرح كل خطوات عملية بناء واستخدام نموذج التعلم الموجه بشكل شامل من بداية رحلة التعلم حتى نهايتها.

في هذه الوحدة ستستخدم مجموعة بيانات من مراجعات الأفلام على موقع IMDb.com الشهير. ستجد البيانات مُقسمة إلى مجموعتين: الأولى ستستخدم لتدريب النموذج، والثانية لاختبار أداء النموذج. في البداية لابد أن تُحمل البيانات إلى DataFrame، لذا عليك استخدام مكتبة بانداس بايثون (Pandas Python) والتي استخدمتها سابقاً. مكتبة بانداس هي إحدى الأدوات الشهيرة التي تُستخدم للتعامل مع جداول البيانات. التعليمات البرمجية التالية ستقوم باستيراد المكتبة إلى البرنامج، ثم تحميل مجموعة البيانات:

```
%capture # capture is used to suppress the installation output.  
  
# install the pandas library, if it is missing.  
!pip install pandas  
import pandas as pd
```

مكتبة بانداس هي مكتبة شهيرة تُستخدم لقراءة ومعالجة البيانات الشبيهة بجدول البيانات.

```
# load the train and testing data.
imdb_train_reviews=pd.read_csv('imdb_data/imdb_train.csv')
imdb_test_reviews=pd.read_csv('imdb_data/imdb_test.csv')

imdb_train_reviews
```

	text	label
0	I grew up (b. 1965) watching and loving the Th...	0
1	When I put this movie in my DVD player, and sa...	0
2	Why do people who do not know what a particula...	0
3	Even though I have great interest in Biblical ...	0
4	Im a die hard Dads Army fan and nothing will e...	1
...
39995	"Western Union" is something of a forgotten cl...	1
39996	This movie is an incredible piece of work. It ...	1
39997	My wife and I watched this movie because we pl...	0
39998	When I first watched Flatliners, I was amazed....	1
39999	Why would this film be so good, but only gross...	1

40000 rows × 2 columns

شكل 3.3: مجموعة بيانات التدريب المعنونة

وكم يتضح في الشكل 3.3، فإن DataFrame مجموعة بيانات تحتوي على عمودين:

- نص التقييم.
- القيم (الصنف).

تقييم إيجابي

تقييم سلبي

القيمة 0 تمثل تقييماً سلبياً بينما القيمة 1 تمثل تقييماً إيجابياً.

الخطوة التالية هي إسناد أعمدة النص والقيم إلى متغيرات مستقلة في أمثلة التدريب والاختبار الممثلة كمجموعة بيانات DataFrame كما يلي:

```
# extract the text from the 'text' column for both training and testing.
X_train_text=imdb_train_reviews['text']
X_test_text=imdb_test_reviews['text']

# extract the labels from the 'label' column for both training and testing.
Y_train=imdb_train_reviews['label']
Y_test=imdb_test_reviews['label']
X_train_text # training data in text format
```

يُستخدم الرمزان X وY عادة في التعلم الموجه فيعبر X عن البيانات المدخلة للتنبؤ، وY عن القيم المستهدفة.

0	I grew up (b. 1965) watching and loving the Th...
1	When I put this movie in my DVD player, and sa...
2	Why do people who do not know what a particula...
3	Even though I have great interest in Biblical ...
4	Im a die hard Dads Army fan and nothing will e...
...	...
39995	"Western Union" is something of a forgotten cl...
39996	This movie is an incredible piece of work. It ...
39997	My wife and I watched this movie because we pl...
39998	When I first watched Flatliners, I was amazed....
39999	Why would this film be so good, but only gross...

Name: text, Length: 40000, dtype: object

شكل 3.4: صورة من أمثلة التدريب (X_train_text) من مجموعة بيانات DataFrame

تجهيز البيانات والمعالجة المسبقة

على الرغم من أن تنسيق النص الأولي كما في الشكل 3.4 بدائي للقارئ البشري، إلا أن خوارزميات التعلم الموجه لا تستطيع التعامل معه بصورته الحالية. فبدلاً من ذلك، تحتاج الخوارزميات إلى تحويل هذه المستن达ات إلى تنسيق متوجه رقمي (Numeric Vector). فيما يُعرف بعملية البرمجة الاتجاهية (Vectorization). ويمكن تطبيق عملية البرمجة الاتجاهية بعدة طرائق مختلفة، وتميز بأن لها تأثيراً إيجابياً كبيراً على أداء النموذج المدرب.

مكتبة Scikit Library

سيتم بناء النموذج الموجه باستخدام مكتبة Scikit-Learn وتُعرف كذلك باسم مكتبة سايكيلت ليرن (Scikit-Learn)، وهي مكتبة شهيرة في البياثون تختص بتعلم الآلة. توفر المكتبة مجموعة من الأدوات والخوارزميات لأداء مهام متعددة، مثل: التصنيف، والانحدار، والتجميع، وتقليل الأبعاد. إحدى الأدوات المفيدة في مكتبة Scikit-Learn هي أداة تُسمى CountVectorizer، ويمكن استخدامها في تهيئة عملية المعالجة وتمثيل البيانات النصية بالمتوجهات.

البرمجة الاتجاهية : (Vectorization)

البرمجة الاتجاهية هي عملية تحويل السلسل النصية المكونة من الكلمات أو العبارات (النص) إلى متوجه متوازن من الأرقام الحقيقة يُستخدم لترجمة خصائص النص باستخدام تنسيق تفهمه خوارزميات تعلم الآلة.

أداة CountVectorizer

تُستخدم أداة CountVectorizer في تحويل مجموعة من المستنداات النصية إلى مصفوفة من رموز متعددة، حيث يمثل كل صف مستند وكل عمود يمثل رمزاً خاصاً. قد تكون الرموز كلمات فردية أو عبارات أو بُنيات أكثر تعقيداً تقوم بالتقاط الأنماط المتعددة من البيانات النصية الأساسية. تشير المدخلات في المصفوفة إلى عدد مرات ظهور الرمز في كل مستند. ويُعرف ذلك أيضاً باسم تمثيل حقيبة الكلمات (BoW)، حيث يتجاهل ترتيب الكلمات في النص مع المحافظة على تكرارها فيه. على الرغم من أن تمثيل حقيبة الكلمات هو تبسيط شديد لغة البشرية، إلا أنه يحقق نتائج تنافسية للغاية عند التطبيق العملي.



شكل 3.5: تمثيل حقيبة الكلمات (bag-of-words)

يستخدم المقطع البرمجي التالي أداة CountVectorizer لتمثيل مجموعة بيانات التدريب IMDb بالمتوجهات:

```
from sklearn.feature_extraction.text import CountVectorizer  
  
# the min_df parameter is used to ignore terms that appear in less than 10 reviews.  
vectorizer_v1 = CountVectorizer(min_df=10)  
  
vectorizer_v1.fit(X_train_text) # fit the vectorizer on the training data.  
# use the fitted vectorizer to vectorize the data.  
X_train_v1 = vectorizer_v1.transform(X_train_text)  
  
X_train_v1
```

```
<40000x23392 sparse matrix of type '<class 'numpy.int64'>'  
with 5301561 stored elements in Compressed Sparse Row format>
```

```
# expand the sparse data into a sparse matrix format, where each column represents a different word.
X_train_v1_dense=pd.DataFrame(X_train_v1.toarray(),
                               columns=vectorizer_v1.get_feature_names_out())
X_train_v1_dense
```

	00	000	007	01	02	04	05	06	07	08	...	zoo	zoom	zooming	zooms	zorro	zu	zucco	zucker	zulu	über
0	0	0	0	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0
1	0	0	0	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0
2	0	0	0	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0
3	0	0	0	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0
4	0	0	0	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0
...
39995	0	0	0	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0
39996	0	0	0	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0
39997	0	0	0	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0
39998	0	0	0	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0
39999	0	2	0	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0

40000 rows × 23392 columns

شكل 3.6: تمثيل مجموعة بيانات التدريب بالمتغيرات

يُعبّر هذا التنسيق الكثيف (Dense) للمصفوفة عن 40,000 تقييم ومراجعة في بيانات التدريب. تحتوي المصفوفة على عمود لكل كلمة تظهر في 10 مراجعات على الأقل (منفذة بواسطة المتغير `min_df`). كما يتضح بالأعلى، ينتج عن ذلك 23,392 عموداً، مرتبة في ترتيب أبجدي رقمي. يُعبّر مدخل المصفوفة في الموضع `[j,i]` عن عدد المرات التي تظهر فيها كلمة `i` في المراجعة `j`. وعلى الرغم من إمكانية استخدام هذه المصفوفة مباشرةً من قبل خوارزمية التعلم الموجّه، إلا أنها غير فعالة من حيث استخدام الذاكرة. والسبب في ذلك أن الغالبية العظمى من المدخلات في هذه المصفوفة تساوي 0. وهذا يحدث لأن نسبة ضئيلة جداً فقط من بين 23,392 كلمة محتملة ستظهر فعلياً في كل مراجعة. ولمعالجة هذا القصور، تخزن أداة `CountVectorizer` البيانات الممثلة بالمتغيرات في مصفوفة متبااعدة، حيث تحفظ فقط بالمدخلات غير الصفرية في كل عمود. يستخدم المقطع البرمجي بالأصل الدالة `getsizeof()` التي تحدّد حجم الكائنات في لغة البايثون (Python) بالبايت (Bytes) لتوضيح مدى التوفير في الذاكرة عند استخدام المصفوفة المتبااعدة لبيانات IMDb:

```
from sys import getsizeof
print('\nMegaBytes of RAM memory used by the raw text format:',
      getsizeof(X_train_text)/1000000)
print('\nMegaBytes of RAM memory used by the dense matrix format:',
      getsizeof(X_train_v1_dense)/1000000)
print('\nMegaBytes of RAM memory used by the sparse format:',
      getsizeof(X_train_v1)/1000000)
```

MegaBytes of RAM memory used by the raw text format: 54.864133

MegaBytes of RAM memory used by the dense matrix format: 7485.440144

MegaBytes of RAM memory used by the sparse format: 4.8e-05

وبحسب المتوقع تحتاج المصفوفة المتباude إلى ذاكرة أقل بكثير وتحديداً 0.000048 ميجابايت، بينما تشغّل المصفوفة الكثيفة 7 جيجابايت، كما أن هذه المصفوفة لن تُستخدم مرة أخرى وبالتالي يمكن حذفها لتوفير هذا الحجم الكبير من الذاكرة:

```
# delete the dense matrix.  
del X_train_v1_dense
```

بناء خط أنابيب التنبؤ

Building a Prediction Pipeline

المُصنّف (Classifier):
المُصنّف في تعلم الآلة هو نموذج يُستخدم لتمييز نقاط البيانات في فئات أو تصنيفات مختلفة. الهدف من المُصنّف هو التعلم من بيانات التدريب المعنونة، ومن ثم القيام بالتنبؤات حول قيم التصنيف لبيانات جديدة.

الآن بعد أن تمكّنت من تمثيل بيانات التدريب بالمتّجهات فإن الخطوة التالية هي بناء خط أنابيب التنبؤ الأول. وللقيام بذلك، ستسخدم نوعاً من المُصنّفات يسمى مُصنّف بايز الساذج (Naive Bayes Classifier)، حيث يُستخدم هذا المُصنّف احتمالات الكلمات أو العبارات المحددة الواردة في النص للتنبؤ باحتمال انتمامه إلى تصنيف محدد. جاءت كلمة الساذج (Naive) في اسم المُصنّف من افتراض أن وجود كلمة بعينها في النص مستقل عن وجود أي كلمة أخرى. وهذا افتراض قوي، ولكنه يسمح بتدريب الخوارزمية بسرعة وبفعالية كبيرة.

يستخدم المقطع البرمجي التالي تطبيق مُصنّف بايز الساذج (Multinomial NB) من مكتبة سكليرن (Sklearn Library) لتدريب نموذج التعلم الموجّه على بيانات التدريب IMDb بالمتّجهات:

```
from sklearn.naive_bayes import MultinomialNB  
  
model_v1=MultinomialNB() # a Naive Bayes Classifier  
  
model_v1.fit(X_train_v1, Y_train) #fit the classifier on the vectorized training data.  
  
from sklearn.pipeline import make_pipeline  
  
# create a prediction pipeline: first vectorize using vectorizer_v1, then use model_v1 to predict.  
prediction_pipeline_v1 = make_pipeline(vectorizer_v1, model_v1)
```

على سبيل المثال، سينتج هذا المقطع البرمجي مصفوفة نتائج يرمز فيها الرقم 1 للتقييم الإيجابي و0 للتقييم السلبي:


```
prediction_pipeline_v1.predict(['One of the best movies of the year. Excellent  
cast and very interesting plot.',  
'I was very disappointed with his film. I  
lost all interest after 30 minutes'])
```

```
array([1, 0], dtype=int64)
```

يتباً خط الأنابيب بشكل صحيح بالقيمة الإيجابية للتقييم الأول والقيمة السلبية للتقييم الثاني. يمكن استخدام الدالة `predict_proba()` لتحديد جميع الاحتمالات التي يقوم خط الأنابيب بتخصيصها لكل واحدة من القيمتين المحتملتين. العنصر الأول هو احتمال تعيين 0 والعنصر الثاني هو احتمال تعيين 1:

```
prediction_pipeline_v1.predict_proba(['One of the best movies of the year. Excellent cast and very interesting plot.', 'I was very disappointed with his film. I lost all interest after 30 minutes'])
```

```
array([[0.08310769, 0.91689231], [0.83173475, 0.16826525]])
```



شكل 3.7: مُخططان دائريان يوضحان النسب المئوية للتقييمين

النموذج يؤكّد بنسبة 8.3% أن التقييم الأول سلبي، بينما يؤكّد بنسبة 91.7% أنه إيجابي. وبالتالي، يؤكّد النموذج بنسبة 83.1% أن التقييم الثاني سلبي، بينما يؤكّد بنسبة 16.8% أنه إيجابي.

الخطوة التالية هي اختبار دقة خط الأنابيب الجديد في تصنیف التقييمات في مجموعة بيانات اختبار IMDb. المخرج هو مصفوفة تشمل جميع قيم نتائج تصنیف التقييمات الواردة في بيانات الاختبار:

```
# use the pipeline to predict the labels of the testing data.
predictions_v1 = prediction_pipeline_v1.predict(X_test_text) # vectorize the text data, then predict.

predictions_v1
```

```
array([0, 0, 0, ..., 0, 0, 0], dtype=int64)
```

توفر لغة البرايشون العديد من الأدوات لتحليل وتصوير نتائج خطوط أنابيب التصنيف. تشمل الأمثلة دالة `accuracy_score()` من مكتبة سكيلر وتمثيل مصفوفة الدقة (Confusion Matrix) من مكتبة سايكريت بلوت (Scikit-Plot)، وهناك مقاييس تقييم أخرى مثل: الدقة، والاستدعاء، والنوعية، والحساسية، ومقياس درجة F1، وفقاً لحالة الاستخدام التي يمكن حسابها من مصفوفة الدقة. المخرج التالي هو تقرير دقيق لدرجة التنبؤ:

```
from sklearn.metrics import accuracy_score
accuracy_score(Y_test, predictions_v1) # get the achieved accuracy.
```

```
0.8468
```

```
%capture
!pip install scikit-plot; # install the scikit-plot library, if it is missing.
import scikitplot; # import the library
```

```
class_names=['neg','pos'] # pick intuitive names for the 0 and 1 labels.
```


```
# plot the confusion matrix.
```

```
scikitplot.metrics.plot_confusion_matrix(
    [class_names[i] for i in Y_test],
    [class_names[i] for i in predictions_v1],
    title="Confusion Matrix", # title to use
    cmap="Purples", # color palette to use
    figsize=(5,5) # figure size
);
```

القيم المُتوقعة.

القيم الحقيقة.

تحتوي مصفوفة الدقة على عدد التصنيفات الحقيقة مقابل المُتوقعة. في مُهمة التصنيف الثنائية (مثل: مسألة احتواء قيمتين، الموجودة في مُهمة IMDb)، ستحتوي مصفوفة الدقة على أربع خلايا:



شكل 3.8: نتائج مصفوفة الدقة بتطبيق مصنف بايز الساذج على بيانات الاختبار باستخدام مجموعة بيانات IMDb

الدقة (Accuracy):

الدقة هي نسبة التنبؤات الصحيحة إلى إجمالي عدد التنبؤات.

$$\text{الدقة} = \frac{\text{(التنبؤات الموجبة الصحيحة + التنبؤات السالبة الصحيحة)}}{\text{(التنبؤات الموجبة الصحيحة + التنبؤات السالبة الصحيحة + التنبؤات الموجبة الخاطئة + التنبؤات السالبة الخاطئة)}}$$

تُظهر النتائج أنه على الرغم من أن خط الأنابيب الأول يحقق دقة تنافسية تصل إلى 84.68%， إلا أنه لا يزال يخطئ في تصنیف مئات التقييمات. فهناك 331 تنبؤاً غير صحيح في الربع الأيمن العلوي و435 تنبؤاً غير صحيح في الربع الأيسر السفلي، بإجمالي 766 تنبؤاً غير صحيح. الخطوة الأولى نحو تحسين الأداء هي دراسة سلوك خط أنابيب التنبؤ، لمعرفة كيف يقوم بمعالجة النص وفهمه.

شرح مُتنبئات الصندوق الأسود Explaining Black-Box Predictors

يستخدم مصنف بايز الساذج الصيغ الرياضية البسيطة لجمع احتمالات آلاف الكلمات وتقديم تنبؤاتها. وبالرغم من بساطة النموذج، إلا أنه لا يزال غير قادر على تقديم شرح بسيط و مباشر لكيفية قيام النموذج بتوقع القيمة الموجبة أو السالبة لجزء محدد من النص. قارن ذلك مع مصنفات شجرة القرار الأكثروضوحاً، حيث يتم تمثيل القواعد التي تعلمها النموذج في الهيكل الشجري، مما يسهل على الأشخاص فهم كيف يقوم المصنف بالتنبؤات. يتيح هيكل الشجرة كذلك الحصول على تصور مرجعي للقرارات المستخدمة في كل فرع، مما يكون مفيداً في فهم العلاقات بين الخصائص المدخلة والمتغير المستهدف.

