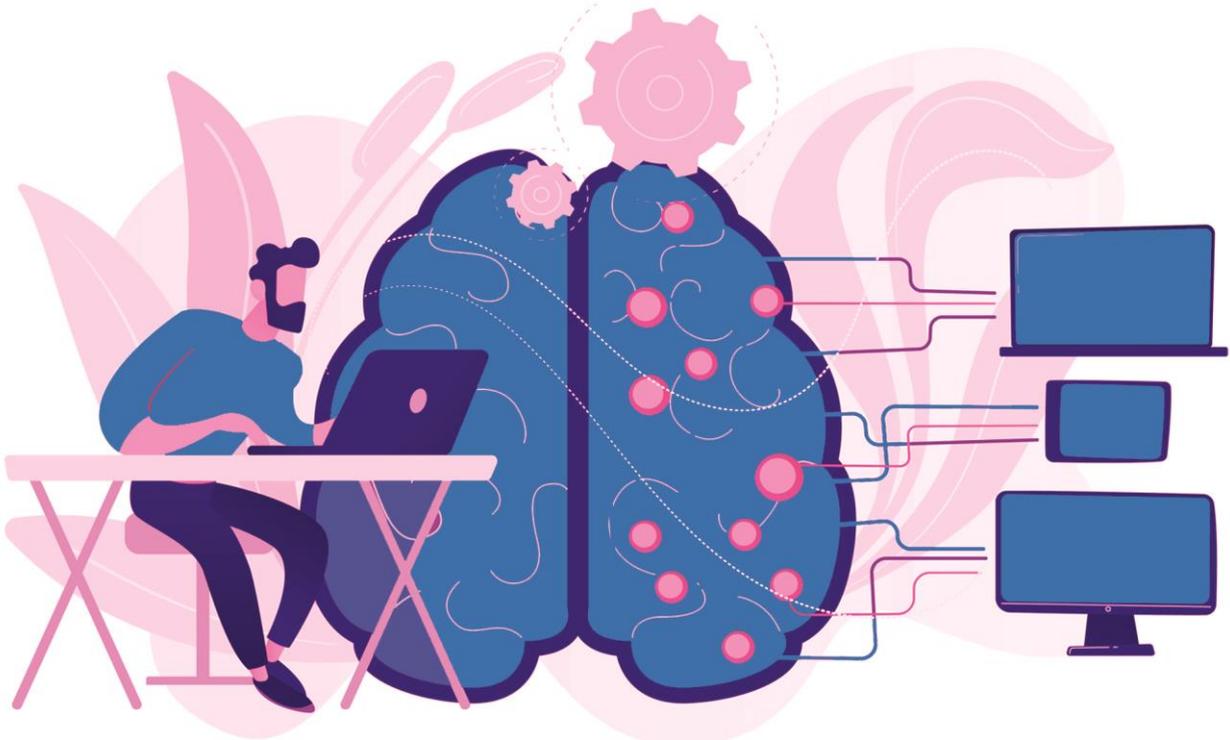


علم البيانات

وتعلم الآلة

45 مشروع علم بيانات مع التعلم الآلي تم حلها وشرحها باستخدام بايثون

ترجمة واعداد : د. علاء طعيمة



بمه تعالى

علم البيانات وتعلم الآلة: عن طريق الامثلة

45 مشروع علم البيانات مع التعلم الآلي تم حلها وشرحها باستخدام بايثون

ترجمة واعداد:

د. علاء طعيمة

المقدمة

يعمل التعلم الآلي على إحداث ثورة تدريجية في كل مجال من مجالات الذكاء الاصطناعي، مما يجعل تطوير التطبيقات أسهل.

تعد البيانات اليوم أداة ووقوداً للشركات لاكتساب رؤى مهمة وتحسين أدائها. سيطر علم البيانات على كل صناعة تقريباً في العالم. لا توجد صناعة في العالم اليوم لا تستخدم البيانات.

في هذا الكتاب، تنقل مشاريع التعلم الآلي باستخدام بايثون كل المعرفة اللازمة لتنفيذ مشاريع التعلم الآلي في مختلف مجالات علم البيانات. كل مشروع من هذه المشاريع فريد من نوعه، مما يساعدك على إتقان الموضوع تدريجياً. في هذه الكتاب، سوف يأخذك المؤلف من خلال قائمة مشاريع علم البيانات باستخدام التعلم الآلي والتي ستساعدك على تعلم وتنفيذ جميع مفاهيم علم البيانات باستخدام لغة برمجة بايثون.

لقد حاولت قدر المستطاع ان اترجم المشاريع الأكثر طرحاً في مجال علم البيانات والتعلم الآلي مع الشرح المناسب والكافي، ومع هذا يبقى عملاً بشرياً يحتمل النقص، فاذا كان لديك أي ملاحظات حول هذا الكتاب، فلا تردد بمراسلتنا عبر بريدنا الالكتروني alaa.taima@qu.edu.iq.

نأمل ان يساعد هذا الكتاب كل من يريد ان يدخل في مجالات علم البيانات والتعلم الآلي والتعلم العميق وعلم البيانات ومساعدة القارئ العربي على تعلم هذا المجالات. اسأل الله التوفيق في هذا العمل لأثراء المحتوى العربي الذي يفتقر أشد الافتقار إلى محتوى جيد ورسن في مجال التعلم الآلي والتعلم العميق وعلم البيانات. ونرجو لك الاستمتاع مع الكتاب ولا تنسونا من صالح الدعاء.

د. علاء طعيمة

كلية علوم الحاسوب وتكنولوجيا المعلومات

جامعة القادسية

العراق

المحتويات

13	Salary Prediction with Machine Learning	التنبؤ بالراتب مع التعلم الآلي
13	التنبؤ بالراتب مع التعلم الآلي
13	التنبؤ بالراتب باستخدام بايثون
14	تدريب نموذج التعلم الآلي
15	الملخص
16	Credit Card Clustering with Machine Learning	تجميع بطاقات الائتمان مع التعلم الآلي
16	تجميع بطاقات الائتمان
16	تجميع بطاقات الائتمان باستخدام بايثون
20	الملخص
21	House Rent Prediction with Machine Learning	التنبؤ بإيجار المنزل باستخدام التعلم الآلي
21	التنبؤ بإيجار المنزل
21	التنبؤ بإيجار المنزل باستخدام لغة بايثون
26	نموذج التنبؤ بإيجار المنزل
29	الملخص
30	Password Strength Checker with Machine Learning	مدقق قوة كلمة المرور مع التعلم الآلي
30	كيفية إنشاء مدقق قوة كلمة المرور؟
30	مدقق قوة كلمة المرور باستخدام بايثون
31	نموذج التنبؤ بقوة كلمة المرور
32	الملخص
33	Spam Comments Detection with Machine Learning	اكتشاف التعليقات غير المرغوب فيها باستخدام التعلم الآلي
33	اكتشاف التعليقات غير المرغوب فيها
33	اكتشاف التعليقات غير المرغوب فيها باستخدام بايثون
35	تدريب نموذج التصنيف

35 الملخص
6	Online Food Order التنبؤ بطلب الطعام عبر الإنترنت باستخدام التعلم الآلي
36 Prediction with Machine Learning
36 التنبؤ بطلب الطعام عبر الإنترنت: دراسة حالة
36 التنبؤ بطلبات الطعام عبر الإنترنت باستخدام لغة بايثون
42 نموذج التنبؤ بطلب الطعام عبر الإنترنت
44 الملخص
7	Instagram Recommendation نظام توصية Instagram مع تعلم الآلة
45 System with Machine Learning
45 كيف يعمل نظام توصيات Instagram ؟
46 نظام توصية Instagram باستخدام بايثون
48 الملخص
8	Student Marks Prediction with التنبؤ بدرجات الطالب مع التعلم الآلي
49 Machine Learning
49 التنبؤ بدرجات الطالب (دراسة حالة)
49 التنبؤ بدرجات الطالب باستخدام بايثون
51 نموذج التنبؤ بعلامات الطالب
52 الملخص
9	Online كشف الاحتيال في المدفوعات عبر الإنترنت باستخدام التعلم الآلي
53 Payments Fraud Detection with Machine Learning
53 كشف الاحتيال في المدفوعات عبر الإنترنت باستخدام التعلم الآلي
54 كشف الاحتيال للمدفوعات عبر الإنترنت باستخدام بايثون
56 نموذج كشف الاحتيال للمدفوعات عبر الإنترنت
57 الملخص
10	Waiter Tips Prediction with التنبؤ بإكرامية النادل مع التعلم الآلي
58 Machine Learning
58 اكرامية النادل (دراسة حالة)
58 التنبؤ بإكرامية النادل باستخدام بايثون
59 تحليل اكرامية النادل

62 نموذج التنبؤ بإكرامية النادل
63 الملخص
64	Clustering Music Genres 11 تجميع أنواع الموسيقى باستخدام التعلم الآلي
64 with Machine Learning
64 تجميع أنواع الموسيقى (بيان المشكلة)
64 تجميع أنواع الموسيقى باستخدام لغة بايثون
66 التحليل العنقودي للميزات الصوتية
68 الملخص
69	Cryptocurrency 12 التنبؤ بأسعار العملات المشفرة باستخدام التعلم الآلي
69 Price Prediction with Machine Learning
69 التنبؤ بأسعار العملات المشفرة باستخدام التعلم الآلي
69 التنبؤ بأسعار العملات المشفرة باستخدام بايثون
71 نموذج التنبؤ بأسعار العملات المشفرة
72 الملخص
73	Stock Price Prediction using 13 التنبؤ بسعر السهم باستخدام التعلم الآلي
73 Machine Learning
73 التنبؤ بسعر السهم
73 تحضير البيانات
74 تطبيق تعلم الآلة للتنبؤ بأسعار الأسهم
75 الملخص
76	Breast Cancer Survival 14 التنبؤ بالنجاة من سرطان الثدي مع التعلم الآلي
76 Prediction with Machine Learning
76 التنبؤ بالنجاة من سرطان الثدي مع التعلم الآلي
77 التنبؤ بالنجاة من سرطان الثدي باستخدام لغة بايثون
82 نموذج التنبؤ بالنجاة من سرطان الثدي
83 الملخص
84	Covid-19 Deaths Prediction 15 التنبؤ بوفيات Covid-19 باستخدام التعلم الآلي
84 with Machine Learning
84 التنبؤ بوفيات كوفيد-19 (دراسة حالة)