الافتقار إلى قدرة التفسير تمثل تحدياً كبيراً في الخوارزميات الأكثر تعقيداً، كتلك المستندة إلى التجمعيات مثل: توليفات من الخوارزميات المتعددة أو الشبكات العصبية. في بدون القدرة على التفسير، تتخلص خوارزميات التعلم الموجه إلى متنبئات الصندوق الأسود: على الرغم من أنها تفهم النص بشكل كافٍ للتنبؤ بالقيم، إلا أنها لا تزال غير قادرة على تفسير كيف تقوم باتخاذ القرار. أجريت العديد من الأبحاث للتغلب على هذه التحديات بتصميم وسائل قادرة على التفسير تستطيع فهم نماذج الصندوق الأسود. واحدة من الوسائل الأكثر شهرة هي النموذج المحايد المحلي القابل للتفسير والشرح (Local Interpretable Model-Agnostic Explanations - LIME).

النموذج المحايد المحلي القابل للتفسير والشرح Local Interpretable Model-Agnostic Explanations - LIME

النموذج المحايد المحلي القابل للتفسير والشرح (LIME) هو طريقة لتفسير التنبؤات التي قامت بها نماذج الصندوق الأسود. وذلك من خلال النظر في نقطة بيانات واحدة في وقت محدد، وإجراء تغييرات بسيطة عليها لمعرفة كيف يؤثر ذلك على قدرة تنبؤ النموذج، ثم تُستخدم هذه المعلومات لتدريب نموذج مفهوم وبسيط مثل الانحدار الخطى على تفسير هذه التنبؤات. بالنسبة للبيانات النصية، يقوم النموذج المحايد المحلي القابل للتفسير والشرح بالتعرف على الكلمات أو العبارات التي لها الأثر الأكبر على القيام بالتنبؤات.

وفيما يلي، تطبيق بلغة البايثون يوضح ذلك:

```
%capture

!pip install lime # install the lime library, if it is missing
from lime.lime_text import LimeTextExplainer

# create a local explainer for explaining individual predictions
explainer_v1 = LimeTextExplainer(class_names=class_names)

# an example of an obviously negative review
easy_example='This movie was horrible. The actors were terrible and the plot
was very boring.'

# use the prediction pipeline to get the prediction probabilities for this example
print(prediction_pipeline_v1.predict_proba([easy_example]))
```

```
[[0.99874831 0.00125169]]
```

كما هو متوقع، يقدم نموذج التنبؤ تنبؤاً سلبياً مؤكداً بدرجة كبيرة في هذا المثال البسيط.

explain the prediction for this example.

```
exp = explainer_v1.explain_instance(easy_example.lower(),
                                     prediction_pipeline_v1.predict_proba,
                                     num_features=10)
```

print the words with the strongest influence on the prediction.

```
exp.as_list()
```

```
[('terrible', -0.07046118794796816),
 ('horrible', -0.06841672591649835),
 ('boring', -0.05909016205135171),
 ('plot', -0.024063095577996376),
 ('was', -0.014436071624747861),
 ('movie', -0.011956911011210977),
 ('actors', -0.011682594571408675),
 ('this', -0.009712387273986628),
 ('very', 0.008956707731803237),
 ('were', -0.008897098392433257)]
```


الدرجة المقابلة لكل كلمة تمثل مُعمايلاً في نموذج الانحدار الخطى البسيط المستخدم لتقديم التفسير.

الخصائص العشرة الأكثر تأثيراً.

يمكن الحصول على تصور مرجئي أكثر دقةً على النحو التالي:

visualize the impact of the most influential words.

```
fig = exp.as_pyplot_figure()
```




شكل 3.9: الكلمات الأعلى تأثيراً في القيام بالتنبؤات

يزيد المُعامل السالب من احتمالية التصنيف السالب، بينما يُقلل المُعامل الموجب منه. على سبيل المثال، الكلمات: *horrible* (فظيع)، و*boring* (مرير) ، و*terrible* (ممل) لها التأثير الأقوى على قرار النموذج بالتنبؤ بالقيمة السالبة. الكلمة *very* (جداً) دفعت النموذج قليلاً في اتجاه آخر إيجابي، ولكنها لم تكن كافية لتغيير القرار. بالنسبة للمراقب البشري، قد يبدو غريباً أن الكلمات الخالية من المشاعر مثل: *plot* (الحبكة الدرامية) أو *was* (كان) لها مُعاملات مرتفعة نسبياً. ومع ذلك، من الضروري أن تذكر أن تعلم الآلة لا يتبع دوماً الوعي البشري السليم.

وقد تكشف هذه المُعاملات المرتفعة بالفعل عن قصور في منطق الخوارزمية وقد تكون مسؤولة عن بعض أخطاء نموذج التنبؤ. وعلى نحو بديل، يُعد نموذج التنبؤ بمثابة مؤشر على الأنماط التنبؤية الكامنة والغنية في الوقت نفسه بالمعلومات. على سبيل المثال، قد يبدو الواقع وكأن المُقيِّمين البشريين أكثر استخداماً لكلمة *plot* (الحبكة الدرامية) أو صيغة الماضي *was* (كان) عند الحديث في سياق سلبي. ويمكن لمكتبة النموذج المحايد المحلي القابل للتفسير والشرح (LIME) في لغة البايثون تصوير الشروhatas بطرائق أخرى. على سبيل المثال:

```
exp.show_in_notebook()
```



شكل 3.10: التمثلات المرئية الأخرى

التقييم المستخدم في المثال السابق كان سلبياً بشكل واضح ويُسهل التنبؤ به. خذَّ بعين الاعتبار التقييم التالي الأكثر صعوبةً والذي يمكن أن يتسبب في تذبذب دقة الخوارزمية، وهو مأخوذ من مجموعة بيانات اختبار IMDb:

```
# an example of a positive review that is mis-classified as negative by prediction_pipeline_v1
```

```
mistake_example= X_test_text[4600]
```

```
mistake_example
```

"I personally thought the movie was pretty good, very good acting by Tadanobu Asano of Ichi the Killer fame. I really can't say much about the story, but there were parts that confused me a little too much, and overall I thought the movie was just too lengthy. Other than that however, the movie contained superb acting great fighting and a lot of the locations were beautifully shot, great effects, and a lot of sword play. Another solid effort by Tadanobu Asano in my opinion. Well I really can't say anymore about the movie, but if you're only outlook on Asian cinema is Crouching Tiger Hidden Dragon or House of Flying Daggers, I would suggest you trying to rent it, but if you're a die-hard Asian cinema fan I would say this has to be in your collection very good Japanese film."

```

# get the correct labels of this example.
print('Correct Label:', class_names[Y_test[4600]])

# get the prediction probabilities for this example.
print('Prediction Probabilities for neg, pos:',
      prediction_pipeline_v1.predict_proba([mistake_example]))

```

Correct Label: pos
Prediction Probabilities for neg, pos: [[0.8367931 0.1632069]]


على الرغم من أن هذا التقييم إيجابي بشكل واضح، إلا أن نموذج التنبؤ قدّم تبؤاً سلبياً مؤكداً للغاية باحتمالية وصلت إلى 83%. يمكن الآن استخدام المفسّر لتوضيح السبب وراء اتخاذ نموذج التنبؤ مثل هذا القرار الخاطئ:

```

# explain the prediction for this example.
exp = explainer_v1.explain_instance(mistake_example, prediction_pipeline_
v1.predict_proba, num_features=10)

# visualize the explanation.
fig = exp.as_pyplot_figure()

```



شكل 3.11: الكلمات التي أثرت على القرار الخاطئ

على الرغم من أن نموذج التنبؤ يستنبط التأثير الإيجابي لبعض الكلمات على نحو صحيح مثل: beautifully (بشكل جميل)، superb (رائع)، great (مدهش)، و acting (تمثيل)، إلا أنه يتّخذ في النهاية قراراً سلبياً استناداً إلى العديد من الكلمات التي يبدو أنها لا تعبر بشكل واضح عن المشاعر السلبية مثل: Asano (أسانو)، Asian (آسيوي)، movie (فيلم)، و movie (فيلم)، و movie (فيلم).

وهذا يوضح العيوب الكبيرة في المنطق الذي يستخدمه نموذج التنبؤ لتصنيف المفردات الواردة في نصوص التقييمات المقدمة. القسم التالي يوضح كيف أن تحسين هذا المنطق يمكن أن يطور من أداء نموذج التنبؤ إلى حدٍ كبير.

تحسين البرمجة الاتجاهية للنصوص

Improving Text Vectorization

التعبير النمطي (Regular Expression):

التعبير النمطي هو نمط نص يُستخدم لمطابقة ومعالجة سلاسل النصوص وتقديم طريقة موجزة ومرنة لتحديد أنماط النصوص، كما تُستخدم على نطاق واسع في معالجة النصوص وتحليل البيانات.

استخدم الإصدار الأول لخط أنابيب التنبؤ أداة CountVectorizer لحساب عدد المرات التي تظهر فيها كل كلمة في كل تقييم. تتجاهل هذه المنهجية حقيقتين أساسيتين حول اللغات البشرية:

- قد يتغير معنى الكلمة وأهميتها حسب الكلمات المستخدمة معها.
- تكرار الكلمة في المستند لا يُعد دوماً تمثيلاً دقيقاً لأهميتها. على سبيل المثال، على الرغم من أن تكرار كلمة great (رائع) مرتين قد يمثل مؤشراً إيجابياً في مستند يحتوي على 100 كلمة، إلا أنه يمثل مؤشراً أقل أهمية بكثير في مستند يحتوي على 1000 كلمة.

سيشرح هذا الجزء كيفية تحسين البرمجة الاتجاهية للنصوص لأخذ هاتين الحقيقتين في عين الاعتبار. يستدعي المقطع البرمجي التالي ثلاثة مكتبات مختلفة بلغة البايثون، ستُستخدم لتحقيق ذلك:

- nltk وجينسم (Gensim): تُستخدم هاتان المكتبتان الشهيرتان في مهام معالجة اللغات الطبيعية المتنوعة.
- re: تُستخدم هذه المكتبة في البحث عن النصوص، ومعالجتها باستخدام التعبيرات النمطية.

```
%capture
!pip install nltk # install nltk
!pip install gensim # install gensim

import nltk # import nltk
nltk.download('punkt') # install nltk's tokenization tool, used to split a text into sentences.

import re # import re

from gensim.models.phrases import Phrases, ENGLISH_CONNECTOR_WORDS # import tools
from the gensim library.
```

التقسيم (Tokenization):

يقصد به: عملية تقسيم البيانات النصية إلى أجزاء مثل كلمات، جمل، ورموز، وعناصر أخرى يطلق عليها الرموز (Tokens).

تحديد العبارات

يمكن استخدام الدالة الآتية لتقسيم مستند محدد إلى قائمة من الجمل المقصّمة، حيث يمكن تمثيل كل جملة مقصّمة بقائمة من الكلمات:

```
# convert a given doc to a list of tokenized sentences.
def tokenize_doc(doc:str):
    return [re.findall(r'\b\w+\b',
                      sent.lower()) for sent in nltk.sent_tokenize(doc)]
```

دالة () sent_tokenize() تُقسم المستند إلى قائمة من الجمل.

دالة () sent_tokenize() من مكتبة nltk تُقسم المستند إلى قائمة من الجمل.

بعد ذلك، يتم كتابة كل جملة بأحرف صغيرة وتغذيتها إلى دالة () findall() من مكتبة re لتقوم بتحديد تكرارات التعبيرات النمطية '\b\w+\b'. ستحتبرها على السلسلة النصية الموجودة في متغير raw_text. في هذا السياق:

- \w تتطابق مع كل الرموز الأبجدية الرقمية (0-9، A-Z، a-z) والشرطية السفلية.
- \w+ تُستخدم للبحث عن واحد أو أكثر من رموز \w. لذلك، في السلسلة النصية hello123_world (مرحباً_123_العالم)، النمط \w+ سيتطابق مع الكلمات hello (مرحباً) و 123 و world (العالم).
- \b تمثل الفاصل (Boundary) بين رمز \w ورمز ليس \w، وكذلك في بداية أو نهاية السلسلة النصية المعطاة. على سبيل المثال: سيتطابق النمط \b\bcat\b مع الكلمة cat (القطة) في السلسلة النصية The cat is cute (القطة لطيفة)، ولكنه لن يتطابق مع الكلمة cat (القطة) في السلسلة النصية The category is pets (فئة الحيوانات الأليفة).

أدناه مثلاً على التقسيم باستخدام الدالة `. tokenize_doc()`

```
raw_text='The movie was too long. I fell asleep after the first 2 hours.'
tokenized_sentences=tokenize_doc(raw_text)
tokenized_sentences
```

```
[['the', 'movie', 'was', 'too', 'long'],
 ['i', 'fell', 'asleep', 'after', 'the', 'first', '2', 'hours']]
```

يمكن الآن تجميع الدالة `tokenize_doc()` مع أداة العبارات من مكتبة جينسم (Gensim) لإنشاء نموذج العبارة، وهو نموذج يمكنه التعرّف على العبارات المكونة من عدة كلمات في جملة معطاة. يستخدم المقطع البرمجي التالي بيانات التدريب IMDB الخاصة بـ `X_train_text` لبناء مثل هذا النموذج:

```
sentences=[] # list of all the tokenized sentences across all the docs in this dataset
for doc in X_train_text: #for each doc in this dataset
    sentences+=tokenize_doc(doc) # get the list of tokenized sentences in this doc

# build a phrase model on the given data
imdb_phrase_model = Phrases(sentences, ❶
                             connector_words=ENGLISH_CONNECTOR_WORDS, ❷
                             scoring='npmi', ❸
                             threshold=0.25).freeze() ❹
```

كما هو موضح بالأعلى، تَستقبل الدالة `Phrases()` أربعة متغيرات:

❶ قائمة الجمل المُقسمة من مجموعة النصوص المعطاة.

❷ قائمة بالكلمات الإنجليزية الشائعة التي تظهر بصورة متكررة في العبارات (مثل: the، و of)، وليس لها أي قيمة موجبة أو سالبة، ولكن يمكنها إضفاء المشاعر حسب السياق، ولذلك يتم التعامل معها بصورة مختلفة.

❸ تُستخدم دالة تسجيل النقاط لتحديد ما إذا كان تضمين مجموعة من الكلمات في العبارة نفسها واجباً. المقطع البرمجي بالأعلى يستخدم مقياس المعلومات النقطية المشتركة المُعايير (Normalized Pointwise Mutual Information - NPMI) لهذا الغرض. يستند هذا المقياس على تكرار توارد الكلمات في العبارة المرشحة وتكون قيمته بين 1 - ويرمز إلى الاستقلالية الكاملة (Complete Co-occurrence)، و +1 ويرمز إلى التوارد الكامل (Complete Independence).

❹ في حدود دالة تسجيل النقاط ذات النقاط الأقل. ومن الناحية العملية، يمكن ضبط هذه الحدود لتحديد القيمة التي تُعطي أفضل النتائج في التطبيقات النهائية مثل: النمذجة التنبؤية.

تحوّل دالة `freeze()` نموذج العبارة إلى تنسيق غير قابل للتغيير أي مُجمّد (Frozen) لكنه أكثر سرعة.

عند تطبيقها على الجملتين المُقسّمتين بالمثال المُوضح بالأعلى، سيتحقق نموذج العبارة النتائج التالية:


```
imdb_phrase_model[tokenized_sentences[0]]
```

```
['the', 'movie', 'was', 'too_long']
```

```
imdb_phrase_model[tokenized_sentences[1]]
```

```
['i', 'fell_asleep', 'after', 'the', 'first', '2_hours']
```

يحدّد نموذج العبارة ثلاثة عبارات على النحو التالي: fell_asleep (سقط نائماً) و too_long (طويل جداً)، و 2_hours (2-ساعة) و جميعها تحمل معلومات أكثر من كلماتها المفردة.



شكل 3.12: المشاعر الإيجابية والسلبية قبل التقسيم وبعده

على سبيل المثال، تحمل عبارة too_long (طويل جداً) مشاعر سلبية واضحة، على الرغم من أن كلمتي too (جداً) و long (طويل) لا تعبّران عن ذلك منفردين، وبالتالي، فعلى الرغم من أن الكلمة asleep (نائم) في مراجعة الفيلم تمثل دلالة سلبية، فالعبارة fell_asleep (سقط نائماً) توصل رسالة أكثر وضوحاً. وأخيراً، تستنبط من 2_hours (2-ساعة) سياقاً أكثر تحديداً من الكلمتين 2 و hours كل على حدة.

تستخدم الدالة التالية إمكانية تحديد العبارات بهذا الشكل لتفسير العبارات في وثيقة مُعطاه:

```
def annotate_phrases(doc:str, phrase_model):  
  
    sentences=tokenize_doc(doc)# split the document into tokenized sentences.  
  
    tokens=[] # list of all the words and phrases found in the doc  
    for sentence in sentences: # for each sentence  
        # use the phrase model to get tokens and append them to the list.  
        tokens+=phrase_model[sentence]  
    return ' '.join(tokens) # join all the tokens together to create a new annotated document.
```

يستخدم المقطع البرمجي التالي دالة () annotate_phrases() لتقسيم كلٍ من تقييمات التدريب والاختبار من مجموعة بيانات IMDb.


```
# annotate all the test and train reviews.  
X_train_text_annotated=[annotate_phrases(doc,imdb_phrase_model) for doc in X_train_text]  
X_test_text_annotated=[annotate_phrases(text,imdb_phrase_model)for text in X_test_text]
```

```
# an example of an annotated document from the imdb training data
X_train_text_annotated[0]
```

'i_grew up b 1965 watching and loving the thunderbirds all my_mates at school watched we played thunderbirds before school during lunch and after school we all wanted to be virgil or scott no_one wanted to be alan counting down from 5 became an art_form i took my children to see the movie hoping they would get_a_glimpse of what i_loved as a child how bitterly disappointing the only high_point was the snappy theme_tune not that it could compare with the original score of the thunderbirds thankfully early saturday_mornings one television_channel still plays reruns of the series gerry_anderson and his_wife created jonatha frakes should hand in his directors chair his version was completely hopeless a waste of film utter_rubbish a cgi remake may_be acceptable but replacing marionettes with homo_sapiens subsp sapiens was a huge error of judgment'

تكرار المصطلح - تكرار المستند العكسي Term Frequency Inverse Document Frequency (TF-IDF)

تكرار المصطلح - تكرار المستند العكسي هو طريقة تُستخدم لتحديد أهمية الرموز في المستند.



شكل 3.13: الكلمات والمصطلحات الواردة في المستند

$$\text{تكرار المستند العكسي} = \frac{\text{عدد المستندات في الأصل النصي}}{\text{عدد المستندات التي تحتوي على المصطلح}}$$

$$\text{تكرار المصطلح} = \frac{\text{عدد مرات ظهور المصطلح في المستند}}{\text{عدد الكلمات في المستند}}$$

$$\text{تكرار المصطلح} \times \text{تكرار المستند العكسي} = \text{القيمة}$$

استخدام مقياس تكرار المصطلح-تكرار المستند العكسي في البرمجة الاتجاهية للنصوص Using TF-IDF for Text Vectorization

تكرار الكلمة في المستند لا يُعد دوماً تمثيلاً دقيقاً لأهميتها. الطريقة المثلثة لتمثيل التكرار هي المقياس الشهير لتكرار المصطلح - تكرار المستند العكسي (TF-IDF). يستخدم هذا المقياس صيغة رياضية بسيطة لتحديد أهمية الرموز مثل: الكلمات أو العبارات في المستند بناءً على عاملين:

- تكرار الرمز في المستند، بقياس عدد مرات ظهوره في المستند مقسوماً على إجمالي عدد الرموز في جميع المستندات.

- تكرار المستند العكسي للرمز، المحسوب بقسمة إجمالي عدد المستندات في مجموعة البيانات على عدد المستندات التي تحتوي على الرمز.

العامل الأول يتجنب المبالغة في تقدير أهمية المصطلحات التي تظهر في الوثائق الأطول، أمّا العامل الثاني فيستبعد المصطلحات التي تظهر في كثير من المستندات، مما يساعد على إثبات حقيقة أن بعض الكلمات هي أكثر شيوعاً من غيرها.

TfidfVectorizer

توفر مكتبة سكيلر (Sklearn) أداة تدعم هذا النوع من البرمجة الاتجاهية لتكرار المصطلح-تكرار المستند العكسي (TF-IDF). يمكن استخدام أداة TfidfVectorizer لتمثيل عبارة باستخدام المتجهات.

```
from sklearn.feature_extraction.text import TfidfVectorizer

# Train a TF-IDF model with the IMDb training dataset
vectorizer_tf = TfidfVectorizer(min_df=10)
vectorizer_tf.fit(X_train_text_annotated)
X_train_tf = vectorizer_tf.transform(X_train_text_annotated)
```

يمكن الآن إدخال أداة التمثيل بالمتغيرات في مُصنف بايز الساذج لبناء خط أنابيب نموذج تبُّوئي جديد وتطبيقه على بيانات اختبار IMDb:

```
# train a new Naive Bayes Classifier on the newly vectorized data.  
model_tf = MultinomialNB()  
model_tf.fit(X_train_v2, Y_train)  
  
# create a new prediction pipeline.  
prediction_pipeline_tf = make_pipeline(vectorizer_tf, model_tf)  
  
# get predictions using the new pipeline.  
predictions_tf = prediction_pipeline_tf.predict(X_test_text_annotated)  
  
# print the achieved accuracy.  
accuracy_score(Y_test, predictions_tf)
```

0.8858

يحقق خط الأنابيب الجديد دقة تصل إلى 88.58%， وهو تحسُّن كبير بالمقارنة مع الدقة السابقة التي وصلت إلى 84.68%. يمكن الآن استخدام النموذج المُحسَّن لإعادة النظر في مثال الاختبار الذي تم تصنيفه بشكل خاطئ بواسطة النموذج الأول:

```
# get the review example that confused the previous algorithm  
mistake_example_annotated=X_test_text_annotated[4600]  
  
print('\nReview:', mistake_example_annotated)  
  
# get the correct labels of this example.  
print('\nCorrect Label:', class_names[Y_test[4600]])  
  
# get the prediction probabilities for this example.  
print('\nPrediction Probabilities for neg, pos:', prediction_pipeline_  
tf.predict_proba([mistake_example_annotated]))
```


Review: iPersonally thought the movie was_pretty good very_good acting by tadanobu_asano of ichi_the_killer fame i really can_t say much about the story but there_were parts that confused me a little_too much and overall i_thought the movie was just too lengthy other_than that however the movie contained superb_acting great fighting and a lot of the locations were beautifully_shot great effects and a lot of sword play another solid effort by tadanobu_asano in my_opinion well i really can_t say anymore about the movie but if_you re only outlook on asian_cinema is crouching_tiger hidden_dragon or house of flying_daggers i_would suggest_you trying to rent_it but if_you re a die_hard asian_cinema fan i_would say this has to be in your_collection very_good japanese film

Correct Label: pos

Prediction Probabilities for neg, pos: [[0.32116538 0.67883462]]

يتتبأ خط الأنابيب الجديد بشكل صحيح بالقيمة الإيجابية لهذا التقييم. يستخدم المقطع البرمجي التالي مفسّر النموذج المحايد المحلي القابل للتفسير والشرح (LIME) لتفسير المنطق وراء هذا التنبؤ:

```
# create an explainer.  
explainer_tf = LimeTextExplainer(class_names=class_names)  
  
# explain the prediction of the second pipeline for this example.  
exp = explainer_tf.explain_instance(mistake_example_annotated, prediction_pipeline_tf.predict_proba, num_features=10)  
  
# visualize the results.  
fig = exp.as_pyplot_figure()
```



شكل 3.14: تأثير الكلمة في مزيج تكرار المصطلح- تكرار المستند العكسي ومصنف بايز الساذج

تؤكد النتائج أن خط الأنابيب الجديد يتبع منطقاً أكثر ذكاءً. فهو يحدد بشكل صحيح المشاعر الإيجابية للعبارات مثل: *beautifully_shot* (لقطة _ جميلة)، و *superb_acting* (تمثيل_ رائع)، و *very good* (جيد جداً)، ولا يمكن تضليله باستخدام الكلمات التي جعلت خط الأنابيب الأول يتتبأ بنتائج خاطئة.

يمكن تحسين أداء خط الأنابيب لنموذج التنبؤ بطرائق متعددة، بإستبدال مصنف بايز البسيط بطرائق أكثر تطوراً مع ضبط متغيراتها لزيادة احتماليتها. وثمة خيار آخر يتلخص في استخدام تقنيات البرمجة الاتجاهية البديلة التي لا تستند إلى تكرار الرمز، مثل تضمين الكلمات والنصوص، وسيُستعرض ذلك في الدرس التالي.

تمرينات

1

خاطئة	صحيحة	حدد الجملة الصحيحة والجملة الخاطئة فيما يلي:
<input type="radio"/>	<input checked="" type="radio"/>	1. في التعلم الموجه تُستخدم مجموعات البيانات المعنونة لتدريب النموذج.
<input type="radio"/>	<input checked="" type="radio"/>	2. البرمجة الاتجاهية هي تقنية لتحويل البيانات من تنسيق متّجه رقمي إلى بيانات أولية.
<input type="radio"/>	<input checked="" type="radio"/>	3. تتطلب المصفوفة المتباعدة ذاكرة أقل بكثير من المصفوفة الكثيفة.
<input type="radio"/>	<input checked="" type="radio"/>	4. تُستخدم خوارزمية مُصنّف بايز الساذج لبناء خط أنابيب التنبؤ.
<input type="radio"/>	<input checked="" type="radio"/>	5. تكرار الكلمة في المستند يُعدُّ التمثيل الدقيق الوحيد لأهمية هذه الكلمة.

2

اشرح لماذا تتطلب المصفوفة الكثيفة مساحة من الذاكرة أكبر من المصفوفة المتباعدة.

3

حلل كيف يُستخدم العاملان الرياضيان في تكرار المصطلح - تكرار المستند العكسي (TF-IDF) لتحديد أهمية الكلمة في النص.

4

لديك `X_train_text` وهي عبارة عن مصفوفة `numpy` تتضمن مستندًا واحدًا في كل صف. لديك كذلك مصفوفة ثانية `Y_train` تتضمن قيم المستندات في `X_train_text`. أكمل المقطع البرمجي التالي بحيث يمكن استخدام تكرار المصطلح-تكرار المستند العكسي (TF-IDF) لتمثيل البيانات بالمتوجهات، وتدريب نموذج تصفيّف `MultinomialNB` على الإصدار الممثل بالمتوجهات، ثم تجميع أدلة التمثيل بالمتوجهات ونموذج التصفيّف في خط أنابيب تنبؤ واحد:

```
from _____ .naive_bayes import MultinomialNB
from sklearn.pipeline import make_pipeline
from sklearn.feature_extraction.text import _____
vectorizer = _____(min_df=10)
vectorizer.fit(_____) # fits the vectorizer on the training data
X_train = vectorizer._____ (X_train_text) # uses the fitted vectorizer to vectorize the data
model_MNB=MultinomialNB() # a Naive Bayes Classifier
model_MNB.fit(X_train, _____) # fits the classifier on the vectorized training data
prediction_pipeline = make_pipeline(_____, _____)
```

5

أكمل المقطع البرمجي التالي بحيث يمكنه بناء مفسّر نصوص النموذج المحايد المحلي القابل للتفسير والشرح (LIME) لخط أنابيب التنبؤ الذي قمت ببنائه في التمرين السابق، واستخدم المفسّر لتفسير التنبؤ على مثال لنص آخر.

```
from _____ import LimeTextExplainer
text_example="I really enjoyed this movie, the actors were excellent"
class_names=['neg','pos'] #creates a local explainer for explaining individual predictions
explainer = _____(class_names=class_names) # explains the prediction for this example
exp = explainer._____ (text_example.lower(),prediction_pipeline._____,_____
_____=10) # focuses the explainer on the 10 most influential features
print(exp._____) # prints the words with the highest influence on the prediction
```

التعلم غير الموجه



استخدام التعلم غير الموجه لفهم النصوص

Using Unsupervised Learning to Understand Text

التعلم غير الموجه هو نوع من تعلم الآلة، يستخدم فيه النموذج بيانات غير مُعنونة، حيث يُقدم له مجموعة من الأمثلة التي يتولى البحث فيها عن الأنماط وال العلاقات بين البيانات من تلقاء نفسه. وفي سياق فهم النص، يمكن استخدام التعلم غير الموجه في تحديد الهياكل والأنماط الكامنة ضمن مجموعة بيانات المستندات النصية. هناك العديد من التقنيات المختلفة التي يمكن استخدامها في التعلم غير الموجه للبيانات النصية، بما في ذلك خوارزميات التجميع (Clustering Algorithms)، وتقنيات تقليل الأبعاد (Dimensionality Reduction Techniques)، وتكنولوجيا النماذج التوليدية (Generative Models). تُستخدم خوارزميات التجميع لضم المستندات المشابهة معاً، بينما تُستخدم تقنيات تقليل الأبعاد لتقليل أبعاد البيانات وتحديد الخصائص الهامة. ومن ناحية أخرى، تُستخدم النماذج التوليدية لتعلم التوزيع الأساسي للبيانات وتوليد نص جديد مشابه لمجموعة البيانات الأصلية.

التعلم غير الموجه (Unsupervised Learning)

في التعلم غير الموجه، يُزود النموذج بكميات كبيرة من البيانات غير المُعنونة ويتوجب عليه البحث عن الأنماط في البيانات غير المترابطة من خلال الملاحظة والتجميع.

تقليل الأبعاد (Dimensionality Reduction)

تقنية تقليل الأبعاد هي إحدى تقنيات تعلم الآلة وتحليل البيانات المستخدمة لتقليل عدد الخصائص (الأبعاد) في مجموعة البيانات مع الاحتفاظ بأكبر قدر ممكن من المعلومات.

خوارزميات التجميع

يمكن لخوارزميات التجميع تجميع العملاء المشابهين استناداً إلى السلوكيات أو демографيا، أو سجل المشتريات؛ لأغراض التسويق المستهدف وزيادة معدلات الاحتفاظ بالعملاء.


تقنيات تقليل الأبعاد

Dimensionality Reduction Techniques

تُستخدم تقنيات تقليل الأبعاد في ضفت الصورة لتقليل عدد وحدات البكسل فيها، مما يساعد على تقليل حجم البيانات اللازمة لتمثيلها مع الحفاظ على خصائصها الرئيسية.

النماذج التوليدية


تُستخدم النماذج التوليدية في تطبيقات الكشف عن الاختلاف؛ حيث تُحدد الاختلافات في البيانات بتعلم الأنماط الطبيعية للبيانات باستخدام النموذج التوليدي.



شكل 3.15: تمثيل التعلم غير الموجه

العنقود (Cluster) :

العنقود هو مجموعة من الأشياء المتشابهة. وفي تعلم الآلة، يشير التجميع (Clustering) إلى عملية تجميع البيانات غير المعنونة في عناقيد متجانسة.



شكل 3.16: تمثيل عنقود

واحدى المزايا الرئيسية لاستخدام التعلم غير الموجه هي أنه يمكن استخدامه للكشف عن الأنماط وال العلاقات التي قد لا تبدو واضحة على الفور للمرأب البشري. وقد يكون هذا مفيداً بشكل خاص في فهممجموعات البيانات الكبيرة المكونة من النصوص غير المترابكة، حيث يكون التحليل اليدوي غير عملي. في هذه الوحدة، ستستخدم مجموعة بيانات متاحة للعامة من المقالات الإخبارية من هيئة الإذاعة البريطانية (BBC) بواسطة جرين وكوننجهام، (Greene & Cunningham, 2006) لتوضيح بعض التقنيات الرئيسية للتعلم غير الموجه. يُستخدم المقطع البرمجي التالي لتحميل مجموعة البيانات، المنظمة في خمسة مجلدات إخبارية مختلفة تمثل مقالات من أقسام إخبارية مختلفة، هي: الأعمال التجارية، والسياسة، والرياضة، والتقنية، والترفيه. لن تستخدم القيم الخمسة في توجيه أي من الخوارزميات المستخدمة في هذه الوحدة. وبدلاً من ذلك، ستُستخدم فقط لأغراض التصوير والمصادقة. يتضمن كل مجلد إخباري مئات الملفات النصية، وكل ملف يتضمن محتوى مقالة واحدة محددة. وقد حملت مجموعة البيانات بالفعل إلى مفكرة جوبيتر (Jupyter Notebook) واستقوم لبناء التعليمات البرمجية بفتح واستخراج كل المستندات والقيم المطلوبة في تركيبتين لبيانات القوائم، على التوالي.

BBC open dataset

<https://www.kaggle.com/datasets/shivamkushwaha/bbc-full-text-document-classification>

D. Greene and P. Cunningham. "Practical Solutions to the Problem of Diagonal Dominance in Kernel Document Clustering", Proc. ICML 2006. All rights, including copyright, in the content of the original articles are owned by the BBC.

```
# used to list all the files and subfolders in a given folder
from os import listdir
# used for generating random number
import random shuffling lists

bbc_docs = [] # holds the text of the articles
bbc_labels = [] # holds the news section for each article

for folder in listdir('bbc'): # for each news-section folder
    for file in listdir('bbc/' + folder): # for each text file in this folder

        # open the text file, use encoding='utf8' because articles may include non-ascii characters
        with open('bbc/' + folder + '/' + file, encoding='utf8', errors='ignore') as f:
            bbc_docs.append(f.read()) # read the text of the article and append to the docs list
        # use the name of the folder (news section) as a label for this doc
        bbc_labels.append(folder)
# shuffle the docs and labels lists in parallel
merged = list(zip(bbc_docs, bbc_labels)) # link the two lists
random.shuffle(merged) # shuffle them in parallel (with the same random order)
bbc_docs, bbc_labels = zip(*merged) # separate them again into individual lists.
```

تجميع المستندات Document Clustering

الآن بعد تحميل مجموعة البيانات فإن الخطوة التالية هي تجربة عدة طرائق غير موجّهة، ومنها: التجميع الذي يُعدّ الطريقة غير الموجّهة الأكثر شهرة في هذا النطاق. وبالنظر إلى مجموعة من المستندات غير المعنونة، سيكون الهدف هو تجميع الوثائق المتشابهة معاً، وفي الوقت نفسه الفصل بين الوثائق غير المتشابهة.

تجميع المستندات

(Document Clustering)

تجميع المستندات هو طريقة تُستخدم لتجميع المستندات النصية في عناقيد بناءً على تشابه محتواها.

جدول 3.2: العوامل التي تُحدد جودة النتائج

1	طريقة تمثيل البيانات بالمتّجّهات: على الرغم من أن تقنية تكرار المستند العكسي (TF-IDF) أثبتت كفاءتها وفعاليتها في هذا المجال، إلا أنّك ستعرف في هذه الوحدة على مزيد من البدائل الأكثر تطويراً وتعقيداً.
2	التعريف الدقيق للتّشابه بين مستند وآخر: بالنسبة للبيانات النصية الممثّلة بالمتّجّهات، تكون مقاييس المسافة الإقليدية وجيب التمام هما الأكثر شيوعاً، وسيُستخدم الأول في الأمثلة المشروحة في هذه الوحدة.
3	عدد العناقيد المختار: يوفر التّجميع التكتلي (AC - Agglomerative Clustering) طريقة واضحة لتحديد العدد المناسب من العناقيد ضمن مجموعة محددة من البيانات، وهو التحدّي الرئيس الذي يواجه مهام التّجميع.