84	التنبؤ بوفيات Covid-19 باستخدام بايثون
85	تحليل معدل الوفيات Covid-19
87	نموذج التنبؤ بوفيات Covid-19
88	الملخص
89	16) التنبؤ بسعر السهم مع LSTM LSTM ... Stock Price Prediction with LSTM
89	التنبؤ بسعر السهم مع LSTM
91	تدريب LSTM للتنبؤ بسعر السهم
93	الملخص
94	17) نظام توصية المقالات مع التعلم الآلي Article Recommendation System with Machine Learning
94	نظام التوصية بالمقالات
94	نظام التوصية بالمقالات باستخدام بايثون
96	الملخص
97	18) التنبؤ بالمبيعات المستقبلية مع التعلم الآلي Future Sales Prediction with Machine Learning
97	التنبؤ بالمبيعات المستقبلية (دراسة حالة)
97	التنبؤ بالمبيعات المستقبلية باستخدام بايثون
100	نموذج التنبؤ بالمبيعات المستقبلية
100	الملخص
101	19) التنبؤ بسعر سهم Netflix مع التعلم الآلي Netflix Stock Price Prediction with Machine Learning
101	التنبؤ بسعر سهم Netflix مع التعلم الآلي
102	تدريب LSTM على التنبؤ بسعر سهم Netflix
105	الملخص
106	20) اكتشاف الاجهاد باستخدام التعلم الآلي Stress Detection with Machine Learning
106	اكتشاف الاجهاد باستخدام التعلم الآلي
106	اكتشاف الإجهاد باستخدام بايثون
108	نموذج اكتشاف الإجهاد

110 الملخص
21	التنبؤ بالطلب على المنتج باستخدام التعلم الآلي Product Demand
111	Prediction with Machine Learning
111 التنبؤ بالطلب على المنتج (دراسة حالة)
111 التنبؤ بالطلب على المنتج باستخدام بايثون
113 نموذج التنبؤ بالطلب على المنتج
114 الملخص
22	التنبؤ بأسعار الكهرباء مع التعلم الآلي Electricity Price Prediction with
115	Machine Learning
115 التنبؤ بأسعار الكهرباء (دراسة حالة)
116 التنبؤ بأسعار الكهرباء باستخدام لغة بايثون
118 نموذج التنبؤ بأسعار الكهرباء
119 الملخص
23	اكتشاف اللغة باستخدام التعلم الآلي Language Detection with Machine
120	Learning
120 اكتشاف اللغة
121 اكتشاف اللغة باستخدام بايثون
122 نموذج اكتشاف اللغة
122 الملخص
24	التنبؤ بسعر سهم Tata Motors مع التعلم الآلي Tata Motors Stock Price
124	Prediction with Machine Learning
124 التنبؤ بسعر سهم Tata Motors
124 التنبؤ بأسعار أسهم شركة Tata Motors باستخدام لغة بايثون
126 الملخص
25	التنبؤ بأقساط التأمين الصحي باستخدام التعلم الآلي Health Insurance
127	Premium Prediction with Machine Learning
127 التنبؤ بأقساط التأمين الصحي
127 التنبؤ بأقساط التأمين الصحي باستخدام بايثون
129 نموذج التنبؤ بأقساط التأمين الصحي

130 الملخص
Number of Orders Prediction	(26) التنبؤ بعدد الطلبات باستخدام التعلم الآلي
131 with Machine Learning
131 التنبؤ بعدد الطلبات
132 التنبؤ بعدد الطلبات باستخدام بايثون
135 نموذج التنبؤ بعدد الطلبات
136 الملخص
Apple Stock Price Prediction	(27) التنبؤ بسعر سهم Apple مع التعلم الآلي
137 with Machine Learning
137 التنبؤ بسعر سهم Apple
137 التنبؤ بسعر سهم Apple باستخدام بايثون
139 الملخص
News Classification with Machine Learning	(28) تصنيف الأخبار مع تعلم الآلة
140
140 تصنيف الأخبار
140 تصنيف الأخبار باستخدام بايثون
141 نموذج تصنيف الأخبار
142 الملخص
Car Price Prediction with Machine	(29) التنبؤ بأسعار السيارة مع التعلم الآلي
143 Learning
143 التنبؤ بأسعار السيارة مع التعلم الآلي
143 نموذج التنبؤ بسعر السيارة باستخدام لغة بايثون
148 تدريب نموذج التنبؤ بسعر السيارة
148 الملخص
Spam Detection with	(30) اكتشاف البريد العشوائي باستخدام التعلم الآلي
149 Machine Learning
149 اكتشاف البريد العشوائي
149 اكتشاف البريد العشوائي باستخدام بايثون
150 الملخص

31	Student Grades Prediction	التنبؤ بدرجات الطلاب باستخدام التعلم الآلي
151	with Machine Learning
151	التنبؤ بدرجات الطالب
151	التنبؤ بدرجات الطالب باستخدام لغة بايثون
152	الملخص
32	Tesla Stock Price Prediction with	التنبؤ بسعر سهم Tesla مع التعلم الآلي
153	Machine Learning
153	التنبؤ بسعر سهم Tesla مع التعلم الآلي
153	التنبؤ بسعر سهم Tesla باستخدام لغة بايثون
155	الملخص
33	Click-Through Rate	التنبؤ بمعدل النقر للظهور من خلال التعلم الآلي
156	Prediction with Machine Learning
156	نموذج التنبؤ بمعدل النقر مع التعلم الآلي
156	نموذج التنبؤ بمعدل النقر باستخدام بايثون
158	نموذج الانحدار اللوجستي:
34	Sarcasm Detection with Machine	اكتشاف السخرية مع التعلم الآلي
160	Learning
160	اكتشاف السخرية مع التعلم الآلي
160	اكتشاف السخرية باستخدام بايثون
162	الملخص
35	Social Media	التنبؤ بمتابعي وسائل التواصل الاجتماعي باستخدام التعلم الآلي
163	Followers Prediction with Machine Learning
163	التنبؤ بمتابعي وسائل التواصل الاجتماعي
164	التنبؤ بمتابعي الوسائط الاجتماعية باستخدام بايثون
166	الملخص
36	Hate Speech Detection with	اكتشاف خطاب الكراهية باستخدام التعلم الآلي
167	Machine Learning
167	اكتشاف خطاب الكراهية باستخدام التعلم الآلي
167	اكتشاف خطاب الكراهية باستخدام بايثون
170	الملخص

37	التنبؤ بسعر Dogecoin مع التعلم الآلي Dogecoin Price Prediction with	Machine Learning
171	
171	التنبؤ بسعر Dogecoin	
171 باستخدام بايثون.	
173 الملخص	
38	تصنيف إعلانات وسائل التواصل الاجتماعي مع التعلم الآلي Social Media Ads	Classification with Machine Learning
174	
174 تصنيف إعلانات وسائل التواصل الاجتماعي	
174 باستخدام بايثون	
176 تدريب نموذج تصنيف إعلانات وسائل التواصل الاجتماعي	
177 الملخص	
39	اكتشاف الأخبار الكاذبة باستخدام التعلم الآلي Fake News Detection with	Machine Learning
178	
178 اكتشاف الأخبار الكاذبة	
178 اكتشاف الأخبار الكاذبة باستخدام بايثون.	
180 الملخص	
40	التنبؤ بالمبيعات باستخدام التعلم الآلي Sales Prediction with Machine	Learning
181	
181 ما هو التنبؤ بالمبيعات؟	
181 التنبؤ بالمبيعات باستخدام بايثون.	
183 الملخص	
41	تصنيف أسعار الأجهزة المحمولة مع التعلم الآلي Mobile Price Classification	with Machine Learning
184	
184 تصنيف أسعار الأجهزة المحمولة مع التعلم الآلي	
184 باستخدام لغة بايثون.	
186 تحضير البيانات	
186 نموذج تصنيف سعر الهاتف المحمول	
43	التنبؤ بسعر صرف العملات مع التعلم الآلي Currency Exchange Rate	Prediction with Machine Learning
188	
188 التنبؤ بسعر صرف العملات	

188	التنبؤ بسعر صرف العملات باستخدام بايثون
191	الملخص
44	Profit Prediction with Machine Learning التنبؤ بالربح مع التعلم الآلي
192
192	التنبؤ بالربح مع التعلم الآلي
192	التنبؤ بالربح باستخدام بايثون
194	الملخص
45	Water Quality Analysis using تحليل جودة المياه باستخدام التعلم الآلي
195	Machine Learning
195	تحليل جودة المياه
195	تحليل جودة المياه باستخدام لغة بايثون
201	نموذج التنبؤ بجودة المياه باستخدام لغة بايثون
202	الملخص
46	Video Game Sales التنبؤ بمبيعات ألعاب الفيديو باستخدام التعلم الآلي
203	Prediction with Machine Learning
203	نموذج التنبؤ بمبيعات ألعاب الفيديو باستخدام بايثون
205	نموذج التنبؤ بمبيعات ألعاب الفيديو التدريبية
205	الملخص

1) التنبؤ بالراتب مع التعلم الآلي Salary Prediction with Machine Learning

يختلف الراتب (Salary) باختلاف الملف الوظيفي للشخص. لكن بشكل عام، فإن خبرة العمل هي التي تحدد الراتب. يعد التنبؤ بالراتب (Salary prediction) مشكلة شائعة بين مجتمع علوم البيانات للمبتدئين تمامًا. لذلك، إذا كنت مبتدئًا في علوم البيانات، فيجب أن تعمل على حل هذه المشكلة لفهم التعلم الآلي (Machine Learning). في هذه المقالة، سوف نخوض في مهمة التنبؤ بالراتب باستخدام التعلم الآلي باستخدام بايثون.