تحديد عدد العناقيد

Selecting the Number of Clusters

تحديد العدد الصحيح للعناقيد هو خطوة ضرورية ضمن مهام التّجميع. للأسف، تعتمد الغالبية العظمى من خوارزميات التّجميع على المستخدم في تحديد عدد العناقيد الصحيحة ضمن المدخلات. ربما يكون للعدد المحدد تأثيراً كبيراً على جودة النتائج وقابليتها للتقسيم، ولكن هناك العديد من المقاييس أو المؤشرات التي يمكن استخدامها لتحديد عدد العناقيد.

- إحدى الطرائق الشائعة هي استخدام مقياس التراص (Compactness). يمكن القيام بذلك عن طريق حساب مجموع المسافات بين النقاط ضمن كل عنقود، وتحديد عدد العناقيد الذي يقلّل من هذا المجموع إلى الحد الأدنى.
- هناك طريقة أخرى تلخص في مقياس الفصل (Separation) بين العناقيد، مثل متوسط المسافة بين النقاط في العناقيد المختلفة، وبناء عليه، يتم تحديد عدد العناقيد الذي يرفع من هذا المتوسط.

وبشكل عملي، غالباً ما تعارض النهجيات المذكورة بالأعلى مع بعضها من حيث التوصية بأرقام مختلفة، ويمثل هذا تحدياً مشتركاً عند التعامل مع البيانات النصية بشكلٍ خاص، فعادةً ما يصعب تمييز تركيبها.



شكل 3.17: آلية حساب المسافات بين النقاط

التجميع الهرمي (Hierarchical Clustering)

التجميع الهرمي هو خوارزمية التجميع المستخدمة لتجميع البيانات في عناقيد بناءً على التشابه. في التجميع الهرمي، تُنظم نقاط البيانات في تركيب يشبه الشجرة، حيث تكون كل عقدة بمثابة عنقود، وتكون العقدة الأم هي نقطة التقاء العقد المتفرعة منها.

في التعلم غير الموجه، يشير عدد العناقيد إلى عدد المجموعات أو التصنيفات التي تقسم إليها البيانات بواسطة الخوارزمية. ويُعد تحديد عدد العناقيد الصحيح أمراً مهماً؛ لأنَّه يؤثر على دقة النتائج وقابليتها للتفسير. إذا كان عدد العناقيد كبيراً للغاية، فإنَّ المجموعات ستكون محددةً جداً دون معنى. في حين أنه إذا كان عدد العناقيد منخفضاً للغاية، فإنَّ المجموعات ستكون ممتدة على نطاق واسع جداً، ولن تستبط الترکيب الأساسي للبيانات. من الضروري تحقيق التوازن بين توفير عددٍ كافٍ من العناقيد لاستنباط أنماط ذات معنى، وألا تكون كثيرة في الوقت نفسه بالقدر الذي يجعل النتائج مُعقدة للغاية وغير مفهومة.

يُستخدم المقطع البرمجي التالي لاستيراد مكتبات محددة تُستخدم في التجميع الهرمي من بدايته حتى نهايته:

```
# used for tf-idf vectorization, as seen in the previous unit
from sklearn.feature_extraction.text import TfidfVectorizer
from sklearn.cluster import AgglomerativeClustering # used for agglomerative clustering

# used to visualize and support hierarchical clustering tasks
import scipy.cluster.hierarchy as hierarchy

# set the color palette to be used by the 'hierarchy' tool.
hierarchy.set_link_color_palette([
    'blue', 'green', 'red', 'yellow', 'brown', 'purple', 'orange', 'pink', 'black'])

import matplotlib.pyplot as plt # used for general visualizations
```

البرمجة الاتجاهية للنصوص

تطلب العديد من طرائق التعلم غير الموجه تمثيل النص الأولي بالتجهيزات في تنسيق رقمي، كما تم عرضه في الوحدة السابقة، ويستخدم المقطع البرمجي التالي أداة TfidfVectorizer التي أُستخدمت في الدرس السابق لهذا الغرض:

```
vectorizer = TfidfVectorizer(min_df=10) # apply tf-idf vectorization, ignore words that
                                         appear in more than 10 docs.

text_tfidf=vectorizer.fit_transform(bbc_docs) # fit and transform in one line

text_tfidf
```

```
<2225x5867 sparse matrix of type '<class 'numpy.float64'>'>
with 392379 stored elements in Compressed Sparse Row format>
```

الآن تحولت بيانات النص إلى تنسيق رقمي متباعد كما أُستخدمت في الدرس السابق.

يُستخدم المقطع البرمجي التالي أداة TSENVisualizer من مكتبة yellowbrick لإسقاط وتصوير النصوص الممثلة بالمتغيرات في فضاء ثالث الأبعاد:

```
%capture
!pip install yellowbrick
from yellowbrick.text import TSNEVisualizer
```

تضمين المجاور العشوائي الموزع على شكل T t-Distributed Stochastic Neighbor Embedding (T-SNE)

خوارزمية تضمين المجاور العشوائي الموزع على شكل T (T-SNE) هي خوارزمية تعلم الآلة غير الموجه المستخدمة لتقليل الأبعاد.

تقليل الأبعاد

يكون تقليل الأبعاد مفيداً في العديد من التطبيقات مثل:

- تصوير البيانات عالية الأبعاد: من الصعب تصوير البيانات في فضاء عالي الأبعاد، ولذلك تقلص الأبعاد ليسهل تصوير البيانات وفهمها في هذه الحالة.
- تبسيط النموذج: النموذج ذو الأبعاد الأقل يكون أبسط وأسهل فهماً، ويستغرق وقتاً أقل في عملية التدريب.
- تحسين أداء النموذج: يساعد تقليل الأبعاد في التخلص من التشويش وتكرار البيانات، مما يحسن أداء النموذج.

جدول 3.3: تقنيات تقليل الأبعاد

التقنية	الوصف	مثال التطبيق العملي
تحديد الخصائص (Feature Selection)	تحديد الخصائص يتضمن تحديد مجموعة فرعية من الخصائص الرئيسية.	تحتويمجموعات البيانات الطبية على مئات من أعمدة البيانات ذات الصلة بحالة المريض. يمكن لعدد قليل من هذه الخصائص مساعدة النموذج في التشخيص السليم لحالة المريض، بينما تكون السمات الأخرى غير مرتبطة بالتشخيص وقد تُشتت النموذج، وتحديد الخصائص يتتجاهل كل الخصائص بإستثناء الأكثر تميزاً منها.
تحويل الخصائص (Feature Transformation)	يتضمن تحويل الخصائص تجميع الخصائص الأصلية أو تحويلها لإنشاء مجموعة جديدة من الخصائص، واستبدال الخصائص الرئيسية إذا لم تكن هناك حاجة إليها.	إذا توقع النموذج إقامة المريض في المستشفى، يمكن إنشاء خصائص إضافية للنموذج باستخدام الخصائص الحالية لسجلات الحالة الطبية للمريض. على سبيل المثال، حساب عدد الفحوصات المخبرية المطلوبة على مدار الأسبوع الماضي، أو عدد الزيارات على مدار الشهر الماضي. وهناك مثال آخر، وهو: حساب مساحة المستطيل بإستخدام ارتفاعه وعرضه.
التعلم المتشعب (Manifold Learning)	تقنيات التعلم المتشعب، مثل تضمين المجاور العشوائي الموزع على شكل T (T-SNE) والتقرير والإسقاط المتشبّع المنتظم (Uniform Manifold Approximation and Projection - UMAP) هي تقنيات التعلم غير الموجه التي تهدف إلى الحفاظ على تركيب البيانات في الفضاء منخفض الأبعاد.	يمكن لهذه التقنيات تحويل صورة عالية الأبعاد إلى فضاء منخفض الأبعاد مع الحفاظ على الخصائص والتركيب الأساسي لها. ونظرًا لأن هذا يقلص من المساحة المطلوبة، فإنه يمكن تخزين وإرسال هذا التمثيل وإعادة بناء الصورة الأصلية مع خسارة أقل قدر من المعلومات.

إحدى الخصائص الرئيسية لتقنية تضمين المجاور العشوائي الموزع على شكل T (T-SNE) هي محاولة الحفاظ على التركيب المحلي للبيانات قدر الإمكان، حتى تقارب نقاط البيانات الشبيهة في التمثيل منخفض الأبعاد، ويتحقق ذلك بتقليل التباعد بين التوزيعين المحتملين: توزيع البيانات عالية الأبعاد، وتوزيع البيانات منخفضة الأبعاد.


مجموعة بيانات هيئة الإذاعة البريطانية الممثلة بالمتغيرات تصنف بالتأكيد كبيانات عالية الأبعاد، لأنها تتضمن بُعداً مستقلاً أي عموداً (Column) لكل كلمة فريدة تظهر في البيانات. يُحسب العدد الإجمالي للأبعاد كما يلي:

```
print('Number of unique words in the BBC documents vectors:',  
      len(vectorizer.get_feature_names_out()))
```

Number of unique words in the BBC documents vectors: 5867

يُستخدم المقطع البرمجي التالي لإسقاط 5,867 بُعداً في محوريين فقط وهما محوري X وY في الرسم البياني. يُستخدم المقطع البرمجي التالي لتصميم مخطط الانتشار حيث يمثل كل لون أحد الأقسام الإخبارية الخمسة.

```
tsne = TSNEVisualizer(colors=['blue', 'green', 'red', 'yellow', 'brown'])  
tsne.fit(text_tfidf,bbc_labels)  
tsne.show();
```




شكل 3.18: إسقاط تضمين المجاور العشوائي الموزع على شكل T (T-SNE)

يُستخدم هذا التصور قيمة ground-truth (بيانات الحقيقة المعتمدة) من القسم الإخباري (News Section) في كل مستند للكشف عن انتشار كل قيمة في إسقاط فضاء البرمجة الاتجاهية ثنائية الأبعاد. يوضح الشكل أنه على الرغم من ظهور بعض الشوائب في فراغات محددة من فضاء البيانات، إلا أن الأقسام الإخبارية الخمسة منفصلة بشكل جيد. وسنستعرض لاحقاً البرمجة الاتجاهية المحسنة للحد من هذه الشوائب.

التجميع التكتلي (AC)

التجميع التكتلي (AC) هو الطريقة الأكثر انتشاراً وفعاليةً في هذا الفضاء، فمن خلالها يمكن التغلب على هذا التحدي بتوفير طريقة واضحة لتحديد العدد المناسب من العناقيد. يستند التجميع التكتلي (AC) إلى منهجية التصميم من أسفل إلى أعلى، حيث تبدأ بحساب المسافة بين كل أزواج نقاط البيانات، ثم اختيار النقطتين الأقرب ودمجهما في عنقود واحد. تكرر هذه العملية حتى تُدمج كل نقاط البيانات في عنقود واحد، أو حتى الوصول إلى العدد المطلوب من العناقيد.



شكل 3.19: التجميع التكتلي (AC)

fx دالة linkage()

تُنفذ لغة البايثون التجميع التكتلي (AC) باستخدام دالة `linkage()`.
يجب توفير متغيرين لدالة `linkage()`:

- البيانات النصية الممثلة بالمتغيرات، ويمكن استخدام دالة `toarray()` لتحويل البيانات إلى تنسيق كثيف يمكن لهذه الدالة أن تعامل معه.
- مقاييس المسافة الذي يجب استخدامه لتحديد العناقيد التي ستُدمج أثناء عملية التجميع التكتلي. توفر عدة خيارات من مقاييس المسافة للاختيار من بينها وفقاً لمتطلبات وفضائل المستخدم، مثل المسافة الإقليدية (Euclidian)، ومسافة مانهاتن (Manhattan) ... إلخ، ولكن في هذا المشروع ستستخدم طريقة وارد (ward) القياسية.


يستخدم المقطع البرمجي التالي دالة `linkage()` من الأداة الهرمية (Hierarchy) الواردة بالأعلى لتطبيق هذه العملية على بيانات هيئة الإذاعة البريطانية الممثلة بالمتوجهات:

```
plt.figure() # create a new empty figure

# iteratively merge points and clusters until all points belong to a single cluster
# return the linkage of the produced tree
linkage_tfidf=hierarchy.linkage(text_tfidf.toarray(),method='ward')

# visualize the linkage
hierarchy.dendrogram(linkage_tfidf)


# show the figure
plt.show()
```



شكل 3.20: الرسم الشجري الهرمي لبيانات هيئة الإذاعة البريطانية

مسافة وارد Ward Distance

يُستخدم المثال أعلاه طريقة وارد (Ward) القياسية لقياس المسافة للمتغير الثاني. تستند مسافة وارد (Ward) إلى مفهوم التباين داخل العنقود، وهو مجموع المسافات بين النقاط في العنقود. في كل تكرار، تُقيّم الطريقة كل عملية دمج ممكنة بحساب التباين داخل العنقود قبل عملية الدمج وبعدها، ثم تبدأ عملية الدمج التي تحقق أقل ارتفاع في التباين. أظهرت مسافة وارد (Ward) نتائج جيدة في معالجة البيانات النصية، بالرغم من وجود العديد من الخيارات الأخرى.



شكل 3.21: مثال على طريقة وارد (Ward)

الرسم الشجري (Dendrogram) :

الرسم الشجري هو رسم تخطيطي تفرعي يوضح العلاقة الهرمية بين البيانات، ويأتي عادةً في صورة أحد مُخرجات التجميع الهرمي.

الرسم الشجري في الشكل 3.20 يعرض طريقة واضحة لتحديد عدد العناقيد. في هذا المثال، تقترح المكتبة استخدام 7 عناقيد، مع تمييز كل عنقود بلون مختلف. قد يتبنى المستخدم هذا المقترن أو يستخدم الرسم الشجري لاختيار رقم مختلف. على سبيل المثال، دُمج اللونين الأزرق والأخضر في آخر خطوة مع مجموعة العناقيد لكل الألوان الأخرى. وهكذا، سيؤدي اختيار 6 عناقيد إلى دمج اللونين الأرجواني والبرتقالي، بينما اختيار 5 عناقيد سيؤدي إلى دمج اللونين الأزرق والأخضر.

يتبنى المقطع البرمجي التالي مقترنات الأداة ويستخدم أداة التجميع التكتلي من مكتبة سكلايرن (Sklearn) لتقطيع المُخطط الشجري بعد إنشاء العناقيد السبع:

```
AC_tfidf=AgglomerativeClustering(linkage='ward',n_clusters=7) # prepare the tool,  
set the number of clusters.  
  
AC_tfidf.fit(text_tfidf.toarray()) # apply the tool to the vectorized BBC data.  
  
pred_tfidf=AC_tfidf.labels_ # get the cluster labels.  
  
pred_tfidf
```

```
array([6, 2, 4, ..., 6, 3, 5], dtype=int64)
```

لاحظ أن قيمة ground-truth (بيانات الحقيقة المعتمدة) من القسم الإخباري (News Section) في كل مستند لم تُستخدم على الإطلاق في هذه العملية. وبدلاً من ذلك، عولجت عملية التجميع استناداً إلى نص محتوى كل وثيقة على حده. إنَّ قيم بيانات الحقيقة المعتمدة مفيدة في التطبيق العملي، فهي تتيح التحقق من صحة نتائج التجميع. وقيم بيانات الحقيقة المعتمدة الحالية موجودة في قائمة `bbc_labels` (قيم_هيئة الإذاعة البريطانية).

يُستخدم المقطع البرمجي التالي قيم بيانات الحقيقة المعتمدة وثلاثة دوال مختلفة لتسجيل النقاط من مكتبة سكليرن (Sklearn) لتقييم جودة تجميع البيانات:

- تكون قيمة مؤشر التجانس (Homogeneity Score) بين 0 و 1 ويمكن زيادة هذه القيم عندما تكون كل النقاط في كل عنقود لها قيمة بيانات الحقيقة المعتمدة. وبالمثل، يحتوي كل عنقود على نقاط البيانات وحيدة التصنيف.
- تكون قيمة مؤشر راند المعدل (Adjusted Rand Score) بين -0.5 و 1.0 ويمكن زيادة هذه القيم عندما تقع كل نقاط البيانات ذات القيم نفسها في العنقود نفسه وكل نقاط البيانات ذات القيم المختلفة في عناقيد مختلفة.
- تكون قيمة مؤشر الالكمال (Completeness Score) بين 0 و 1 ويمكن زيادة هذه القيمة بتعيين كل نقاط البيانات من تصنيف محدد في العنقود نفسه.

```
from sklearn.metrics import homogeneity_score,adjusted_rand_score,completeness_score

print('\nHomogeneity score:',homogeneity_score(bbc_labels,pred_tfidf))
print('\nAdjusted Rand score:',adjusted_rand_score(bbc_labels,pred_tfidf))
print('\nCompleteness score:',completeness_score(bbc_labels,pred_tfidf))
```

Homogeneity score: 0.6224333236569846

المؤشر أقرب إلى 1 وهذا يعني أن مجموعة النصوص في العنقود تنتهي إلى قيمة واحدة.

Adjusted Rand score: 0.4630492696176891

المؤشر أقرب إلى 1 وهذا يعني إنشاء روابط أفضل بين العناقيد والقيم: كل على حده.

Completeness score: 0.5430590192420555

لاستكمال تحليل البيانات، يُعاد تجميع البيانات باستخدام 5 عناقيد، بالتساوي مع العدد الحقيقي لقيم (بيانات الحقيقة المعتمدة) ground-truth :

```
AC_tfidf=AgglomerativeClustering(linkage='ward',n_clusters=5)
AC_tfidf.fit(text_tfidf.toarray())
pred_tfidf=AC_tfidf.labels_

print('\nHomogeneity score:',homogeneity_score(bbc_labels,pred_tfidf))
print('\nAdjusted Rand score:',adjusted_rand_score(bbc_labels,pred_tfidf))
print('\nCompleteness score:',completeness_score(bbc_labels,pred_tfidf))
```

Homogeneity score: 0.528836079209762
Adjusted Rand score: 0.45628412883628383
Completeness score: 0.6075627851312266

نظرًا لقدرة التجميع الهرمي على إيجاد العدد الحقيقي من القيم، وتوفير مؤشر اكمال أكثر دقة، ستحصل على عملية تجميع أفضل من حيث تمثيل البيانات.

على الرغم من أن نتائج المؤشر تُظهر أن التجميع التكتلي باستخدام البرمجة الاتجاهية لتكرار المصطلح-تكرار المستند العكسي (TF-IDF) تحقق نتائج معقولة، إلا أنه لا يزال بالإمكان تحسين دقة عملية التجميع. سيوضح القسم التالي كيف يمكن أنتحقق نتائج مبهرة باستخدام تقنيات البرمجة الاتجاهية المستندة على الشبكات العصبية.

البرمجة الاتجاهية للكلمات باستخدام الشبكات العصبية

Word Vectorization with Neural Networks

البرمجة الاتجاهية لتكرار المصطلح-تكرار المستند العكسي (TF-IDF) تستند إلى حساب تكرار الكلمات ومعالجتها عبر المستندات في مجموعة البيانات. بالرغم من أن هذا يحقق نتائج جيدة، إلا أنَّ القيود الكبيرة تعيب الطرائق المستندة إلى التكرار. فهي تتجاهل تماماً العلاقة الدلالية بين الكلمات. على سبيل المثال، على الرغم من أن كلمتي *trip* (نزلة) و *journey* (رحلة) متراوختان، إلا أنَّ البرمجة الاتجاهية المستندة إلى التكرار ستتعامل معهما باعتبارهما كلمتان منفصلتان تماماً ولهم خصائص مستقلة. وبالمثل، بالرغم من أن كلمتي *apple* (تفاح) و *fruit* (فاكهة) مترابطتان دلائلاً؛ لأنَّ التفاح نوع من الفاكهة إلا أنَّ ذلك لن يؤخذ بعين الاعتبار أيضاً.

تؤثر هذه القيود كثيراً على التطبيقات التي تستخدم هذا النوع من البرمجة الاتجاهية. فمثلاً في الجملتين التاليتين:

• I have a very high fever, so I have to visit a doctor (لدي حمى شديدة، ويجب علي زيارة الطبيب).

My body temperature has risen significantly, so I need to see a healthcare professional • (ارتفعت درجة حرارة جسمي كثيراً، ويجب علي زيارة أخصائي الرعاية الصحية).

بالرغم من أن الجملتين تصفان الحالة نفسها إلا أنهما لا تشاركان أي كلمات دلالية. ولذلك، ستفشل خوارزميات التجميع المستندة إلى تكرار المصطلح-تكرار المستند العكسي (TF-IDF) أو أي برمجة اتجاهية (تستند إلى التكرار) في رؤية التشابه بين الكلمات، ومن المحتمل ألا تضعها في نفس العنود.

الكلمات المستبعدة (Stopwords):

الكلمات المستبعدة هي كلمات شائعة في اللغات تُستبعد عادةً أثناء المعالجة المُسبقة للنصوص ضمن مهام معالجة اللغات الطبيعية (NLP) مثل البرمجة الاتجاهية للكلمات. هذه الكلمات تشمل أدوات التعريف، وحرروف العطف، وحرروف الجر، والكلمات التي لا تكون مفيدة لتحديد معنى النص، أو سياقه.

التضمين (Embedding):

التضمين يُعبر عن الكلمات أو الرموز في فضاء المتجه المستمر حيث ترتبط الكلمات المشابهة دلائلاً مع النقاط القريبة.

هذا النموذج يربط كل كلمة بتضمين مكون من 300 بعد.

نموذج الكلمة إلى المتجه Word2Vec

يمكن معالجة هذه القيود بالطرق التي تأخذ بعين الاعتبار التشابه الدلالي بين الكلمات. إحدى الطرق الشهيرة المتبعة في هذا الصدد هي نموذج الكلمة إلى المتجه (Word2Vec) التي تستخدم بنية تستند إلى الشبكات العصبية. يستند نموذج الكلمة إلى المتجه (Word2Vec) إلى فكرة أن الكلمات المشابهة دلائلاً تحاط بكلمات مماثلة في السياق نفسه. ولذلك، نجد الشبكات العصبية تستخدم التضمين الخفي لكل كلمة للتنبؤ بالسياق، مع ضرورة إنشاء الروابط بين الكلمات والتضمينات الشبيهة. عملياً، يخضع نموذج الكلمة إلى المتجه (Word2Vec) للتدريب المسبق على ملايين المستندات لتعلم التضمين عالي الدقة للكلمات. يمكن تحميل النماذج المدربة مسبقاً واستخدامها في التطبيقات المستندة إلى النصوص. يستخدم المقطع البرمجي التالي مكتبة جينسم (Gensim) لتحميل نموذج شهير مدرب مسبقاً على مجموعة كبيرة جداً من أخبار قوقل (Google News) :

```
import gensim.downloader as api  
model_wv = api.load('word2vec-google-news-300')  
fox_emb=model_wv['fox']  
print(len(fox_emb))
```

300

الأبعاد العشرة الأولى للتضمين العددي لكلمة fox (ثعلب) موضحة بالأمثلة:

```
fox_emb[:10]
```

```
array([-0.08203125, -0.01379395, -0.3125, -0.04125977, 0.05493164,  
       -0.12988281, -0.10107422, -0.00164795, 0.15917969, 0.12402344],  
       dtype=float32)
```

يُستخدم النموذج تضمينات الكلمات لتقييم درجة التشابه. فكُر في المثال التالي حيث تُظهر المقارنة بين كلمة car (السيارة) والكلمات الأخرى درجة التشابه من خلال تناقص قيمة التشابه. علماً بأن قيمة التشابه تقع دوماً بين 0 و 1.

```
pairs = [  
    ('car', 'minivan'),  
    ('car', 'bicycle'),  
    ('car', 'airplane'),  
    ('car', 'street'),  
    ('car', 'apple'),  
]  
for w1, w2 in pairs:  
    print(w1, w2, model_wv.similarity(w1, w2))
```

```
car minivan 0.69070363  
car bicycle 0.5364484  
car airplane 0.42435578  
car street 0.33141237  
car apple 0.12830706
```

يمكن استخدام المقطع البرمجي التالي للعثور على الكلمات الخمسة المشابهة لـحدى الكلمات:

```
print(model_wv.most_similar(positive=['apple'], topn=5))
```

```
[('apples', 0.720359742641449), ('pear', 0.6450697183609009),  
 ('fruit', 0.6410146355628967), ('berry', 0.6302295327186584), ('pears',  
 0.613396167755127)]
```

يمكن استخدام التصوير في التحقق من صحة تضمينات هذا النموذج المدرب مسبقاً، ويمكن تحقيق ذلك عبر:

- تحديد نماذج الكلمات من مجموعة بيانات هيئة الإذاعة البريطانية.
- استخدام تضمين المجاور العشوائي الموزع على شكل T (T-SNE) لتخفيض التضمين ذي الـ 300 بعدٍ لكل كلمة إلى نقطة ثنائية الأبعاد.
- تصوير النقاط في مخطط الانتشار في الفضاء ثنائي الأبعاد.



```

%%capture
import nltk # import the nltk library for nlp.
import re # import the re library for regular expressions.
import numpy as np # used for numeric computations
from collections import Counter # used to count the frequency of elements in a given list
from sklearn.manifold import TSNE # Tool used for Dimensionality Reduction.

# download the 'stopwords' tool from the nltk library. It includes very common words for different
languages
nltk.download('stopwords')

from nltk.corpus import stopwords # import the 'stopwords' tool.

stop=set(stopwords.words('english')) # load the set of english stopwords.

```

تُستخدم الدالة الآتية لاحقًا لتحديد عينة من الكلمات التمثيلية من مجموعة بيانات هيئة الإذاعة البريطانية. يُحدّد المقطع البرمجي الكلمات الخمسين الأكثر تكراراً على وجه التحديد من الأقسام الإخبارية الخمسة لهيئة الإذاعة البريطانية مع استثناء الكلمات **المُستبعدة** (Stopwords) وهي الكلمات الإنجلizية الشائعة جداً والكلمات التي لم تُضمن في نموذج الكلمة إلى المتجه (Word2Vec) المُدرّب مسبقاً.

```

def get_sample(bbc_docs:list,
              bbc_labels:list
              ):

    word_sample=set() # a sample of words from the BBC dataset

    #for each BBC news section
    for label in ['business', 'entertainment', 'politics', 'sport', 'tech']:

        # get all the words in this news section, ignore stopwords.
        #for each BBC doc and for each word in the BBC doc
        #if the word belongs to the label and is not a stopword and is included in the Word2Vec model
        label_words=[word for i in range(len(bbc_docs))
                     for word in re.findall(r'\b\w\w+\b',bbc_docs[i].lower())
                     if bbc_labels[i]==label and
                     word not in stop and
                     word in model_wv]

        cnt=Counter(label_words) #count the frequency of each word in this news section.

        #get the top 50 most frequent words in this section.
        top50=[word for word,freq in cnt.most_common(50)]
        #add the top50 words to the word sample.
        word_sample.update(top50)


    word_sample=list(word_sample) #convert the set to a list.
    return word_sample

word_sample=get_sample(bbc_docs,bbc_labels)

```

بعض الكلمات الإنجلizية الشائعة التي تُعدُّ كلمات مُستبعدة هي a (أ) و the (ال) و is (يكون) و are (يكونون). (Stopwords)

وأخيراً، ستستخدم طريقة تضمين المجاور العشوائي الموزع على شكل T (T-SNE) لتخفيض التضمينات ذات الـ 300 بُعد للكلمات في العينة ضمن النقاط ثنائية الأبعاد. بعدها، تمثل النقاط في مخطط انتشار بسيط.



شكل 3.22: تمثيل الكلمات الأكثر تكراراً من مجموعة بيانات هيئة الإذاعة البريطانية

يُثبت المخطط أن تضمينات نموذج الكلمة إلى المتجه (Word2Vec) تستنبط الارتباطات الدلالية بين الكلمات، كما يتضح من مجموعات الكلمات الواضحة مثل:

- economy (الاقتصاد)، financial (الأعمال)، business (الاقتصادية)، sales (المبيعات)،
- bank (المصرف)، firm (الشركة)، firms (الشركات).
- Internet (الإنترنت)، mobile (الهاتف المحمول)، phone (الهاتف)، phones (الهواتف)، digital (رقمي)، broadband (النطاق العريض).
- actor (ممثل)، actress (ممثلة)، film (فيلم)، comedy (كوميدي)، films (أفلام)، festival (مهرجان)، movie (فلم)، band (فرقة).
- game (لعبة)، team (فريق)، coach (مدرب)، players (لاعبون)، match (مباراة)، injury (إصابة)، club (نادي)، rugby (الرجبي).

البرمجة الاتجاهية للجمل باستخدام التعلم العميق

Sentence Vectorization with Deep Learning

على الرغم من إمكانية استخدام نموذج الكلمة إلى المتجه (Word2Vec) في نمذجة الكلمات الفردية، يتطلب التجميع البرمجة الاتجاهية للنص بأكمله. إحدى الطرائق الأكثر شهرة لتحقيق ذلك هي تمثيلات ترميز الجمل ثنائية الاتجاه من المحولات (SBERT) المستندة إلى منهجية التعلم العميق.

تمثيلات الترميز ثنائية الاتجاه من المحولات

Bidirectional Encoder Representations from Transformers (BERT)

تمثيلات الترميز ثنائية الاتجاه من المحولات (BERT) هي نموذج تمثيل لغوي قوي طورته شركة قوقل، وبعد التدريب المُسبق والضبط الدقيق عاملاً رئيسيّاً وراء قدرة تمثيلات الترميز ثنائية الاتجاه من المحولات (BERT) على تطبيق نقل التعلم، أي القدرة على الاحتفاظ بالمعلومات حول مشكلة ما والاستفادة منها في حل مشكلة أخرى، ويتم التدريب المُسبق عبر تغذية النموذج بكمية هائلة من البيانات غير المعنونة لعدة مهام، مثل التنبؤ اللغوي المُقنع (إخفاء الكلمات العشوائية في مدخلات النصوص والمُهمة هي التنبؤ بهذه الكلمات). يُهيئ نموذج تمثيلات الترميز ثنائية الاتجاه من المحولات (BERT) المتغيرات المُدربة مُسبقاً للضبط الدقيق، كما تُستخدم مجموعات البيانات المعنونة من المهام النهائية لضبط دقة عمل النموذج، ويكون لكل مُهمة نهائية نماذج دقيقة منفصلة، برغم أنها مُهيأة بالمتغيرات المُدربة نفسها مُسبقاً. على سبيل المثال، تختلف عملية الضبط الدقيق لنموذج تحليل المشاعر عن نموذج الإجابة على الأسئلة. ومن المهم معرفة أن الفروقات في بنية النماذج تصبح ضئيلة أو منعدمة بعد خطوة ضبط الدقة.

تمثيلات ترميز الجمل ثنائية الاتجاه من المحولات SBERT

تمثيلات ترميز الجمل ثنائية الاتجاه من المحولات (SBERT) هي الإصدار المُعدل من تمثيلات الترميز ثنائية الاتجاه من المحولات (BERT). تُدرّب تمثيلات الترميز ثنائية الاتجاه من المحولات (BERT) مثل نموذج الكلمة إلى المتجه (Word2Vec) للتنبؤ بالكلمات بناءً على سياق الجمل الواردة بها. ومن ناحية أخرى، تُدرّب تمثيلات ترميز الجمل ثنائية الاتجاه من المحولات (SBERT) للتنبؤ بما إذا كانت جملتان متتشابهتين دلائلاً. تُستخدم تمثيلات ترميز الجمل ثنائية الاتجاه من المحولات (SBERT) لإنشاء تضمينات لأجزاء النصوص الأطول من الجمل، مثل الفقرات، أو النصوص القصيرة، أو المقالات في مجموعة بيانات هيئة الإذاعة البريطانية محل الدراسة في هذه الوحدة. بالرغم من أن النماذج الثلاث تستند جميعها إلى الشبكات العصبية، إلا أن تمثيلات الترميز ثنائية الاتجاه من المحولات (BERT) وتمثيلات ترميز الجمل ثنائية الاتجاه من المحولات (SBERT) تتفانان في بنية مختلفة بشكل كبير وأكثر تعقيداً من نموذج الكلمة إلى المتجه (Word2Vec).

مكتبة الجمل والمحولات Sentence_transformers Library

تُطبق مكتبة الجمل والمحولات (sentence_transformers) الوظائف الكاملة لنموذج تمثيلات ترميز الجمل ثنائية الاتجاه من المحولات (SBERT). تأتي المكتبة بالعديد من نماذج تمثيلات ترميز الجمل ثنائية الاتجاه من المحولات (SBERT) المُدربة مُسبقاً؛ كل منها مدرب على مجموعة بيانات مختلفة ولتحقيق أهداف مختلفة. يعمل المقطع البرمجي التالي على تحميل أحد النماذج العامة الشهيرة المُدربة مُسبقاً، ويستخدمها لإنشاء تضمينات للمستندات في مجموعة بيانات هيئة الإذاعة البريطانية:


```
%capture
!pip install sentence_transformers
from sentence_transformers import SentenceTransformer

model = SentenceTransformer('all-MiniLM-L6-v2') # load the pre-trained model.

text_emb = model.encode(bbc_docs) # embed the BBC documents.
```

لقد استخدمت في وقت سابق في هذه الوحدة أداة تضمين المجاور العشوائي الموزع على شكل T والتي هي (TSNEVisualizer)، لتصوير المستندات الممثلة بالتجهيزات المنتجة باستخدام أداة تكرار المصطلح-تكرار المستند العكسي (TF-IDF). يمكن الآن استخدامها للتضمينات المنتجة بواسطة تمثيلات ترميز الجمل ثنائية الاتجاه من المحولات (SBERT) :

```
tsne = TSNEVisualizer(colors=['blue','green','red','yellow','brown'])
tsne.fit(text_emb,bbc_labels)
tsne.show();
```




شكل 3.23: إسقاط تضمين المجاور العشوائي الموزع على شكل T-SNE (T-SNE) للتضمينات المنتجة بواسطة تمثيلات ترميز الجمل ثنائية الاتجاه من المحولات (SBERT)

يوضح الشكل أن تمثيلات ترميز الجمل ثنائية الاتجاه من المحولات (SBERT) تؤدي إلى فصل أكثر وضوحاً للأقسام الإخبارية المختلفة مع عدد أقل من الشوائب من تكرار المصطلح-تكرار المستند العكسي (TF-IDF). الخطوة التالية هي استخدام التضمينات لتدريب خوارزمية التجميع التكتلي:

```
plt.figure() # create a new figure.

# iteratively merge points and clusters until all points belong to a single cluster. Return the linkage of the produced tree.
linkage_emb=hierarchy.linkage(text_emb, method='ward')

hierarchy.dendrogram(linkage_emb) # visualize the linkage.
plt.show() # show the figure.
```



شكل 3.24: الرسم الشجري الهرمي لتمثيلات ترميز الجمل ثنائية الاتجاه من المحولات (SBERT)

كما هو موضح في الشكل 3.24، فإن أداة الرسم الشجري تشير إلى 4 عناقيد، كل واحد منها مُميز بلون مختلف. يُستخدم المقطع البرمجي التالي هذا المقترن لحساب العناقيد وحساب مقاييس التقييم:

```
AC_emb=AgglomerativeClustering(linkage='ward',n_clusters=4)
AC_emb.fit(text_emb)
pred_emb=AC_emb.labels_

print('\nHomogeneity score:',homogeneity_score(bbc_labels,pred_emb))
print('\nAdjusted Rand score:',adjusted_rand_score(bbc_labels,pred_emb))
print('\nCompleteness score:',completeness_score(bbc_labels,pred_emb))
```

```
Homogeneity score: 0.6741395570357063
Adjusted Rand score: 0.6919474005627763
Completeness score: 0.7965514907905805
```

إذا كانت البيانات قد تم إعادة تجميعها باستخدام العدد الصحيح من 5 عناقيد، فالعنقود الأصفر المحدد بالشكل أعلاه سينقسم إلى اثنين، وستكون النتائج على النحو التالي:

```
AC_emb=AgglomerativeClustering(linkage='ward',n_clusters=5)
AC_emb.fit(text_emb)
pred_emb=AC_emb.labels_

print('\nHomogeneity score:',homogeneity_score(bbc_labels,pred_emb))
print('\nAdjusted Rand score:',adjusted_rand_score(bbc_labels,pred_emb))
print('\nCompleteness score:',completeness_score(bbc_labels,pred_emb))
```

```
Homogeneity score: 0.7865655030556284
Adjusted Rand score: 0.8197670431956582
Completeness score: 0.7887580797775077
```

تُظهر النتائج أن استخدام تمثيلات ترميز الجمل ثنائية الاتجاه من المحولات (SBERT) في البرمجة الاتجاهية للنصوص يَنتج عنه نتائج تجميع مُحسنة بِالمقارنة مع تكرار المصطلح-تكرار المستند العكسي (TF-IDF). إذا كان عدد العناقيد هو 5 لتكرار المصطلح-تكرار المستند العكسي (TF-IDF) (القيمة الصحيحة) و4 عنقides لتمثيلات ترميز الجمل ثنائية الاتجاه من المحولات (SBERT)، فإن المقاييس الثلاثة لتمثيلات ترميز الجمل ثنائية الاتجاه من المحولات (SBERT) لا تزال هي الأعلى بفارق كبير. ثم تزداد الفجوة إذا كان العدد 5 لكلٍ من الطريقتين. وهذا يُعد دليلاً على إمكانات الشبكات العصبية، التي تسمح لها ببنيتها المتغيرة بفهم الأنماط الدلالية المعقّدة في البيانات النصية.