التنبؤ بالراتب مع التعلم الآلي

للتنبؤ بالراتب، نحتاج إلى إيجاد علاقات في البيانات حول كيفية تحديد الراتب. لهذه المهمة، نحتاج إلى مجموعة بيانات تعتمد على الرواتب. لقد وجدت مجموعة بيانات تحتوي على بيانات حول كيفية تأثير الخبرة الوظيفية (job experience) على الراتب.

تحتوي مجموعة البيانات على عمودين فقط:

1. الخبرة الوظيفية (job experience).
2. الراتب (salary).

يمكنك تنزيل مجموعة البيانات من [هنا](#).

في القسم أدناه، سأقدم كيفية استخدام التعلم الآلي للتنبؤ بالراتب بناءً على الخبرة الوظيفية.

التنبؤ بالراتب باستخدام بايثون

لنبدأ هذه المهمة عن طريق استيراد مكتبات بايثون ومجموعة البيانات الضرورية:

```
import pandas as pd
import numpy as np
import plotly.express as px
import plotly.graph_objects as go

data = pd.read_csv("Salary_Data.csv")
print(data.head())
```

	YearsExperience	Salary
0	1.1	39343.0
1	1.3	46205.0
2	1.5	37731.0
3	2.0	43525.0
4	2.2	39891.0


```
random_state=42)
```

إليك الآن كيف يمكننا تدريب نموذج التعلم الآلي:

```
model = LinearRegression()
model.fit(xtrain, ytrain)
```

الآن دعنا نتوقع راتب شخص ما باستخدام نموذج التعلم الآلي المدرب:

```
a = float(input("Years of Experience : "))
features = np.array([[a]])
print("Predicted Salary = ", model.predict(features))
```

```
Years of Experience : 2
Predicted Salary = [[44169.21365784]]
```

إذن هذه هي الطريقة التي يمكنك بها حل مشكلة التنبؤ بالراتب كمبتدئ في علوم البيانات.

الملخص

يعد التنبؤ بالراتب مشكلة شائعة بين مجتمع علوم البيانات للمبتدئين تمامًا. من خلال تحليل الانحدار هذا، وجدنا علاقة خطية مثالية بين الراتب والخبرة الوظيفية للأفراد. هذا يعني أن المزيد من الخبرة الوظيفية يؤدي إلى راتب أعلى. أمل أن تكون قد أحببت هذه المقالة حول مهمة التنبؤ بالراتب باستخدام التعلم الآلي باستخدام بايثون.

2) تجميع بطاقات الائتمان مع التعلم الآلي Credit Card Clustering with Machine Learning

تجميع بطاقات الائتمان (Credit card clustering) هو مهمة تجميع حاملي بطاقات الائتمان بناءً على عادات الشراء وحدود الائتمان والعديد من العوامل المالية الأخرى. إذا كنت تريد معرفة كيفية استخدام تحليل المجموعات لتجميع حاملي بطاقات الائتمان، فهذه المقالة مناسبة لك. في هذه المقالة، سوف آخذك خلال مهمة تجميع بطاقات الائتمان باستخدام التعلم الآلي باستخدام بايثون.

تجميع بطاقات الائتمان

يعني تجميع بطاقات الائتمان تجميع حاملي بطاقات الائتمان بناءً على عادات الشراء (buying habits) وحدود الائتمان (credit limits) والعديد من العوامل المالية الأخرى. يُعرف أيضًا باسم تجزئة بطاقة الائتمان (credit card segmentation). يساعد تحليل المجموعات هذا الشركات في العثور على عملائها المحتملين والعديد من استراتيجيات التسويق الأخرى.

بالنسبة لمهمة تجميع بطاقات الائتمان مع التعلم الآلي، نحتاج إلى مجموعة بيانات تستند إلى سجل الشراء لحاملي بطاقات الائتمان. لقد وجدت مجموعة بيانات مثالية لهذه المهمة تحتوي على جميع الميزات الضرورية التي تكفي لفهم تحليل مجموعة بطاقات الائتمان. يمكنك تنزيل مجموعة البيانات من [هنا](#).

في القسم أدناه، سوف آخذك خلال مهمة تحليل مجموعات بطاقات الائتمان باستخدام التعلم الآلي باستخدام لغة برمجة بايثون.

تجميع بطاقات الائتمان باستخدام بايثون

لنبدأ مهمة تحليل مجموعة بطاقات الائتمان عن طريق استيراد مكتبات بايثون ومجموعة البيانات اللازمة:

```
import pandas as pd
import numpy as np
from sklearn import cluster

data = pd.read_csv("CC_GENERAL.csv")
print(data.head())
```

	CUST_ID	BALANCE	BALANCE_FREQUENCY	PURCHASES	ONEOFF_PURCHASES	\
0	C10001	40.900749	0.818182	95.40	0.00	
1	C10002	3202.467416	0.909091	0.00	0.00	
2	C10003	2495.148862	1.000000	773.17	773.17	
3	C10004	1666.670542	0.636364	1499.00	1499.00	
4	C10005	817.714335	1.000000	16.00	16.00	

	INSTALLMENTS_PURCHASES	CASH_ADVANCE	PURCHASES_FREQUENCY	\
0	95.4	0.000000	0.166667	
1	0.0	6442.945483	0.000000	
2	0.0	0.000000	1.000000	
3	0.0	205.788017	0.083333	
4	0.0	0.000000	0.083333	

	ONEOFF_PURCHASES_FREQUENCY	PURCHASES_INSTALLMENTS_FREQUENCY	\
0	0.000000	0.083333	
1	0.000000	0.000000	
2	1.000000	0.000000	
3	0.083333	0.000000	
4	0.083333	0.000000	

	CASH_ADVANCE_FREQUENCY	CASH_ADVANCE_TRX	PURCHASES_TRX	CREDIT_LIMIT	\
0	0.000000	0	2	1000.0	
1	0.250000	4	0	7000.0	
2	0.000000	0	12	7500.0	
3	0.083333	1	1	7500.0	
4	0.000000	0	1	1200.0	

	PAYMENTS	MINIMUM_PAYMENTS	PRC_FULL_PAYMENT	TENURE
0	201.802084	139.509787	0.000000	12
1	4103.032597	1072.340217	0.222222	12
2	622.066742	627.284787	0.000000	12
3	0.000000	NaN	0.000000	12
4	678.334763	244.791237	0.000000	12

قبل المضي قدماً، دعنا نتحقق مما إذا كانت مجموعة البيانات هذه تحتوي على أي قيم فارغة أم لا:

```
data.isnull().sum()
```

```
CUST_ID                0
BALANCE                0
BALANCE_FREQUENCY      0
PURCHASES              0
ONEOFF_PURCHASES      0
INSTALLMENTS_PURCHASES 0
CASH_ADVANCE           0
PURCHASES_FREQUENCY    0
ONEOFF_PURCHASES_FREQUENCY 0
PURCHASES_INSTALLMENTS_FREQUENCY 0
CASH_ADVANCE_FREQUENCY 0
CASH_ADVANCE_TRX       0
PURCHASES_TRX          0
CREDIT_LIMIT           1
PAYMENTS               0
MINIMUM_PAYMENTS       313
PRC_FULL_PAYMENT        0
TENURE                 0
dtype: int64
```

تحتوي مجموعة البيانات على بعض القيم الخالية في عمود الحد الأدنى للمدفوعات (**minimum payments column**). سوف أسقط الصفوف ذات القيم الفارغة وسأنتقل إلى أبعد من ذلك:

```
data = data.dropna()
```

هناك ثلاث ميزات في مجموعة البيانات تعتبر ذات قيمة كبيرة لمهمة تقسيم بطاقة الائتمان:

1. **BALANCE**: الرصيد المتبقي في حسابات عملاء بطاقات الائتمان.

2. **PURCHASES**: مقدار المشتريات التي تمت من حسابات عملاء بطاقات الائتمان.

3. **CREDIT_LIMIT**: حد بطاقة الائتمان.