تمرينات

1

خاطئة	صحيحة	حدد الجملة الصحيحة والجملة الخاطئة فيما يلي:
<input type="radio"/>	<input type="radio"/>	1. في التعلم غير الموجه تُستخدم مجموعات البيانات المعنونة لتدريب النموذج.
<input type="radio"/>	<input type="radio"/>	2. يتطلب التعلم غير الموجه البرمجة الاتجاهية للبيانات.
<input type="radio"/>	<input type="radio"/>	3. تمثيلات ترميز الجمل ثنائية الاتجاه من المحولات (SBERT) تُعدُّ أفضل من تكرار المصطلح-تكرار المستند العكسي (TF-IDF) للبرمجة الاتجاهية للكلمات.
<input type="radio"/>	<input type="radio"/>	4. يتبع التجميع التكتلي منهجية التصميم من أعلى إلى أسفل لتحديد العناقيد.
<input type="radio"/>	<input type="radio"/>	5. تمثيلات ترميز الجمل ثنائية الاتجاه من المحولات (SBERT) مدربة للتنبؤ بما إذا كانت جملتان مختلفتين دلالياً.

2

استعرض بعض التطبيقات التي يستخدم فيها تقليص الأبعاد، وصف التقنيات المستخدمة فيه.

3

اشرح وظائف البرمجة الاتجاهية لقياس تكرار المصطلح-تكرار المستند العكسي (TF-IDF).

4

لديك مصفوفة 'Docs' تدعى numPy تتضمن مستندًا نصيًّا واحدًا في كل صف. لديك كذلك مصفوفة labels تتضمن قيم كل مستند في Docs. أكمل المقطع البرمجي التالي بحيث تستخدم نموذج تمثيلات ترميز الجمل ثنائية الاتجاه من المحولات (SBERT) المُدرَّب مُسبقاً لحساب تمثيلات كل الوثائق في Docs، ثم استخدم أداة TSNEVisualizer لتضمين المجاور العشوائي الموزع على شكل T تصوير التمثيلات في الفضاء ثنائي الأبعاد، باستخدام لون مختلف لكل واحد من القيم الأربع المحتملة:

```
from sentence_transformers import _____  
  
from _____ import TSNEVisualizer model = _____('all-MiniLM-L6-v2') # loads the pre-trained model.  
  
docs_emb = model._____ (Docs) # embeds the docs  
  
tsne = _____ ([ 'blue', 'green', 'red', 'yellow' ])  
  
tsne._____ ( _____ , _____ )  
tsne.show();
```

5

أكمل المقطع البرمجي التالي بحيث تستخدم نموذج الكلمة إلى المتجه (Word2Vec) لاستبدال كل كلمة في إحدى الجمل بأخرى تكون أكثر شبهاً بها:

```
import gensim.downloader as _____  
import re  
  
model_wv = _____ ('word2vec-google-news-300')  
old_sentence='My name is John and I like basketball.'  
new_sentence=''  
  
for word in re._____ (r'\b\w\w+\b', old_sentence.lower()):  
  
    replacement=model_wv._____ (positive=[ 'apple' ], _____ =1)[0]  
  
    new_sentence+=_____  
sentence=new_sentence.strip()
```

توليد النص

رابط الدرس الرقمي



www.ien.edu.sa

Natural Language Generation (NLG)


توليد اللغات الطبيعية (NLG) هو أحد فروع معالجة اللغات الطبيعية (NLP) التي ترتكز على توليد النصوص البشرية باستخدام خوارزميات الحاسوب. الهدف من توليد اللغات الطبيعية (NLG) هو توليد اللغات المكتوبة أو المنطقية بصورة طبيعية ومفهومة للبشر دون الحاجة إلى تدخل بشري. توجد العديد من المنهجيات المختلفة لتوليد اللغات الطبيعية مثل: المنهجيات المستندة إلى القواعد، والمستندة إلى القواعد، والمستندة إلى تعلم الآلة.

معالجة اللغات الطبيعية (Natural Language Processing-NLP)

معالجة اللغات الطبيعية (NLP) هو أحد فروع الذكاء الاصطناعي الذي يمنح أجهزة الكمبيوتر القدرة على محاكاة اللغات البشرية الطبيعية.

توليد اللغات الطبيعية (Natural Language Generation-NLG)

توليد اللغات الطبيعية (NLG) هي عملية توليد النصوص البشرية باستخدام الذكاء الاصطناعي (AI).



شكل 3.25: مخطط فن (Venn) لمعالجة اللغات الطبيعية (NLP)

جدول 3.4: تأثير توليد اللغات الطبيعية

<p>يُستخدم توليد اللغات الطبيعية (NLG) لتوليد المقالات والتقارير الإخبارية، والمحتوى المكتوب آلياً مما يوفر الوقت، ويساعد الأشخاص في التركيز على المهام الإبداعية أو المهام عالية المستوى.</p>	
<p>يمكن الاستفادة من ذلك في تحسين كفاءة وفعالية روبوت الدردشة لخدمة العملاء وتمكينه من تقديم ردود طبيعية ومفيدة لأسئلتهم واستفساراتهم.</p>	
<p>يمكن الاستفادة من توليد اللغات الطبيعية (NLG) في تحسين إمكانية الوصول لذوي الإعاقة أو لذوي الحاجز اللغوي، بتمكينهم من التواصل مع الآلات بطريقة طبيعية وبديهية تناسبهم.</p>	

هناك أربع أنواع من توليد اللغات الطبيعية (NLG) :

توليد اللغات الطبيعية المبني على القوالب Selection-Based NLG

يتضمن توليد اللغات الطبيعية المبني على الاختيار تحديد مجموعة فرعية من الجمل أو الفقرات لإنشاء ملخص للنص الأصلي الأكبر حجمًا. بالرغم من أن هذه المنهجية لا تُولد نصوصًا جديدة، إلا أنها مُطبقة عمليًا على نطاق واسع؛ وذلك لأنها تأخذ العينات من مجموعة من الجمل المكتوبة بواسطة البشر، يمكن الحد من مخاطرة توليد النصوص غير المتنبئ بها أو ضعيفة البنية. على سبيل المثال، مُولد تقرير الطقس المبني على الاختيار قد يضم قاعدة بيانات من العبارات مثل: It is hot outside (الطقس حار بالخارج)، و The temperature is rising (درجة الحرارة ترتفع)، و Expect sunny skies (تنبؤات بطقس مشمس).

Template-Based NLG

يتضمن توليد اللغات الطبيعية المبني على القوالب استخدام قوالب محددة مسبقًا تحدد بنية ومحظى النص المولد. تزود هذه القوالب بمعلومات محددة لتوليد النص النهائي. تُعد هذه المنهجية بسيطة نسبيًا وتحقق فعالية في توليد النصوص للمهام المحددة والمعرفة جيدًا. من ناحية أخرى، قد تواجه صعوبة مع المهام المفتوحة أو المهام التي تتطلب درجة عالية من التباين في النص المولد. على سبيل المثال، قالب تقرير حالة الطقس ربما يبدو كمالي: Today in [city], it is [temperature] degrees (اليوم في [المدينة]، درجة الحرارة هي [درجة الحرارة] مئوية و[حالة الطقس]).

توليد اللغات الطبيعية المبني على تعلم الآلة Machine Learning-Based NLG

يتضمن توليد اللغات الطبيعية المبني على تعلم الآلة تدريب نموذج تعلم الآلة على مجموعة كبيرة من بيانات النصوص البشرية. يتعلم النموذج أنماط النص وبنيته، ومن ثم يمكنه توليد النص الجديد الذي يشبه النص البشري في الأسلوب والمحظى. قد تكون المنهجية أكثر فعالية في المهام التي تتطلب درجة عالية من التباين في النص المولد. وقد تتطلب المنهجيةمجموعات أكبر من بيانات التدريب والموارد الحسابية.


توليد اللغات الطبيعية المبني على القواعد Rule-Based NLG

يستخدم توليد اللغات الطبيعية المبني على القواعد مجموعة من القواعد المحددة مسبقًا لتوليد النص. قد تحدد هذه القواعد طريقة تجميع الكلمات والعبارات لتشكيل الجمل، أو كيفية اختيار الكلمات وفقاً للسياق المستخدمة فيه. عادةً تُستخدم هذه القواعد لتصميم روبوت الدردشة لخدمة العملاء. قد يكون من السهل تطبيق الأنظمة المبنية على القواعد. وفي بعض الأحيان قد ترسم بالجملة ولا تُولد مخرجات تبدو طبيعية.

استخدام توليد اللغات الطبيعية المبني على القوالب

توليد اللغات الطبيعية المبني على القوالب بسيط نسبيًا وقد يكون فعالًا في توليد النصوص للمهام المحددة والمعرفة مثل إنشاء التقارير أو توصيف البيانات. إحدى مميزات توليد اللغات الطبيعية المبني على القوالب هو سهولة التطبيق والصيانة. يُصمّم الأشخاص القوالب، دون الحاجة إلى خوارزميات تعلم الآلة المعقدة أومجموعات كبيرة من بيانات التدريب. وهذا يجعل توليد اللغات الطبيعية المبني على القوالب هو الخيار المناسب للمهام التي تكون ذات بنية ومحظى نص محددين، دون الحاجة إلى إجراء تغييرات كبيرة. تستند قوالب توليد اللغات الطبيعية (NLG) إلى أي بنية لغوية محددة مسبقًا. إحدى الممارسات الشائعة هي إنشاء القوالب التي تتطلب كلمات بوسوم محددة كجزء من الكلام لإدراجها في الفراغات المحددة ضمن الجملة.

وسوم أقسام الكلام (POS) Tags



شكل 3.26: مثال على عملية وسم أقسام الكلام

وسوم أقسام الكلام (Part Of Speech)، التي تُعرَّف كذلك باسم POS هي قيم تُخصَّص للكلمات في النص للإشارة إلى البناء النحووي للكلمات، أو جزء الكلام في الجملة. على سبيل المثال، قد تكون الكلمة اسمًا أو فعلًا أو صفةً أو ظرفًا، إلخ، وتُستخدم وسوم أقسام الكلام في معالجة اللغات الطبيعية (NLP) لتحليل بنية النص وفهم معناه.

تحليل بناء الجمل Syntax Analysis

يُستخدم تحليل بناء الجمل عادةً إلى جانب وسوم أقسام الكلام (POS) في توليد اللغات الطبيعية المبنية على القوالب لضمان قدرة القوالب على توليد النصوص الواقعية. يتضمن تحليل بناء الجمل التعرف على أجزاء الكلام في الجمل، والعلاقات بينها لتحديد البناء النحوي للجملة. تتضمن الجملة أنواعاً مختلفة من عناصر بناء الجملة، مثل:

- الفعل (Predicate) هو قسم الجملة الذي يحتوي على الفعل. وهو عادةً يعبر عمّا يقوم به الفاعل أو عمّا يحدث.
- الفاعل (Subject) هو قسم الجملة الذي ينفذ الفعل.

يُستخدم المقطع البرمجي التالي مكتبة ووندروورذ (Wonderwords) التي تتبع منهجية بناء الجمل لعرض بعض الأمثلة على توليد اللغات الطبيعية المبنية على القوالب.

```
%capture
```

```
!pip install wonderwords
# used to generate template-based randomized sentences
from wonderwords import RandomSentence

# make a new generator with specific words
generator=RandomSentence(
    # specify some nouns
    nouns=["lion", "rabbit", "horse", "table"],
    verbs=["eat", "run", "laugh"], # specify some verbs.
    adjectives=['angry', 'small']) # specify some adjectives.

# generates a sentence with the following template: [subject (noun)] [predicate (verb)]
generator.bare_bone_sentence()
```

```
'The table runs.'
```

```
# generates a sentence with the following template:
# the [(adjective)] [subject (noun)] [predicate (verb)] [direct object (noun)]
generator.sentence()
```

```
'The small lion runs rabbit.'
```

توضح الأمثلة بالأعلى أنه، بينما يستخدم توليد اللغات الطبيعية المبنية على القوالب لتوليد الجمل وفق بنية محددة ومعتمدة مسبقاً، إلا أن هذه الجمل قد لا تكون ذات مغزى عملي. وعلى الرغم من إمكانية تحسين دقة النتائج إلى حد كبير بتحديد قوالب متطرفة ووضع المزيد من القيود على استخدام المفردات، إلا أن هذه المنهجية غير عملية لتوليد النصوص الواقعية على نطاقٍ واسع. فبدلاً من إنشاء القوالب المحددة مسبقاً، تُستخدم المنهجية الأخرى لتوليد اللغات الطبيعية القائمة على القوالب البنية والمفردات نفسها المكونة لأي جملة حقيقة ك قالب ديناميكي متغير. تتبنى دالة () `paraphrase` هذه المنهجية.

Paraphrase() دالة

نُقسم الدالة في البداية النص المكون من فقرة إلى مجموعة من الجمل. ثم تحاول استبدال كل كلمة في الجملة بكلمة أخرى متشابهة دلائلاً. يُقيّم التشابه الدلالي بواسطة نموذج الكلمة إلى المتجه (Word2Vec) الذي درسته في الدرس السابق. قد يوصي نموذج الكلمة إلى المتجه (Word2Vec) باستبدال الكلمة في الجملة بكلمة أخرى مشابهة لها، مثل: استبدال apple (تفاح) بـ apples (تفاح)، ولتجنب مثل هذه الحالات تُستخدم دالة مكتبة **fuzzywuzzy** الشهيرة لتقدير تشابه المفردات بين الكلمة الأصلية والكلمة البديلة.

الدالة نفسها موضحة بالأمثلة:

```
def paraphrase(text:str, #text to be paraphrased
               stop:set, #set of stopwords
               model_wv,# Word2Vec Model
               lexical_sim_ubound:float, #upper bound on lexical similarity
               semantic_sim_lbound:float #lower bound on semantic similarity
               ):
    words=word_tokenize(text) #tokenizes the text to words
    new_words=[] #new words that will replace the old ones.

    for word in words: #for every word in the text
        word_l=word.lower() #lower-case the word.

        #if the word is a stopword or is not included in the Word2Vec model, do not try to replace it.
        if word_l in stop or word_l not in model_wv:
            new_words.append(word) #append the original word

        else: #otherwise
            #get the 10 most similar words, as per the Word2Vec model.
            #returned words are sorted from most to least similar to the original.
            #semantic similarity is always between 0 and 1.
            replacement_words=model_wv.most_similar(positive=[word_l],
topn=10)
            #for each candidate replacement word
            for rword, sem_sim in replacement_words:
                #get the lexical similarity between the candidate and the original word.
                #the partial_ratio function returns values between 0 and 100.
                #it compares the shorter of the two words with all equal-sized substrings
                #of the original word.
                lex_sim=fuzz.partial_ratio(word_l,rword)

                #if the lexical sim is less than the bound, stop and use this candidate.
                if lex_sim<lexical_sim_ubound:
                    break
```

fuzzywuzzy تشير إلى مكتبة

```
# quality check: if the chosen candidate is not semantically similar enough to  
# the original, then just use the original word.
```

```
if sem_sim < semantic_sim_lbound:  
    new_words.append(word)  
else: # use the candidate.  
    new_words.append(rword)
```

```
return ' '.join(new_words) # re-join the new words into a single string and return.
```

المُخرج هو إصدار مُعاد صياغته من النص المُدخل.

يُستخدم المقطع البرمجي التالي لاستيراد كل الأدوات الضرورية لدعم دالة `paraphrase()` وفي المربع الأبيض أدناه، تحصل على مُخرج طريقة إعادة الصياغة (Paraphrase) للنص المسند إلى المتغير `text`:

```
%capture  
  
import gensim.downloader as api # used to download and load a pre-trained Word2Vec model  
model_wv = api.load('word2vec-google-news-300')  
  
import nltk  
# used to split a piece of text into words. Maintains punctuations as separate tokens  
from nltk import word_tokenize  
nltk.download('stopwords') # downloads the stopwords tool of the nltk library  
# used to get list of very common words in different languages  
from nltk.corpus import stopwords  
stop=set(stopwords.words('english')) # gets the list of english stopwords  
  
!pip install fuzzywuzzy[speedup]  
from fuzzywuzzy import fuzz  
  
text='We had dinner at this restaurant yesterday. It is very close to my  
house. All my friends were there, we had a great time. The location is  
excellent and the steaks were delicious. I will definitely return soon, highly  
recommended!'  
# parameters: target text, stopwords, Word2Vec model, upper bound on lexical similarity, lower bound  
# on semantic similarity  
paraphrase(text, stop, model_wv, 80, 0.5)
```

'We had brunch at this eatery Monday. It is very close to my bungalow. All my acquaintances were there, we had a terrific day. The locale is terrific and the tenderloin were delicious. I will certainly rejoin quickly, hugely advised!'