هذه الميزات الثلاث كافية لتجميع حاملي بطاقات الائتمان حيث يخبروننا عن تاريخ الشراء (**buying history**)، والرصيد المصرفي (**bank balance**)، والحد الائتماني (**credit limit**) لحاملي بطاقات الائتمان. فلنستخدم هذه الميزات لإنشاء مجموعات من مجموعة البيانات:

```
clustering_data = data[["BALANCE", "PURCHASES",
"CREDIT_LIMIT"]]
from sklearn.preprocessing import MinMaxScaler
for i in clustering_data.columns:
    MinMaxScaler(i)

from sklearn.cluster import KMeans
kmeans = KMeans(n_clusters=5)
clusters = kmeans.fit_predict(clustering_data)
data["CREDIT_CARD_SEGMENTS"] = clusters
```

لقد أضفت عمودًا جديدًا باسم "**CREDIT_CARD_SEGMENTS**". يحتوي على تسميات (**labels**) حول مجموعة عملاء بطاقات الائتمان. تتراوح المجموعات المكونة من 0 إلى 4. للتبسيط، سأقوم بتحويل أسماء هذه المجموعات:

```
data["CREDIT_CARD_SEGMENTS"] =
data["CREDIT_CARD_SEGMENTS"].map({0: "Cluster 1", 1:
"Cluster 2", 2: "Cluster 3", 3: "Cluster 4", 4: "Cluster 5"})
print(data["CREDIT_CARD_SEGMENTS"].head(10))
```

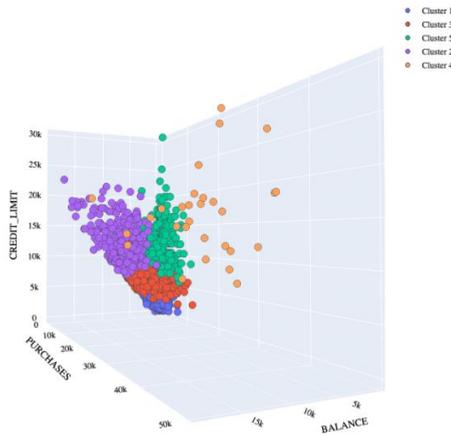
```
0    Cluster 1
1    Cluster 3
2    Cluster 3
4    Cluster 1
5    Cluster 1
6    Cluster 5
7    Cluster 1
8    Cluster 3
9    Cluster 5
10   Cluster 1
Name: CREDIT_CARD_SEGMENTS, dtype: object
```

الآن دعونا نرسم مجموعات بطاقات الائتمان التي وجدناها من تحليل المجموعة لدينا:

```
import plotly.graph_objects as go
PLOT = go.Figure()
for i in list(data["CREDIT_CARD_SEGMENTS"].unique()):

    PLOT.add_trace(go.Scatter3d(x =
data[data["CREDIT_CARD_SEGMENTS"]== i]['BALANCE'],
        y = data[data["CREDIT_CARD_SEGMENTS"] ==
i]['PURCHASES'],
        z = data[data["CREDIT_CARD_SEGMENTS"] ==
i]['CREDIT_LIMIT']
        ,
        mode = 'markers',marker_size = 6,
marker_line_width = 1,
        name = str(i)((
PLOT.update_traces(hovertemplate='BALANCE: %{x} <br>PURCHASES
%{y} <br>DCREDIT_LIMIT: %{z}')
```

```
PLOT.update_layout(width = 800, height = 800, autosize = True,
showlegend = True,
        scene = dict(xaxis=dict(title = 'BALANCE',
titlefont_color = 'black,'
        yaxis=dict(title = 'PURCHASES', titlefont_color =
'black'),
        zaxis=dict(title = 'CREDIT_LIMIT',
titlefont_color = 'black'),(
        font = dict(family = "Gilroy", color =
'black', size = 12))
```



هذه هي الطريقة التي يمكنك بها إجراء تجزئة لبطاقات الائتمان باستخدام التعلم الآلي باستخدام بايثون.

الملخص

يعني تحليل مجموعة بطاقات الائتمان تجميع حاملي بطاقات الائتمان بناءً على عادات الشراء وحدود الائتمان والعديد من العوامل المالية الأخرى. يساعد تحليل المجموعات هذا الشركات في العثور على عملائها المحتملين والعديد من استراتيجيات التسويق الأخرى. أمل أن تكون قد أحببت هذه المقالة حول تجزئة بطاقة الائتمان باستخدام التعلم الآلي باستخدام بايثون.

3) التنبؤ بإيجار المنزل باستخدام التعلم الآلي House Rent Prediction with Machine Learning

يعتمد إيجار المنزل (House Rent) على العديد من العوامل. مع البيانات المناسبة وتقنيات التعلم الآلي، تجد العديد من المنصات العقارية خيارات الإسكان وفقاً لميزانية العميل. لذلك، إذا كنت تريد معرفة كيفية استخدام التعلم الآلي للتنبؤ بإيجار منزل، فهذه المقالة مناسبة لك. في هذه المقالة، سوف نخوض في مهمة التنبؤ بإيجار المنزل باستخدام التعلم الآلي باستخدام بايثون.

التنبؤ بإيجار المنزل

يعتمد إيجار عقار سكني على العديد من العوامل مثل:

1. عدد غرف النوم والصالة والمطبخ (number of bedrooms, hall, and kitchen).
2. حجم العقار (size of the property).
3. أرضية المنزل (the floor of the house).
4. نوع المنطقة (area type).
5. محلة المنطقة (area locality).
6. المدينة (City).
7. حالة تأثيث المنزل (furnishing status of the house).

لبناء نظام التنبؤ بإيجار المنزل، نحتاج إلى بيانات تستند إلى العوامل التي تؤثر على إيجار عقار سكني. لقد عثرت على مجموعة بيانات من Kaggle تتضمن جميع الميزات التي نحتاجها. يمكنك تنزيل مجموعة البيانات من [هنا](#).

التنبؤ بإيجار المنزل باستخدام لغة بايثون

سأبدأ مهمة التنبؤ بإيجار المنزل عن طريق استيراد مكتبات بايثون ومجموعة البيانات اللازمة:

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import plotly.express as px
import plotly.graph_objects as go

data = pd.read_csv("House_Rent_Dataset
```

```

Posted On  BHK  Rent  Size      Floor  Area Type \
0 2022-05-18  2 10000 1100  Ground out of 2  Super Area
1 2022-05-13  2 20000  800    1 out of 3  Super Area
2 2022-05-16  2 17000 1000    1 out of 3  Super Area
3 2022-07-04  2 10000  800    1 out of 2  Super Area
4 2022-05-09  2  7500  850    1 out of 2  Carpet Area

Area Locality  City  Furnishing Status  Tenant Preferred \
0              Bandel  Kolkata  Unfurnished  Bachelors/Family
1 Phool Bagan, Kankurgachi  Kolkata  Semi-Furnished  Bachelors/Family
2 Salt Lake City Sector 2  Kolkata  Semi-Furnished  Bachelors/Family
3              Dumdum Park  Kolkata  Unfurnished  Bachelors/Family
4              South Dum Dum  Kolkata  Unfurnished  Bachelors

Bathroom Point of Contact
0      2  Contact Owner
1      1  Contact Owner
2      1  Contact Owner
3      1  Contact Owner
4      1  Contact Owner

```

قبل المضي قدماً، دعنا نتحقق مما إذا كانت البيانات تحتوي على قيم خالية أم لا:

```
print(data.isnull().sum())
```

```

Posted On      0
BHK            0
Rent           0
Size           0
Floor         0
Area Type      0
Area Locality  0
City           0
Furnishing Status  0
Tenant Preferred  0
Bathroom       0
Point of Contact  0
dtype: int64

```

دعونا نلقي نظرة على الإحصائيات الوصفية للبيانات:

```
print(data.describe())
```

```

count      BHK      Rent      Size      Bathroom
count  4746.000000  4.746000e+03  4746.000000  4746.000000
mean      2.083860  3.499345e+04  967.490729  1.965866
std       0.832256  7.810641e+04  634.202328  0.884532
min       1.000000  1.200000e+03  10.000000  1.000000
25%      2.000000  1.000000e+04  550.000000  1.000000
50%      2.000000  1.600000e+04  850.000000  2.000000
75%      3.000000  3.300000e+04  1200.000000  2.000000
max       6.000000  3.500000e+06  8000.000000  10.000000

```

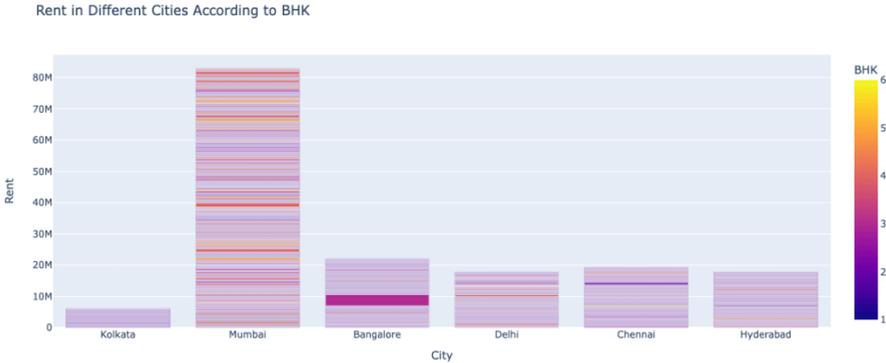
دعنا الآن نلقي نظرة على متوسط (mean) الإيجار ووسيطه (median) وأعلى (highest) وأدنى (lowest) إيجار للمنازل:

```
print(f"Mean Rent: {data.Rent.mean()}")
print(f"Median Rent: {data.Rent.median()}")
print(f"Highest Rent: {data.Rent.max()}")
print(f"Lowest Rent: {data.Rent.min()}")
```

```
Mean Rent: 34993.45132743363
Median Rent: 16000.0
Highest Rent: 3500000
Lowest Rent: 1200
```

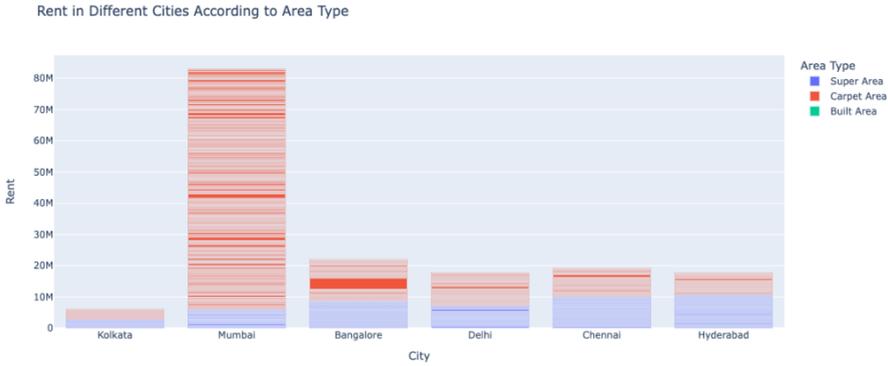
دعونا الآن نلقي نظرة على إيجار المنازل في مدن مختلفة حسب عدد غرف النوم والصالات والمطابخ:

```
figure = px.bar(data, x=data["City"],
                y = data["Rent"],
                color = data["BHK"],
                title="Rent in Different Cities According to BHK")
figure.show()
```



دعونا الآن نلقي نظرة على إيجار المنازل في مدن مختلفة وفقاً لنوع المنطقة:

```
figure = px.bar(data, x=data["City"],
                y = data["Rent"],
                color = data["Area Type"],
                title="Rent in Different Cities According to Area Type")
figure.show()
```



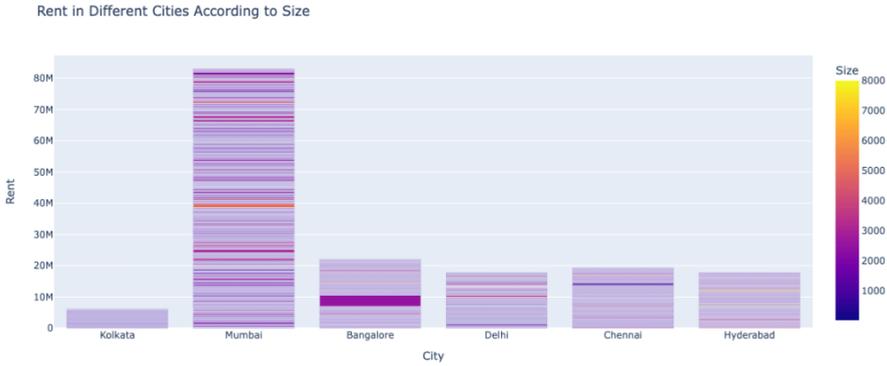
دعونا الآن نلقي نظرة على إيجار المنازل في مدن مختلفة وفقاً لحالة تأثيث المنزل:

```
figure = px.bar(data, x=data["City"],
               y = data["Rent"],
               color = data["Furnishing Status"],
               title="Rent in Different Cities According to Furnishing Status")
figure.show()
```



دعونا الآن نلقي نظرة على إيجار المنازل في مدن مختلفة حسب حجم المنزل:

```
figure = px.bar(data, x=data["City"],
               y = data["Rent"],
               color = data["Size"],
               title="Rent in Different Cities According to Size")
figure.show()
```

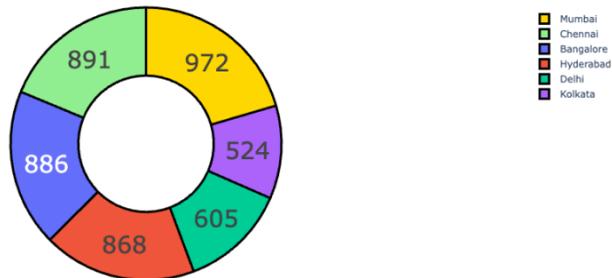


دعونا الآن نلقي نظرة على عدد المنازل المتاحة للإيجار في مدن مختلفة وفقاً لمجموعة البيانات:

```
cities = data["City"].value_counts()
label = cities.index
counts = cities.values
colors = ['gold', 'lightgreen']

fig = go.Figure(data=[go.Pie(labels=label, values=counts,
hole=0.5)])
fig.update_layout(title_text='Number of Houses Available for
Rent')
fig.update_traces(hoverinfo='label+percent', textinfo='value',
textfont_size=30,
marker=dict(colors=colors, line=dict(color='black',
width=3)))
fig.show()
```

Number of Houses Available for Rent



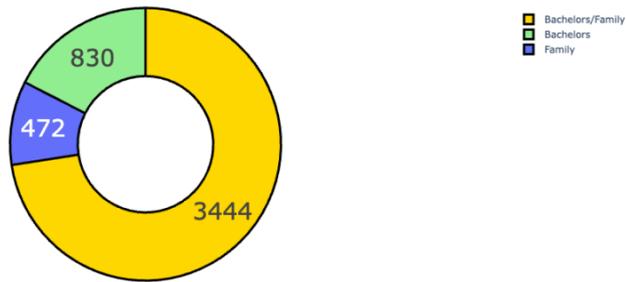
دعونا الآن نلقي نظرة على عدد المنازل المتاحة لأنواع مختلفة من المستأجرين (**tenants**):

```
#Preference of Tenant
tenant = data["Tenant Preferred"].value_counts()
label = tenant.index
```

```
counts = tenant.values
colors = ['gold', 'lightgreen']

fig = go.Figure(data=[go.Pie(labels=label, values=counts,
hole=0.5)])
fig.update_layout(title_text='Preference of Tenant in India')
fig.update_traces(hoverinfo='label+percent', textinfo='value',
textfont_size=30,
marker=dict(colors=colors, line=dict(color='black',
width=3)))
fig.show()
```

Preference of Tenant in India



نموذج التنبؤ بإيجار المنزل

الآن سأحول جميع الميزات الفئوية (categorical features) إلى ميزات عددية نحتاجها لتدريب نموذج التنبؤ بإيجار المنزل:

```
data["Area Type"] = data["Area Type"].map({"Super Area": 1,
"
    Carpet Area": 2,
"
    Built Area": 3})
data["City"] = data["City"].map({"Mumbai": 4000, "Chennai":
6000,
"
    Bangalore": 5600, "Hyderabad": 5000,
"
    Delhi": 1100, "Kolkata": 7000})
data["Furnishing Status"] = data["Furnishing
Status"].map({"Unfurnished": 0,
"
    Semi-Furnished": 1,
"
    Furnished": 2})
data["Tenant Preferred"] = data["Tenant
Preferred"].map({"Bachelors/Family": 2,
"
    Bachelors": 1,
"
    Family": 3})
```

	Posted On	BHK	Rent	Size	Floor	Area Type \
0	2022-05-18	2	10000	1100	Ground out of 2	1
1	2022-05-13	2	20000	800	1 out of 3	1
2	2022-05-16	2	17000	1000	1 out of 3	1
3	2022-07-04	2	10000	800	1 out of 2	1
4	2022-05-09	2	7500	850	1 out of 2	2

	Area Locality	City	Furnishing Status	Tenant Preferred \
0	Bandel	7000	0	2
1	Phool Bagan, Kankurgachi	7000	1	2
2	Salt Lake City Sector 2	7000	1	2
3	Dumdum Park	7000	0	2
4	South Dum Dum	7000	0	1

	Bathroom	Point of Contact
0	2	Contact Owner
1	1	Contact Owner
2	1	Contact Owner
3	1	Contact Owner
4	1	Contact Owner

الآن سأقسم البيانات إلى مجموعات تدريب واختبار:

```
##splitting data
from sklearn.model_selection import train_test_split
x = np.array(data[["BHK", "Size", "Area Type", "City",
                  "Furnishing Status", "Tenant Preferred",
                  "Bathroom"]])
y = np.array(data[["Rent"]])

xtrain, xtest, ytrain, ytest = train_test_split(x, y,
                                               test_size=0.10,
                                               random_state=42)
```

دعنا الآن ندرّب نموذج التنبؤ بإيجار المنزل باستخدام نموذج الشبكة العصبية LSTM:

```
from keras.models import Sequential
from keras.layers import Dense, LSTM
model = Sequential()
model.add(LSTM(128, return_sequences=True,
              input_shape= (xtrain.shape[1], 1)))
model.add(LSTM(64, return_sequences=False))
model.add(Dense(25))
model.add(Dense(1))
```

Model: "sequential"

Layer (type)	Output Shape	Param #
lstm (LSTM)	(None, 7, 128)	66560
lstm_1 (LSTM)	(None, 64)	49408
dense (Dense)	(None, 25)	1625
dense_1 (Dense)	(None, 1)	26

=====
 Total params: 117,619
 Trainable params: 117,619
 Non-trainable params: 0

```
model.compile(optimizer='adam', loss='mean_squared_error')
model.fit(xtrain, ytrain, batch_size=1, epochs=21)
```

```
Epoch 1/21
4271/4271 [=====] - 35s 7ms/step - loss: 7038080512.0000
Epoch 2/21
4271/4271 [=====] - 31s 7ms/step - loss: 6481502720.0000
Epoch 3/21
4271/4271 [=====] - 31s 7ms/step - loss: 6180754944.0000
Epoch 4/21
4271/4271 [=====] - 31s 7ms/step - loss: 5968361472.0000
Epoch 5/21
4271/4271 [=====] - 30s 7ms/step - loss: 5770649088.0000
Epoch 6/21
4271/4271 [=====] - 29s 7ms/step - loss: 5618835968.0000
Epoch 7/21
4271/4271 [=====] - 30s 7ms/step - loss: 5440893952.0000
Epoch 8/21
4271/4271 [=====] - 29s 7ms/step - loss: 5341533696.0000
Epoch 9/21
4271/4271 [=====] - 30s 7ms/step - loss: 5182846976.0000
Epoch 10/21
4271/4271 [=====] - 31s 7ms/step - loss: 5106288128.0000
Epoch 11/21
4271/4271 [=====] - 30s 7ms/step - loss: 5076118528.0000
Epoch 12/21
4271/4271 [=====] - 30s 7ms/step - loss: 5001080320.0000
Epoch 13/21
4271/4271 [=====] - 31s 7ms/step - loss: 4941253120.0000
Epoch 14/21
4271/4271 [=====] - 33s 8ms/step - loss: 4904356864.0000
Epoch 15/21
4271/4271 [=====] - 29s 7ms/step - loss: 4854262784.0000
Epoch 16/21
4271/4271 [=====] - 30s 7ms/step - loss: 4855796736.0000
Epoch 17/21
4271/4271 [=====] - 36s 8ms/step - loss: 4764052480.0000
Epoch 18/21
4271/4271 [=====] - 30s 7ms/step - loss: 4709226496.0000
Epoch 19/21
4271/4271 [=====] - 31s 7ms/step - loss: 4702300160.0000
Epoch 20/21
4271/4271 [=====] - 31s 7ms/step - loss: 4670900736.0000
Epoch 21/21
4271/4271 [=====] - 31s 7ms/step - loss: 4755582976.0000
<keras.callbacks.History at 0x7fd1deb6c9d0>
```

الآن إليك كيفية التنبؤ بإيجار عقار سكني باستخدام النموذج المدرب:

```
print("Enter House Details to Predict Rent")
a = int(input("Number of BHK: "))
b = int(input("Size of the House: "))
c = int(input("Area Type (Super Area = 1, Carpet Area = 2,
Built Area = 3): "))
d = int(input("Pin Code of the City: "))
e = int(input("Furnishing Status of the House (Unfurnished =
0, Semi-Furnished = 1, Furnished = 2): "))
f = int(input("Tenant Type (Bachelors = 1, Bachelors/Family =
2, Only Family = 3): "))
g = int(input("Number of bathrooms: "))
features = np.array([[a, b, c, d, e, f, g]])
print("Predicted House Price = ", model.predict(features))
```

```
Enter House Details to Predict Rent
Number of BHK: 3
Size of the House: 1100
Area Type (Super Area = 1, Carpet Area = 2, Built Area = 3): 2
Pin Code of the City: 1100
Furnishing Status of the House (Unfurnished = 0, Semi-Furnished = 1, Furnished = 2): 1
Tenant Type (Bachelors = 1, Bachelors/Family = 2, Only Family = 3): 3
Number of bathrooms: 2
Predicted House Price = [[34922.3]]
```

الملخص

هذه هي كيفية استخدام التعلم الآلي للتنبؤ بإيجار عقار سكني. مع البيانات المناسبة وتقنيات التعلم الآلي، تجد العديد من المنصات العقارية خيارات الإسكان وفقاً لميزانية العميل. أمل أن تكون قد أحببت هذه المقالة حول التنبؤ بإيجار المنزل باستخدام التعلم الآلي باستخدام بايثون.

4) مدقق قوة كلمة المرور مع التعلم الآلي Password Strength Checker with Machine Learning

مدقق قوة كلمة المرور (Password Strength Checker) هو تطبيق يتحقق من مدى قوة كلمة المرور. تستخدم بعض مقاييس قوة كلمة المرور الشائعة خوارزميات التعلم الآلي للتنبؤ بقوة كلمة المرور الخاصة بك. لذلك، إذا كنت تريد معرفة كيفية استخدام التعلم الآلي للتحقق من قوة كلمة المرور، فهذه المقالة مناسبة لك. في هذه المقالة، سوف أطلعك على كيفية إنشاء مدقق قوة كلمة المرور باستخدام التعلم الآلي باستخدام بايثون.

كيفية إنشاء مدقق قوة كلمة المرور؟

يعمل مدقق قوة كلمة المرور من خلال فهم مجموعة الأرقام والأحرف والرموز الخاصة التي تستخدمها في كلمة مرورك. يتم إنشاؤه من خلال تدريب نموذج التعلم الآلي على مجموعة بيانات مصنفة من مجموعات مختلفة من الأحرف والرموز الخاصة التي يستخدمها الأشخاص في كلمات المرور. يتعلم النموذج من البيانات حول مجموعات الأحرف والرموز التي يمكن تصنيفها على أنها كلمة مرور صلبة أو ضعيفة.

لذلك لإنشاء تطبيق للتحقق من قوة كلمات المرور، نحتاج إلى مجموعة بيانات معونة حول مجموعات مختلفة من الأحرف والرموز. لقد عثرت على مجموعة بيانات على Kaggle لتدريب نموذج التعلم الآلي للتنبؤ بقوة كلمة المرور. يمكننا استخدام تلك البيانات لهذه المهمة. يمكنك تنزيل مجموعة البيانات من [هنا](#).

في القسم أدناه، سوف أطلعك على كيفية استخدام التعلم الآلي لإنشاء مدقق قوة كلمة المرور باستخدام بايثون.

مدقق قوة كلمة المرور باستخدام بايثون

لنبدأ باستيراد مكتبات بايثون ومجموعة البيانات اللازمة لإنشاء مدقق قوة كلمة المرور:

```
import pandas as pd
import numpy as np
from sklearn.feature_extraction.text import CountVectorizer
from sklearn.feature_extraction.text import TfidfVectorizer
from sklearn.model_selection import train_test_split
from sklearn.ensemble import RandomForestClassifier

data = pd.read_csv("data.csv", error_bad_lines=False)
print(data.head())
```

	password	strength
0	kzde5577	1
1	kino3434	1
2	visi7k1yr	1
3	megzy123	1
4	lamborghin1	1

تتكون مجموعة البيانات من عمودين؛ كلمة المرور (`password`) والقوة (`strength`). في عمود القوة:

0 يعني: قوة كلمة المرور ضعيفة (`weak`)؛

1 تعني: قوة كلمة المرور متوسطة (`medium`)؛

2 تعني: قوة كلمة المرور قوية (`strong`)؛

قبل المضي قدمًا، سأحول القيم 0 و 1 و 2 في عمود القوة إلى قيم ضعيفة ومتوسطة وقوية:

```
data = data.dropna()
data["strength"] = data["strength"].map({0: "Weak",
":1": "Medium",
":2": "Strong"})
print(data.sample(5))
```

	password	strength
476676	xupet0n	Weak
112569	cdm06690669	Medium
267402	bluerose1291	Medium
237407	2298409uur	Medium
336018	jejien8	Weak

نموذج التنبؤ بقوة كلمة المرور

دعنا الآن ننتقل إلى تدريب نموذج التعلم الآلي للتنبؤ بقوة كلمة المرور. قبل أن نبدأ في إعداد النموذج، نحتاج إلى ترميز (`tokenize`) كلمات المرور لأننا نحتاج إلى النموذج للتعلم من مجموعات الأرقام والحروف والرموز للتنبؤ بقوة كلمة المرور. إذن، إليك كيف يمكننا ترميز البيانات وتقسيمها إلى مجموعات تدريب واختبار:

```
def word(password):
    character=[]
    for i in password:
        character.append(i)
    return character

x = np.array(data["password"])
y = np.array(data["strength"])

tdif = TfidfVectorizer(tokenizer=word)
x = tdif.fit_transform(x)
xtrain, xtest, ytrain, ytest = train_test_split(x, y,
```

```
test_size=0.05,
random_state=42)
```

إليك الآن كيفية تدريب نموذج التصنيف للتنبؤ بقوة كلمة المرور:

```
model = RandomForestClassifier()
model.fit(xtrain, ytrain)
print(model.score(xtest, ytest))
```

```
0.956991816498417
```

الآن إليك كيف يمكننا التحقق من قوة كلمة المرور باستخدام النموذج المدرب:

```
import getpass
user = getpass.getpass("Enter Password: ")
data = tdif.transform([user]).toarray()
output = model.predict(data)
print(output)
```

```
Enter Password: .....
['Strong']
```

الملخص

هذه هي الطريقة التي يمكنك بها استخدام التعلم الآلي لإنشاء مدقق قوة كلمة المرور باستخدام لغة برمجة بايثون. يعمل مدقق قوة كلمة المرور من خلال فهم مجموعة الأرقام والأحرف والرموز الخاصة التي تستخدمها في كلمة مرورك. آمل أن تكون قد أحببت هذه المقالة حول إنشاء مدقق قوة كلمة المرور باستخدام التعلم الآلي باستخدام بايثون.

5) اكتشاف التعليقات غير المرغوب فيها باستخدام التعلم الآلي Spam Comments Detection with Machine Learning

يعني اكتشاف التعليقات غير المرغوب (Spam comments detection) فيها تصنيف التعليقات على أنها تعليقات غير مرغوب بها (spam) أو ليست تعليقات غير مرغوب بها (not spam). يُعد YouTube أحد الأنظمة الأساسية التي تستخدم التعلم الآلي لتصنيف التعليقات غير المرغوب فيها تلقائياً لحفظ منشئها من التعليقات غير المرغوب فيها. إذا كنت تريد معرفة كيفية اكتشاف التعليقات غير المرغوب فيها باستخدام "التعلم الآلي"، فهذه المقالة مناسبة لك. في هذه المقالة، سوف آخذك خلال مهمة الكشف عن التعليقات غير المرغوب فيها باستخدام التعلم الآلي باستخدام بايثون.

اكتشاف التعليقات غير المرغوب فيها

يعد اكتشاف التعليقات غير المرغوب فيها مهمة تصنيف النص (text classification) في التعلم الآلي. التعليقات غير المرغوب فيها على منصات التواصل الاجتماعي هي نوع التعليقات المنشورة لإعادة توجيه المستخدم إلى حساب وسائط اجتماعية آخر أو موقع ويب أو أي جزء من المحتوى.

لاكتشاف التعليقات غير المرغوب فيها باستخدام التعلم الآلي، نحتاج إلى بيانات مصنفة لتعليقات غير المرغوب بها. لحسن الحظ، وجدت مجموعة بيانات على Kaggle حول تعليقات غير المرغوب بها على YouTube والتي ستكون مفيدة لمهمة اكتشاف التعليقات غير المرغوب فيها. يمكنك تنزيل مجموعة البيانات من [هنا](#).

في القسم أدناه، ستتعلم كيفية اكتشاف التعليقات غير المرغوب فيها باستخدام التعلم الآلي باستخدام لغة برمجة بايثون.

اكتشاف التعليقات غير المرغوب فيها باستخدام بايثون

لنبدأ هذه المهمة عن طريق استيراد مكتبات بايثون ومجموعة البيانات الضرورية:

```
import pandas as pd
import numpy as np
from sklearn.feature_extraction.text import CountVectorizer
from sklearn.model_selection import train_test_split
from sklearn.naive_bayes import BernoulliNB

data = pd.read_csv("Youtube01-Psy.csv")
print(data.sample(5))
```

```

                COMMENT_ID      AUTHOR \
287  z13vnhh5ewvdyzh3o23bjz551xbwjznor04  diego acosta
43   z12jvnuu2tifirkvk23cfjtpxwmgxfch004  Didier Drogba
265  z13ucxdzemugi1v5n04ccjloko25drfb4js  Haley Harmicar
322  z13uffbajziyw5cfp23bwbw5auytzd15b04  Juris Dumagan
89   z12pzpvpbf12igbwhe04cihtpuwymvr5gvsg0k  NstyIC Gold

                DATE                CONTENT \
287  2014-11-08T10:05:27  If I get 100 subscribers, I will summon Freddy...
43   2014-01-20T06:57:25  http://www.twitch.tv/jaroadc come follow and w...
265  2014-11-08T05:35:42  9 year olds be like, 'How does this have 2 bil...
322  2014-11-12T11:03:25                I think he was drunk during this :) x)
89   2014-11-03T20:41:23  Ching Ching ling long ding ring yaaaaaa Ganga ...

                CLASS
287      1
43       1
265      0
322      0
89       0

```

نحتاج فقط إلى عمود المحتوى (`content column`) وعمود الفئة (`class column`) من مجموعة البيانات لبقية المهمة. لذلك دعونا نحدد كلا العمودين ونتحرك أبعد من ذلك:

```
data = data[["CONTENT", "CLASS"]]
print(data.sample(5))
```

```

                CONTENT  CLASS
160  CHECK MY CHANNEL FOR MY NEW SONG 'STATIC'!! YO...      1
157          Follow me on Twitter @mscalifornia95          1
336  To everyone joking about how he hacked to get ...      0
329  FOLLOW MY COMPANY ON TWITTER thanks. https://...      1
79   Hi there~I'm group leader of Angel, a rookie K...      1

```

يحتوي عمود الفئة على القيمتين 0 و 1. يشير 0 إلى أنه ليس تعليق غير مرغوب به، ويشير الرقم 1 إلى تعليق غير مرغوب به. ولجعل الأمر يبدو أفضل، سأستخدم تسميات "spam" و "not spam" بدلاً من 1 و 0:

```
data["CLASS"] = data["CLASS"].map({0: "Not Spam,"
                                   " :1  Spam Comment"})
print(data.sample(5))
```

```

                CONTENT                CLASS
161          Incmedia.org where the truth meets you.  Spam Comment
335  Hey guys can you check my YouTube channel I kn...  Spam Comment
134          ♥ ♥ ♥ ♥ ♥ ♥ ♥ ♥ ♥ ♥ ♥ ♥ ♥ ♥ ♥ ♥      Not Spam
209  How can this music video get 2 billion views w...  Not Spam
45   ...subscribe..... .....to my..... .....      Spam Comment

```

تدريب نموذج التصنيف

دعنا الآن ننتقل إلى أبعد من ذلك من خلال تدريب نموذج التعلم الآلي لتصنيف التعليقات إلى "spam" و "not spam". نظراً لأن هذه المشكلة هي مشكلة تصنيف ثنائي، سأستخدم خوارزمية [Bernoulli Naive Bayes](#) لتدريب النموذج:

```
x = np.array(data["CONTENT"])
y = np.array(data["CLASS"])

cv = CountVectorizer()
x = cv.fit_transform(x)
xtrain, xttest, ytrain, ytest = train_test_split(x, y ,
test_size=0.2 ,
random_state=42(
model = BernoulliNB()
model.fit(xtrain, ytrain)
print(model.score(xttest, ytest))
```

```
0.9857142857142858
```

دعنا الآن نختبر النموذج من خلال تقديم تعليقات "spam" و "not spam" كإدخال:

```
sample = "Check this out: https://thecleverprogrammer.com " /
data = cv.transform([sample]).toarray()
print(model.predict(data))
```

```
['Spam Comment']
```

```
sample = "Lack of information!"
data = cv.transform([sample]).toarray()
print(model.predict(data))
```

```
['Not Spam']
```

هذه هي الطريقة التي يمكنك بها تدريب نموذج التعلم الآلي على مهمة اكتشاف البريد العشوائي باستخدام بايثون.

الملخص

يعني اكتشاف التعليقات غير المرغوب فيها تصنيف التعليقات على أنها تعليق غير مرغوب به أو ليست تعليق غير مرغوب به. التعليقات غير المرغوب فيها على منصات التواصل الاجتماعي هي نوع التعليقات المنشورة لإعادة توجيه المستخدم إلى حساب وسائط اجتماعية آخر أو موقع ويب أو أي جزء من المحتوى. أمل أن تكون قد أحببت هذه المقالة حول اكتشاف التعليقات غير المرغوب فيها باستخدام التعلم الآلي.

6) التنبؤ بطلب الطعام عبر الإنترنت باستخدام التعلم الآلي Online Food Order Prediction with Machine Learning

كان هناك طلب كبير على طلبات الطعام عبر الإنترنت ([online food orders](#)) بعد إدخال Swiggy و Zomato في السوق. تستخدم شركات توصيل الطعام عاداتك الشرائية لتسريع عملية التوصيل. يعد نظام التنبؤ بطلب الطعام أحد الأساليب المفيدة التي يمكن أن تستخدمها هذه الشركات لتسريع عملية التسليم بأكملها. في هذه المقالة، سأطلعك على مهمة التنبؤ بطلب الطعام عبر الإنترنت باستخدام التعلم الآلي باستخدام بايثون.

التنبؤ بطلب الطعام عبر الإنترنت: دراسة حالة

بعد تطبيق نظام توصيل الطعام الكامل عبر الإنترنت، ستحاول شركات مثل Swiggy و Zomato دائماً تحسينها. الهدف الرئيسي لهذه الشركات تجاه عملائها هو توصيل الطعام في الوقت المناسب. لتقديم الطعام بشكل أسرع، تحدد هذه الشركات المجالات التي يكون فيها الطلب على طلبات الطعام عبر الإنترنت مرتفعاً وتوظف المزيد من شركاء التوصيل في تلك المواقع. يساعد في توصيل الطعام بشكل أسرع في المناطق التي يوجد بها المزيد من الطلبات.

تمتلك هذه الشركات الكثير من البيانات حول عملائها لدرجة أنهم يعرفون الآن عادات طلب الطعام لجميع العملاء. باستخدام هذه البيانات، يمكنهم أيضاً التنبؤ بما إذا كان العميل سيطلب مرة أخرى من تطبيقه أم لا. إنها تقنية جيدة لتحديد المناطق والعائلات وأنواع العملاء مع المزيد من فرص العمل.

أمل أن تكون قد فهمت الآن حالة استخدام أنظمة التنبؤ بطلب الطعام عبر الإنترنت. في القسم أدناه، سأطلعك على كيفية تدريب نموذج التعلم الآلي للتنبؤ بطلبات الطعام عبر الإنترنت من عميل معين.

التنبؤ بطلبات الطعام عبر الإنترنت باستخدام لغة بايثون

لنبدأ الآن بمهمة التنبؤ بطلب الطعام عبر الإنترنت باستخدام التعلم الآلي. يمكنك تنزيل مجموعة البيانات التي أستخدمها لهذه المهمة من [هنا](#). لنبدأ باستيراد مكتبات بايثون ومجموعة البيانات الضرورية:

```
import numpy as np
import pandas as pd
import numpy as np
import plotly.express as px
import plotly.graph_objects as go
```