كما في المنهجيات الأخرى المستندة إلى القوالب، يمكن تحسين النتائج بإضافة المزيد من القيود لتصحيح بعض البدائل الأقل وضوحاً والمذكورة في الأعلى. ومع ذلك، يوضح المثال أعلاه أنه يمكن باستخدام هذه الدالة البسيطة توليد نصوص واقعية.



استخدام توليد اللغات الطبيعية المبني على الاختيار

Using Selection-Based NLG

في هذا القسم، ستسنعرض منهجية عملية لاختيار نموذج من الجُمل الفرعية من وثيقة مُحدّدة. هذه المنهجية تُجسّد استخدام ومزايا توليد اللغات الطبيعية المبني على الاختيار يستند إلى لبنتين رئيسيتين:

- نموذج الكلمة إلى المُتجه (Word2Vec) المستخدم لتحديد أزواج الكلمات المشابهة دلائلاً.
- مكتبة Networkx الشهيرة ضمن لغة البايثون المستخدمة لإنشاء ومعالجة أنواع مختلفة من بيانات الشبكة.

النص المُدخل الذي سيُستخدم في هذا الفصل هو مقالة إخبارية نُشرت بعد المباراة النهائية لكأس العالم 2022.

```
# reads the input document that we want to summarize
with open('article.txt',encoding='utf8',errors='ignore') as f: text=f.read()

text[:100] # shows the first 100 characters of the article
```


```
'It was a consecration, the spiritual overtones entirely appropriate.
Lionel Messi not only emulated '
```

في البداية، يُرمز النص باستخدام مكتبة re والتعبير النمطي نفسه المستخدم في الوحدات السابقة:

```
import re # used for regular expressions

# tokenize the document, ignore stopwords, focus only on words included in the Word2Vec model.
tokenized_doc=[word for word in re.findall(r'\b\w\w+\b',text.lower()) if word not in stop and word in model_wv]

# get the vocabulary (set of unique words).
vocab=set(tokenized_doc)
```



مكتبة Networkx

يمكن الآن نمذجة مفردات المستند في مُخطط موزون (Weighted Graph). توفر مكتبة Networkx في لغة البايثون مجموعة واسعة من الأدوات لإنشاء وتحليل المخططات. في توليد اللغات الطبيعية المبني على الاختيار، يُساعد تمثيل مفردات الوثيقة في مُخطط موزون في تحديد العلاقات بين الكلمات وتسهيل اختيار العبارات والجمل ذات الصلة. في المُخطط الموزون، تمثل كل عُقدة كلمة أو مفهوماً، وتُمثل الحواف بين العُقد العلاقات بين هذه المفاهيم. تُعبر الأوزان على الحواف عن قوة هذه العلاقات، مما يسمح لنظام توليد اللغات الطبيعية بتحديد المفاهيم الأقوى ارتباطاً. عند توليد النصوص، يُستخدم المُخطط الموزون للبحث عن العبارات والجمل استناداً إلى العلاقات بين الكلمات. على سبيل المثال، قد يُستخدم النظام المُخطط للبحث عن الكلمات والعبارات الأكثر ارتباطاً لوصف كيان مُحدد ثم استخدام هذه الكلمات لتحديد الجملة الأكثر ملاءمةً من قاعدة بيانات النظام.

شكل 3.27: مثال على مُخطط موزون له

fx دالة Build_graph()

تُستخدم دالة Build_graph() مكتبة NetworkX لإنشاء مخطط يتضمن:

- عقدة واحدة لكل كلمة ضمن مفردات محددة.

Doc2Vec حافة بين كل كلمتين. الوزن على الحافة يساوي التشابه الدلالي بين الكلمات، المحسوب بواسطة أداة وهي أداة معالجة اللغات الطبيعية المخصصة لتمثيل النص كمتجه وهي تعميم لنهجية نموذج الكلمة إلى المتجه (Word2Vec).

ترسم الدالة مخططاً ذا عقدة واحدة لكل كلمة في المفردات المحددة. توجد كذلك حافة بين عقدتين إذا كان تشابه نموذج الكلمة إلى المتجه (Word2Vec) أكبر من الحد المُعطى.

```
# tool used to create combinations (e.g. pairs, triplets) of the elements in a list
from itertools import combinations
import networkx as nx # python library for processing graphs

def build_graph(vocab:set, # set of unique words
                model_wv # Word2Vec model
               ):
    # gets all possible pairs of words in the doc
    pairs=combinations(vocab,2)


    G=nx.Graph() # makes a new graph

    for w1,w2 in pairs: #for every pair of words w1, w2
        sim=model_wv.similarity(w1, w2) # gets the similarity between the two words
        G.add_edge(w1,w2,weight=sim)

    return G

# creates a graph for the vocabulary of the World Cup document
G=build_graph(vocab,model_wv)
# prints the weight of the edge (semantic similarity) between the two words
G['referee']['goalkeeper']
```

```
{'weight': 0.40646762}
```



شكل 3.28: المجتمعات في المخطط

وبالنظر إلى ذلك المخطط المبني على الكلمة، يمكن تمثيل مجموعة من الكلمات المتشابهة دلائياً في صورة عناقيد من العقد المتصلة معاً بواسطة حواف عالية الوزن. يطلق على عناقيد العقد كذلك المجتمعات (Communities). مخرج المخطط هو مجموعة بسيطة من الرؤوس والحواف الموزونة. لم تُجرى عملية التجميع حتى الآن لإنشاء المجتمعات. في الشكل 3.28 تُستخدم ألوان مختلفة لتمييز المجتمعات في المخطط المذكور بالمثال السابق.

خوارزمية لوفان Louvain Algorithm

تتضمن مكتبة NetworkX العديد من الخوارزميات لتحليل المخطط والبحث عن المجتمعات. واحدة من الخيارات الأكثر فعالية هي خوارزمية لوفان التي تعمل عبر تحريك العقد بين المجتمعات حتى تجد بنية المجتمع التي تمثل الربط الأفضل في الشبكة الضمنية.

fx دالة Get_communities()

تستخدم الدالة الآتية خوارزمية لوفان للبحث عن المجتمعات في المخطط المبني على الكلمات. تحسب الدالة كذلك مؤشر الأهمية لكل مجتمع على حده، ثم تكون المخرجات في صورة قاموسين:

- word_to_community الذي يربط الكلمة بالمجتمع.
- community_scores الذي يربط المجتمع بدرجة الأهمية.

الدرجة تساوي مجموع تكرار الكلمات في المجتمع. على سبيل المثال، إذا كان المجتمع يتضمن ثلاثة كلمات تظهر 5 و8 و6 مرات في النص، فإن مؤشر المجتمع حينئذ يساوي 19. ومن ناحية المفهوم، يمثل المؤشر جزءاً من النص الذي يضمّه المجتمع.

```
from networkx.algorithms.community import louvain_communities
from collections import Counter # used to count the frequency of elements in a list

def get_communities( G, # the input graph
                     tokenized_doc:list): # the list of words in a tokenized document

    # gets the communities in the graph
    communities=louvain_communities(G, weight='weight')
    word_cnt=Counter(tokenized_doc)# counts the frequency of each word in the doc

    word_to_community={ }# maps each word to its community

    community_scores={ }# maps each community to a frequency score

    for comm in communities: #for each community
        # convert it from a set to a tuple so that it can be used as a dictionary key.
        comm=tuple(comm)
        score=0 # initialize the community score to 0.

        for word in comm: #for each word in the community
            word_to_community[word]=comm # map the word to the community
            score+=word_cnt[word] # add the frequency of the word to the community's score.

        community_scores[comm]=score # map the community to the score.

    return word_to_community, community_scores
```

```
word_to_community, community_scores = get_communities(G,tokenized_doc)
word_to_community['player'][:10] # prints 10 words from the community of the word 'team'
```

```
('champion',
'stretch',
'finished',
'fifth',
'playing',
'scoring',
'scorer',
'opening',
'team',
'win')
```

الآن بعد ربط كل الكلمات بالمجتمع، وربط المجتمع بمؤشر الأهمية، ستكون الخطوة التالية هي استخدام هذه المعلومات لتقدير أهمية كل جملة في المستند الأصلي. دالة `evaluate_sentences()` مُصممة لهذا الغرض.

Evaluate_sentences() دالة

تبدأ الدالة بتقسيم المستند إلى جمل، ثم حساب مؤشر الأهمية لكل جملة، استناداً إلى الكلمات التي تتضمنها. تكتسب كل كلمة مؤشر الأهمية من المجتمع الذي تنتمي إليه.

على سبيل المثال، لديك جملة مكونة من خمسة كلمات w_1, w_2, w_3, w_4, w_5 . الكلمتان w_1 و w_2 تنتميان إلى مجتمع بمؤشر قيمته 25، والكلمتان w_3 و w_4 تنتميان إلى مجتمع بمؤشر قيمته 30، والكلمة w_5 تنتمي إلى مجتمع بمؤشر قيمته 15. مجموع مؤشرات الجمل هو $25+30+25=125=15+30+25+30+15$. ستستخدم الدالة بعد ذلك هذه المؤشرات لتصنيف الجمل في ترتيب تنازلي، من الأكثر إلى الأقل أهمية.

```
from nltk import sent_tokenize # used to split a document into sentences

def evaluate_sentences(doc:str, # original document
                      word_to_community:dict,# maps each word to its community
                      community_scores:dict, # maps each community to a score
                      model_wv): # Word2Vec model

    # splits the text into sentences
    sentences=sent_tokenize(doc)
    scored_sentences=[]# stores (sentence, score) tuples

    for raw_sent in sentences: # for each sentence

        # get all the words in the sentence, ignore stopwords and focus only on words that are in the
        # Word2Vec model.
        sentence_words=[word
                        for word in re.findall(r'\b\w+\b',raw_sent.lower()) # tokenizes
                        if word not in stop and # ignores stopwords
```

```

word in model_wv] # ignores words that are not in the Word2Vec model

sentence_score=0 # the score of the sentence

for word in sentence_words: # for each word in the sentence

    word_comm=word_to_community[word] # get the community of this word
    sentence_score+=community_scores[word_comm] # add the score of this
community to the sentence score.

scored_sentences.append((sentence_score,raw_sent)) # stores this sentence and
its total score

# scores the sentences by their score, in descending order
scored_sentences=sorted(scored_sentences,key=lambda x:x[0],reverse=True)

return scored_sentences

scored_sentences=evaluate_sentences(text,word_to_community,community_
scores,model_wv)
len(scored_sentences)

```

61

يتضمن المستند الأصلي إجمالي 61 جملة، ويُستخدم المقطع المقطعي البرمجي التالي للعثور على الجُمل الثلاثة الأكثر أهمية من بين هذه الجُمل:

```

for i in range(3):
    print(scored_sentences[i], '\n')

```

(3368, 'Lionel Messi not only emulated the deity of Argentinian football, Diego Maradona, by leading the nation to World Cup glory; he finally plugged the burning gap on his CV, winning the one title that has eluded him – at the fifth time of asking, surely the last time.')

(2880, 'He scored twice in 97 seconds to force extra-time; the first a penalty, the second a sublime side-on volley and there was a point towards the end of regulation time when he appeared hell-bent on making sure that the additional period would not be needed.')

(2528, 'It will go down as surely the finest World Cup final of all time, the most pulsating, one of the greatest games in history because of how Kylian Mbappé hauled France up off the canvas towards the end of normal time.')

```
print(scored_sentences[-1]) # prints the last sentence with the lowest score
print()
print(scored_sentences[30]) # prints a sentence at the middle of the scoring scale
```

```
(0, 'By then it was 2-0.')
```

```
(882, 'Di María won the opening penalty, exploding away from Ousmane Dembélé before being caught and Messi did the rest.')
```

النتائج تؤكد أن هذه المنهجية تحدّد بنجاح الجُمل الأساسية التي تستنبط النقاط الرئيسية في المستند الأصلي، مع تعين مؤشرات أقل للجمل الأقل دلالة. تُطبق المنهجية نفسها كما هي لتوليد ملخص لأي وثيقة محددة.

استخدام توليد اللغات الطبيعية المبني على القواعد لإنشاء روبوت الدردشة

Using Rule-Based NLG to Create a Chatbot

في هذا القسم، ستُصمّم روبوت دردشة (Chatbot) وفق المسار المحدّد الموصي به بالجمع بين قواعد المعرفة الرئيسية للأسئلة والأجوبة والنموذج العصبي تمثيلات ترميز الجُمل ثنائية الاتجاه من المحولات (SBERT)، ويشير هذا إلى أن نقل التعلم المستخدم في تمثيلات ترميز الجُمل ثنائية الاتجاه من المحولات (SBERT) له البنية نفسها كما في تمثيلات ترميز الجُمل ثنائية الاتجاه من المحولات (all-MiniLM-L6-v2 (SBERT) وسوف يهياً بشكل دقيق لمهمة أخرى غير تحليل المشاعر، وهي: توليد اللغات الطبيعية.

1. تحميل نموذج تمثيلات ترميز الجُمل ثنائية الاتجاه من المحولات المُدرب مُسبقاً Load the Pre-Trained SBERT Model

الخطوة الأولى هي تحميل نموذج تمثيلات ترميز الجُمل ثنائية الاتجاه من المحولات (SBERT) المُدرب مُسبقاً:

```
%%capture
from sentence_transformers import SentenceTransformer, util
model_sbert = SentenceTransformer('all-MiniLM-L6-v2')
```

2. إنشاء قاعدة معرفة بسيطة Create a Simple Knowledge Base

الخطوة الثانية هي إنشاء قاعدة معرفة بسيطة لتحديد النص البرمجي المكون من الأسئلة والأجوبة التي يستخدمها روبوت الدردشة. يتضمن النص البرمجي 4 أسئلة (السؤال 1 إلى 4) والأجوبة على كل سؤال (الإجابة 1 إلى 4). كل إجابة مكونة من مجموعة من الخيارات كل خيار يتكون من قيمتين فقط، تمثل القيمة الثانية السؤال التالي الذي يستخدمه روبوت الدردشة. إذا كان هذا هو السؤال الأخير، ستكون القيمة الثانية خالية. هذه الخيارات تمثل الإجابات الصحيحة المحتملة على الأسئلة المعنية بها. على سبيل المثال، الإجابة على السؤال الثاني لها خيارات محتملان ["Java", "None"] and ["Python", "None"] and ["Java", "None"] and ["Python", "None"]. كل خيار مُكون من قيمتين:

- النص الحقيقي للإجابة المقبولة مثل: Java (جافا) أو Courses on Marketing (دورات تدريبية في التسويق).
- مُعرف يشير إلى السؤال التالي الذي سيطرحه روبوت الدردشة عند تحديد هذا الخيار. على سبيل المثال، إذا حدد المستخدم خيار ["Courses on Engineering", "3"] ([دورات تدريبية في الهندسة", "3"]) كإجابة على السؤال الأول، يكون السؤال التالي الذي سيطرحه روبوت الدردشة هو السؤال الثالث.

يمكن توسيع قاعدة المعرفة البسيطة لتشمل مستويات أكثر من الأسئلة والأجوبة، وتجعل روبوت الدردشة أكثر ذكاءً.

```
QA={  
    "Q1": "What type of courses are you interested in?",  
    "A1": [[ "Courses in Computer Programming", "2" ],  
           [ "Courses in Engineering", "3" ],  
           [ "Courses in Marketing", "4" ]],  
  
    "Q2": "What type of Programming Languages are you interested in?",  
    "A2": [[ "Java", None ], [ "Python", None ]],  
  
    "Q3": "What type of Engineering are you interested in?",  
    "A3": [[ "Mechanical Engineering", None ], [ "Electrical Engineering", None ]],  
  
    "Q4": "What type of Marketing are you interested in?",  
    "A4": [[ "Social Media Marketing", None ], [ "Search Engine  
Optimization", None ]]  
}
```

Chat() دالة

في النهاية، تُستخدم دالة Chat() لمعالجة قاعدة المعرفة وتتنفيذ روبوت الدردشة. بعد طرح السؤال، يقرأ روبوت الدردشة رد المستخدم.

- إن كان الرد مشابهًا دلاليًا لأحد خيارات الإجابات المقبولة لهذا السؤال، يُحدد ذلك الخيار وينتقل روبوت الدردشة إلى السؤال التالي.
 - إن لم يتشابه الرد مع أيٍ من الخيارات، يُطلب من المستخدم إعادة صياغة الرد.
- تُستخدم دالة تمثيلات ترميز الجمل ثنائية الاتجاه من المحولات (SBERT) لتقييم مؤشر التشابه الدلالي بين الرد وكل الخيارات المرشحة. يُعدُّ الخيار مشابهًا إذا كان المؤشر أعلى من مُتغير الحد الأدنى sim_lbound.

```
import numpy as np # used for processing numeric data  
  
def chat(QA:dict, # the Question-Answer script of the chatbot  
         model_sbert, # a pre-trained SBERT model  
         sim_lbound:float): # lower bound on the similarity between the user's response and the  
         closest candidate answer  
  
    qa_id='1' # the QA id  
  
    while True: # an infinite loop, will break in specific conditions  
  
        print('>>',QA['Q'+qa_id]) # prints the question for this qa_id  
        candidates=QA["A"+qa_id] # gets the candidate answers for this qa_id  
  
        print(flush=True) # used only for formatting purposes  
        response=input() # reads the user's response  
  
        # embed the response  
        response_embeddings = model_sbert.encode([response], convert_to_  
tensor=True)  
        # embed each candidate answer. x is the text, y is the qa_id. Only embed x.
```

```

candidate_embeddings = model_sbert.encode([x for x, y in candidates],
convert_to_tensor=True)

# gets the similarity score for each candidate
similarity_scores = util.cos_sim(response_embeddings, candidate_
embeddings)

# finds the index of the closest answer.
# np.argmax(L) finds the index of the highest number in a list L
winner_index=np.argmax(similarity_scores[0])

# if the score of the winner is less than the bound, ask again.
if similarity_scores[0][winner_index]<sim_lbound:
    print('>> Apologies, I could not understand you. Please rephrase
your response.')
    continue

# gets the winner (best candidate answer)
winner=candidates[winner_index]

# prints the winner's text
print('\n>> You have selected:',winner[0])
print()

qa_id=winner[1] # gets the qa_id for this winner

if qa_id==None: # no more questions to ask, exit the loop
    print('>> Thank you, I just emailed you a list of courses.')
    break

```

انظر إلى التفاعلين التاليين بين روبوت الدردشة والمستخدم:

التفاعل الأول

chat(QA,model_sbert, 0.5)

```

>> What type of courses are you interested in?
marketing courses
>> You have selected: Courses on Marketing
>> What type of Marketing are you interested in?
seo
>> You have selected: Search Engine Optimization
>> Thank you, I just emailed you a list of courses.

```

في التفاعل الأول، يفهم روبوت الدردشة أن المستخدم يبحث عن دورات تدريبية في التسويق. وكذلك، روبوت الدردشة ذكي بالقدر الكافي ليفهم أن المصطلح SEO يشبه دلائلاً مصطلح (تحسين محركات البحث) مما يؤدي إلى إنهاء المناقشة بنجاح.

```
chat(QA,model_sbert, 0.5)
```

```
>> What type of courses are you interested in?  
cooking classes  
>> Apologies, I could not understand you. Please rephrase your response.  
>> What type of courses are you interested in?  
software courses  
>> You have selected: Courses on Computer Programming  
>> What type of Programming Languages are you interested in?  
C++  
>> You have selected: Java  
>> Thank you, I just emailed you a list of courses.
```

في التفاعل الثاني، يفهم روبوت الدردشة أن Cooking Classes (دروس الطهي) لا تشبه دلائلاً الخيارات الموجودة في قاعدة المعرفة. وهو ذكي بالقدر الكافي ليفهم أن Software courses (الدورات التدريبية في البرمجة) يجب أن ترتبط بخيار Courses on Computer Programming (الدورات التدريبية في برمجة الحاسب). الجزء الأخير من التفاعل يسلط الضوء على نقاط الضعف: يربط روبوت الدردشة بين رد المستخدم C++ و Java. على الرغم من أن لغتي البرمجة مرتبطةان بالفعل ويمكن القول بأنهما أكثر ارتباطاً من لغتي البايثون و C++, إلا أن الرد المناسب يجب أن يوضح أن روبوت الدردشة لا يمتلك القدرة الكافية للتوصية بالدورات التدريبية في لغة C++. إحدى الطرق لمعالجة هذا القصور هي استخدام التشابه بين المفردات بدلاً من التشابه الدلالي للمقارنة بين الردود والخيارات ذات الصلة ببعض الأسئلة.


استخدام تعلم الآلة لتوليد نص واقعي

Using Machine Learning to Generate Realistic Text

الطرائق الموضحة في الأقسام السابقة تستخدم القواعد، والقواعد، أو تقنيات التحديد لتوليد النصوص للتطبيقات المختلفة. في هذا القسم، ستتعرف على أحدث تقنيات تعلم الآلة المستخدمة في توليد اللغات الطبيعية (NLG).

جدول 3.5: تقنيات تعلم الآلة المتقدمة المستخدمة في توليد اللغات الطبيعية

الوصف	التقنية
ت تكون شبكة الذاكرة المطلوبة قصيرة المدى (LSTM) من خلايا ذاكرة (Memory Cells) مرتبطة بعض. عند إدخال سلسلة من البيانات إلى الشبكة، تتولى معالجة كل عنصر في السلسلة واحداً تلو الآخر، وتحدد الشبكة خلايا الذاكرة لتوليد مخرج لكل عنصر على حده. شبكات الذاكرة المطلوبة قصيرة المدى (LSTM) تناسب مهام توليد اللغات الطبيعية (NLG) لقدرتها على الاحتفاظ بالمعلومات من سلاسل البيانات (مثل التعرف على الكلام أو الكتابة اليدوية) ومعالجة تعقيد اللغات الطبيعية.	شبكة الذاكرة المطلوبة قصيرة المدى Long Short-Term Memory – LSTM
النماذج المبنية على المحولات (Transformer-Based Models) تتمثّل هذه النماذج في عملها إلى تقنية الانتباه الذاتي (Self-Attention) التي تمكّنها من فهم العلاقات بين الكلمات المختلفة في الجمل.	النماذج المبنية على المحولات (Transformer-Based Models)



شكل 3.29: الذاكرة المطلوبة قصيرة المدى

المحولات Transformers

المحولات مناسبة لمهام توليد اللغات الطبيعية لقدرتها على معالجة البيانات المدخلة المتسلسلة بكفاءة. في نموذج المحولات، تمرر البيانات المدخلة عبر المُرمِز الذي يحول المدخلات إلى تمثيل مستمر، ثم يمرر التمثيل عبر مُفكِّك الترميز الذي يُولد التسلسل المُخْرَج. إحدى الخصائص الرئيسية لهذه النماذج هي استخدام آليات الانتباه التي تسمح للنموذج بالتركيز على الأجزاء المهمة من التسلسل في حين تتجاهل الأجزاء الأقل دلالة. أظهرت نماذج المحولات كفاءة في توليد النص عالي الدقة للعديد من مهام توليد اللغات الطبيعية بما في ذلك ترجمة الآلة، والتلخيص، والإجابة على الأسئلة.

نموذج الإصدار الثاني من المُحَوْل التوليدي مُسبَق التدريب GPT-2 Model

في هذا القسم، ستستخدم الإصدار الثاني من المُحَوْل التوليدي مُسبَق التدريب (GPT-2) وهو نموذج لغوي قوي طورته شركة أوبين آي آي (OpenAI) لتوليد النصوص المستندة إلى النص التقيني المدخل بواسطة المستخدم. الإصدار الثاني من المُحَوْل التوليدي مُسبَق التدريب (GPT-2 - Generative Pre-training Transformer 2 - GPT-2) مُدرب على مجموعة بيانات تضم أكثر من ثمان ملايين صفحة ويب ويتميز بالقدرة على إنشاء النصوص البشرية بعدة لغات وأساليب. بنية الإصدار الثاني من المُحَوْل التوليدي مُسبَق التدريب (GPT-2) المبنية على المُحَوْل تسمح بتحديد التبعيات (Dependencies) بعيدة المدى وتوليد النصوص المتّسقة، وهو مُدرب للتنبؤ بالكلمة التالية وفقاً لكل الكلمات السابقة ضمن النص، وبالتالي، يمكن استخدام النموذج لتوليد نصوص طويلة جداً عبر التنبؤ المستمر وإضافة المزيد من الكلمات.

```
%capture
!pip install transformers
!pip install torch
import torch # an open-source machine learning library for neural networks, required for GPT2.
from transformers import GPT2LMHeadModel, GPT2Tokenizer

# initialize a tokenizer and a generator based on a pre-trained GPT2 model.

# used to:
# -encode the text provided by the user into tokens
# -translate (decode) the output of the generator back to text
tokenizer = GPT2Tokenizer.from_pretrained('gpt2')

# used to generate new tokens based on the inputted text
generator = GPT2LMHeadModel.from_pretrained('gpt2')
```

يُقدّم النص التالي كأساس يستند إليه الإصدار الثاني من المُحَوْل التوليدي مُسبَق التدريب (GPT-2) :

```
text='We had dinner at this restaurant yesterday. It is very close to my
house. All my friends were there, we had a great time. The location is
```

excellent and the steaks were delicious. I will definitely return soon, highly recommended! '

```
# encodes the given text into tokens
encoded_text = tokenizer.encode(text, return_tensors='pt')

# use the generator to generate more tokens.
# do_sample=True prevents GPT-2 from just predicting the most likely word at every step.
generated_tokens = generator.generate(encoded_text,
                                         max_length=200) # max number of new tokens to
generate
#decode the generated tokens to convert them to words
# skip_special_tokens=True is used to avoid special tokens such as '>' or '-' characters.
print(tokenizer.decode(generated_tokens[0], skip_special_tokens=True))
```

We had dinner at this restaurant yesterday. It is very close to my house. All my friends were there, we had a great time. The location is excellent and the steaks were delicious. I will definitely return soon, highly recommended!

```
# use the generator to generate more tokens.  
# do_sample=True prevents GPT-2 from just predicting the most likely word at every step.  
generated_tokens = generator.generate(encoded_text,  
                                      max_length=200, # max number of new tokens to  
generate  
                                      do_sample=True)  
  
print(tokenizer.decode(generated_tokens[0], skip_special_tokens=True))
```

We had dinner at this restaurant yesterday. It is very close to my house. All my friends were there, we had a great time. The location is excellent and the steaks were delicious. I will definitely return soon, highly recommended!

If you just found this place helpful. If you like to watch videos or go to the pool while you're there, go for it! Good service - I'm from Colorado and love to get in and out of this place. The food was amazing! Also, we were happy to see the waitstaff with their great hands - I went for dinner. I ordered a small side salad (with garlic on top), and had a slice of tuna instead. When I was eating, I was able to get up and eat my salad while waiting for my friend to pick up the plate, so I had a great time too. Staff was welcoming and accommodating. Parking is cheap in this neighborhood, and it is in the neighborhood that it needs to

يتحقق هذا مُخرّجات أكثر تنوعاً، مع الحفاظ على دقة وسلامة النص المولد، حيث يستخدم النص مفردات غنية وهو سليم نحوياً. يسمح الإصدار الثاني من المحول التوليد مُسبق التدريب (GPT-2) بتخصيص المُخرج بشكل أفضل. يتضح ذلك عند استخدام مُتغير `temperature` (درجة الحرارة) الذي يسمح للنموذج بقبول المزيد من المخاطر بل وأحياناً اختيار بعض الكلمات الأقل احتمالاً. القيم الأعلى لهذا المُتغير تؤدي إلى نصوص أكثر تنوعاً، مثل:

```
# Generate tokens with higher diversity
generated_tokens = generator.generate(
    encoded_text, max_length=200, do_sample=True, temperature=2.0)

print(tokenizer.decode(generated_tokens[0], skip_special_tokens=True))
```

We had dinner at this restaurant yesterday. It is very close to my house. All my friends were there, we had a great time. The location is excellent and the steaks were delicious. I will definitely return soon, highly recommended!

Worth a 5 I thought a steak at a large butcher was the end story!! We were lucky. The price was cheap!! That night though as soon as dinner was on my turn that price cut completely out. At the tail area they only have french fries or kiwifet - no gravy - they get a hard egg the other day too they call kawif at 3 PM it will be better this summer if I stay more late with friends. When asked it takes 2 or 3 weeks so far to cook that in this house. Once I found a place it was great. Everything I am waiting is just perfect as usual....great prices especially at one where a single bite would suffice or make more as this only runs on the regular hours

ومع ذلك، إذا كانت درجة الحرارة مرتفعة للغاية، فإن النموذج سيتجاهل الإرشادات الأساسية التي تظهر في المدخل الأولي (Original Seed) ويُولد مُخرجاً أقل واقعية وليس له معنى:

```
# Too high temperature leads to divergence in the meaning of the tokens
generated_tokens = generator.generate(
    encoded_text, max_length=200, do_sample=True, temperature=4.0)

print(tokenizer.decode(generated_tokens[0], skip_special_tokens=True))
```

We had dinner at this restaurant yesterday. It is very close to my house. All my friends were there, we had a great time. The location is excellent and the steaks were delicious. I will definitely return soon, highly recommended! It has the nicest ambagias of '98 that I like; most Mexican. And really nice steak house; amazing Mexican atmosphere to this very particular piece of house I just fell away before its due date, no surprise my 5yo one fell in right last July so it took forever at any number on it being 6 (with it taking two or sometimes 3 month), I really have found comfort/affability on many more restaurants when ordering. If you try at it they tell ya all about 2 and three places will NOT come out before they close them/curry. Also at home i would leave everything until 1 hour but sometimes wait two nights waiting for 2+ then when 2 times you leave you wait in until 6 in such that it works to

تمرينات

1

صحيحة	خاطئة	حدد الجملة الصحيحة والجملة الخاطئة فيما يلي:
<input type="radio"/>	<input checked="" type="radio"/>	1. توليد اللغات الطبيعية المبني على تعلم الآلة يتطلب مجموعات كبيرة من بيانات التدريب والموارد الحسابية.
<input type="radio"/>	<input checked="" type="radio"/>	2. الفعل هو نوع من وسوم أقسام الكلام (POS).
<input type="radio"/>	<input checked="" type="radio"/>	3. في تحليل بناء الجمل لتوليد اللغات الطبيعية المبني على القوالب، يستخدم التحليل بصورة منفصلة عن وسوم أقسام الكلام (POS).
<input type="radio"/>	<input checked="" type="radio"/>	4. المجتمعات هي عناقيد العُقد التي تمثل الكلمات المختلفة دلائلاً.
<input type="radio"/>	<input checked="" type="radio"/>	5. يصبح روبوت الدردشة أكثر ذكاءً كلما ازداد عدد مستويات الأسئلة والأجوبة المُضافة إلى قاعدة المعرفة.

قارن بين المنهجيات المختلفة لتوليد اللغات الطبيعية (NLG).

2

حدد ثلاث تطبيقات مختلفة لتوليد اللغات الطبيعية (NLG).

3

أكمل المقطع البرمجي التالي حتى تقبل الدالة build_graph() مفردات محددة من الكلمات ونموذج الكلمة إلى المتّجه (Word2Vec) المدرب لرسم مخطط ذي عقدة واحدة لكل كلمة في المفردات المحددة. يجب أن يحتوي المخطط على حافة بين عقدتين إذا كان تشابه نموذج الكلمة إلى المتّجه (Word2Vec) أكبر من مستوى التشابه المعطى، ويجب ألا تكون هناك أوزان على الحواف.

```

from _____ import combinations # tool used to create combinations

import networkx as nx # python library for processing graphs

def build_graph(vocab:set, #set of unique words

                model_wv, # Word2Vec model

                similarity_threshold:float

                ):

    pairs=combinations(vocab, _____) # gets all possible pairs of words in the vocabulary

    G=nx._____ # makes a new graph

    for w1,w2 in pairs: #for every pair of words w1,w2

        sim=model_wv._____ (w1, w2)# gets the similarity between the two words

        if _____:

            G._____ (w1,w2)

    return G

```

5

أكمل المقطع البرمجي التالي حتى تُستخدم الدالة `get_max_sim()` نموذج تمثيلات ترميز الجمل ثنائية الاتجاه من المحولات (SBERT) للمقارنة بين جملة محددة `my_sentence` وكل الجمل الواردة في قائمة أخرى `.my_sentence`. يجب أن تُعيد الدالة الجملة ذات مؤشر التشابه الأعلى من L1 إلى L2.

```

from sentence_transformers import _____, util

from _____ import combinations # tool used to create combinations

model_sbert = _____('all-MiniLM-L6-v2')

def get_max_sim(L1,my_sentence):

    # embeds my_sentence

    my_embedding = model_sbert, _____([my_sentence], convert_to_tensor=True)

    # embeds the sentences from L2

    L_embeddings = model_sbert._____([L, convert_to_tensor=True])

    similarity_scores = _____.cos_sim(_____, _____)

    winner_index=np.argmax(similarity_scores[0])

    return _____

```

المشروع

تصنيف النص هو عملية مكونة من خطوتين تشمل:

الخطوة الأولى: استخدام مجموعة من نصوص التدريب ذات القيم (التصنيفات) المعروفة لتدريب نموذج التصنيف.

الخطوة الثانية: استخدام نموذج التدريب للتبيؤ بالقيم لكل نص في مجموعة بيانات الاختبار. القيم في مجموعة بيانات الاختبار إما غير معروفة أو مخبأة وتُستخدم لاحقاً في عملية التحقق.

يجب تمثيل النصوص في كل منمجموعات بيانات التدريب والاختبار بالتجهيزات قبل استخدامها. تُستخدم أدوات CountVectorizer أو TfidfVectorizer من مكتبة سكليرن (Sklearn) في البرمجة الاتجاهية.

تُقدم مكتبة سكليرن (Sklearn) في لغة البايثون قائمة طويلة من نماذج التصنيف. مثل:

GradientBoostingClassifier() <

DecisionTreeClassifier() <

RandomForestClassifier() <

مهمتك هي استخدام مجموعة بيانات التدريب IMDB المستخدمة في هذا الدرس لتدريب النموذج الذي يحقق أعلى درجة على مجموعة بيانات الاختبار IMDB (imdb_data/imdb_test.csv). يمكنك تحقيق ذلك عبر:

1 استبدال المصنف MultinomialNB بنماذج تصنيف أخرى من مكتبة سكليرن (Sklearn) مثل الموضحة بالأعلى.

2 إعادة تشغيل المفكرة التفاعلية لديك بعد الاستبدال، لحساب دقة كل نموذج جديد بعد تجربته.

3 إنشاء تقرير للمقارنة بين دقة كل النماذج التي جربتها وتحديد النموذج الذي حقق نتائج دقيقة.

ماذا تعلمت

- < تصنيف النص باستخدام نماذج التعلم غير الموجه.
- < تحليل النص باستخدام نماذج التعلم الموجه.
- < استخدام نماذج تعلم الآلة لتوليد اللغات الطبيعية.
- < برمجة روبوت دردشة بسيط.

المصطلحات الرئيسية

Black-Box predictors	مُتنبئات الصندوق الأسود	Part of Speech (POS) Tags	وسوم أقسام الكلام
Chatbot	روبوت الدردشة	Sentiment Analysis	تحليل المشاعر
Cluster	عنقود	Supervised Learning	التعلم الموجه
Dendrogram	الرسم الشجري	Syntax Analysis	تحليل بناء الجمل
Dimensionality Reduction	تقليل الأبعاد	Tokenization	ال التقسيم
Document Clustering	تجمیع المستندات	Transfer Learning	التعلم المنقول
Natural Language Generation	تولید اللغات الطبيعية	Unsupervised Learning	التعلم غير الموجه
Natural Language Processing	معالجة اللغات الطبيعية	Vectorization	البرمجة الاتجاهية