```
import matplotlib.pyplot as plt
import seaborn as sns
sns.set_theme(style="whitegrid")

data = pd.read_csv("onlinefoods.csv")
print(data.head())
```

	Age	Gender	Marital Status	Occupation	Monthly Income \
0	20	Female	Single	Student	No Income
1	24	Female	Single	Student	Below Rs.10000
2	22	Male	Single	Student	Below Rs.10000
3	22	Female	Single	Student	No Income
4	22	Male	Single	Student	Below Rs.10000

	Educational Qualifications	Family size	latitude	longitude	Pin code \
0	Post Graduate	4	12.9766	77.5993	560001
1	Graduate	3	12.9770	77.5773	560009
2	Post Graduate	3	12.9551	77.6593	560017
3	Graduate	6	12.9473	77.5616	560019
4	Post Graduate	4	12.9850	77.5533	560010

	Output	Feedback	Unnamed: 12
0	Yes	Positive	Yes
1	Yes	Positive	Yes
2	Yes	Negative	Yes
3	Yes	Positive	Yes
4	Yes	Positive	Yes

لذلك تحتوي مجموعة البيانات على معلومات مثل:

1. عمر العميل (Age).
2. جنس العميل (Gender).
3. الحالة الاجتماعية للعميل (Marital Status).
4. مهنة العميل (Occupation).
5. الدخل الشهري للعميل (Monthly Income).
6. المؤهل التعليمي للعميل (Educational Qualifications).
7. حجم الأسرة للعميل (Family size).
8. خطوط الطول والعرض لموقع العميل (longitude, latitude).
9. الرقم السري الخاص بمحل إقامة العميل (Pin code).

10. هل طلب العميل مرة أخرى (Output).

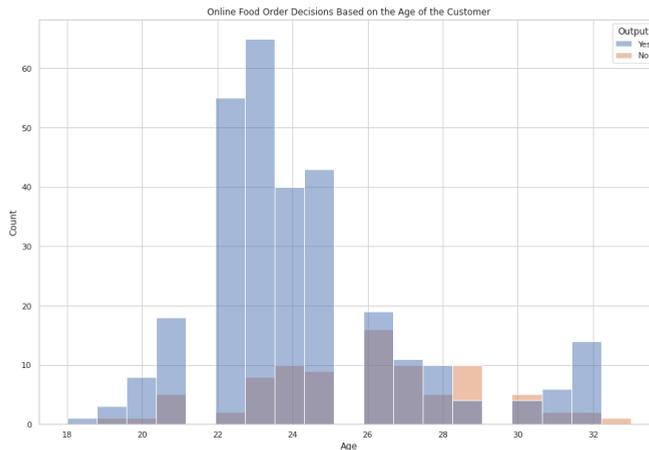
11. تعليقات (Feedback) على الطلب الأخير (إيجابي أو سلبي).

دعنا نلقي نظرة على المعلومات المتعلقة بجميع الأعمدة في مجموعة البيانات:

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 388 entries, 0 to 387
Data columns (total 13 columns):
#   Column                Non-Null Count  Dtype
---  ---
0   Age                   388 non-null   int64
1   Gender                388 non-null   object
2   Marital Status        388 non-null   object
3   Occupation            388 non-null   object
4   Monthly Income        388 non-null   object
5   Educational Qualifications 388 non-null   object
6   Family size           388 non-null   int64
7   latitude              388 non-null   float64
8   longitude             388 non-null   float64
9   Pin code              388 non-null   int64
10  Output                388 non-null   object
11  Feedback              388 non-null   object
12  Unnamed: 12           388 non-null   object
dtypes: float64(2), int64(3), object(8)
memory usage: 39.5+ KB
None
```

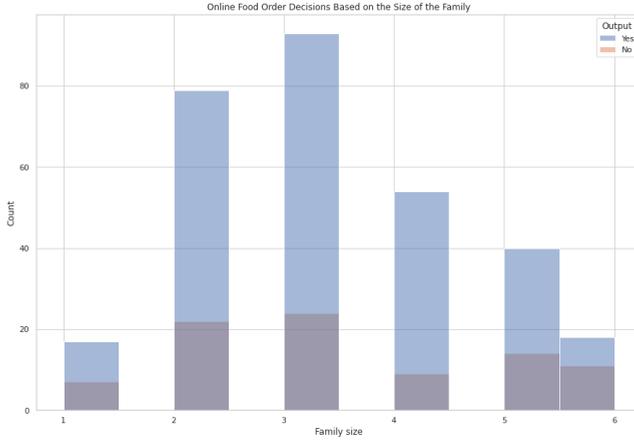
دعنا الآن ننتقل إلى تحليل هذه البيانات. سابدأ بإلقاء نظرة على قرارات طلب الطعام عبر الإنترنت بناءً على عمر العميل:

```
plt.figure(figsize=(15, 10))
plt.title("Online Food Order Decisions Based on the Age of the Customer")
sns.histplot(x="Age", hue="Output", data=data)
plt.show()
```



يمكننا أن نرى أن الفئة العمرية من 22-25 طلبت الطعام مراراً وتكراراً. وهذا يعني أيضاً أن هذه الفئة العمرية هي هدف شركات توصيل الطعام عبر الإنترنت. دعنا الآن نلقي نظرة على قرارات طلب الطعام عبر الإنترنت بناءً على حجم عائلة العميل:

```
plt.figure(figsize=(15, 10))
plt.title("Online Food Order Decisions Based on the Size of the Family")
sns.histplot(x="Family size", hue="Output", data=data)
plt.show()
```



تطلب العائلات المكونة من 2 و 3 أفراد الطعام كثيراً. يمكن أن يكون هؤلاء رفقاء في السكن أو أزواج أو أسرة مكونة من ثلاثة أفراد.

لننشئ مجموعة بيانات لجميع العملاء الذين طلبوا الطعام مرة أخرى:

```
buying_again_data = data.query("Output == 'Yes'")
print(buying_again_data.head())
```

	Age	Gender	Marital Status	Occupation	Monthly Income	\
0	20	Female	Single	Student	No Income	
1	24	Female	Single	Student	Below Rs.10000	
2	22	Male	Single	Student	Below Rs.10000	
3	22	Female	Single	Student	No Income	
4	22	Male	Single	Student	Below Rs.10000	

	Educational Qualifications	Family size	latitude	longitude	Pin code	\
0	Post Graduate	4	12.9766	77.5993	560001	
1	Graduate	3	12.9770	77.5773	560009	
2	Post Graduate	3	12.9551	77.6593	560017	
3	Graduate	6	12.9473	77.5616	560019	
4	Post Graduate	4	12.9850	77.5533	560010	

	Output	Feedback	Unnamed: 12
0	Yes	Positive	Yes
1	Yes	Positive	Yes
2	Yes	Negative	Yes
3	Yes	Positive	Yes
4	Yes	Positive	Yes

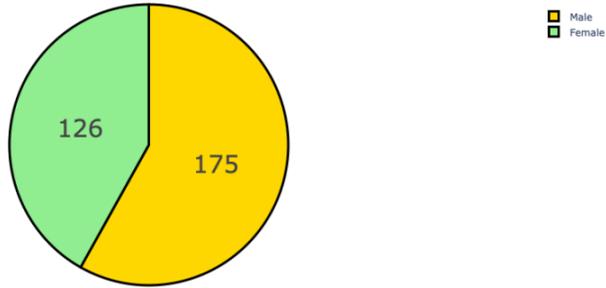
الآن دعونا نلقي نظرة على عمود الجنس. لتتعرف على من يطلب الطعام عبر الإنترنت:

```
gender = buying_again_data["Gender"].value_counts()
label = gender.index
counts = gender.values
colors = ['gold', 'lightgreen']

fig = go.Figure(data=[go.Pie(labels=label, values=counts)])
fig.update_layout(title_text='Who Orders Food Online More:
Male Vs. Female')
fig.update_traces(hoverinfo='label+percent', textinfo='value',
textfont_size=30,
marker=dict(colors=colors, line=dict(color='black',
width=3)))

fig.show()
```

Who Orders Food Online More: Male Vs. Female



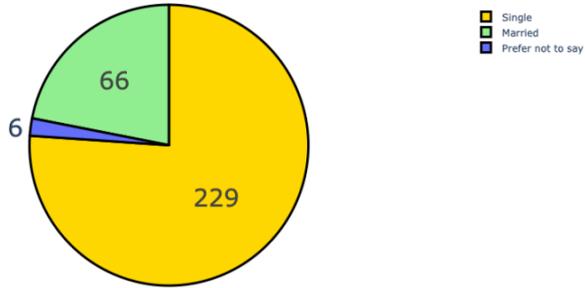
الآن دعونا نلقي نظرة على عمود الجنس. لتتعرف على من يطلب الطعام عبر الإنترنت:

```
marital = buying_again_data["Marital Status"].value_counts()
label = marital.index
counts = marital.values
colors = ['gold', 'lightgreen']

fig = go.Figure(data=[go.Pie(labels=label, values=counts)])
fig.update_layout(title_text='Who Orders Food Online More:
Married Vs. Singles')
fig.update_traces(hoverinfo='label+percent', textinfo='value',
textfont_size=30,
marker=dict(colors=colors, line=dict(color='black',
width=3)))

fig.show()
```

Who Orders Food Online More: Married Vs. Singles

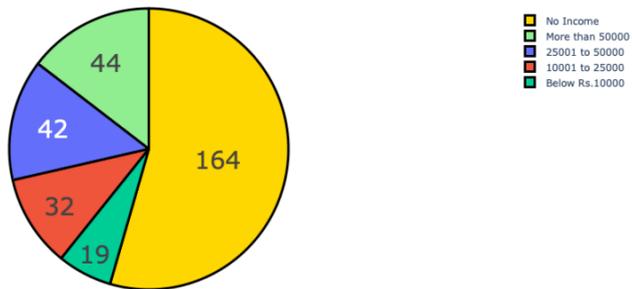


وفقاً للرقم أعلاه، 76.1% من العملاء الدائمين هم من العزاب. دعنا الآن نلقي نظرة على مجموعة دخل العملاء الذين طلبوا الطعام مرة أخرى:

```
income = buying_again_data["Monthly Income"].value_counts()
label = income.index
counts = income.values
colors = ['gold', 'lightgreen']

fig = go.Figure(data=[go.Pie(labels=label, values=counts)])
fig.update_layout(title_text='Which Income Group Orders Food Online More')
fig.update_traces(hoverinfo='label+percent', textinfo='value',
                  textfont_size=30,
                  marker=dict(colors=colors, line=dict(color='black',
                  width=3)))
fig.show()
```

Which Income Group Orders Food Online More



وفقاً للرقم أعلاه، لا يندرج 54% من العملاء تحت أي فئة دخل. يمكن أن يكونوا ربات بيوت أو طلاب.

دعنا الآن نجهز البيانات لمهمة تدريب نموذج التعلم الآلي. سأقوم هنا بتحويل جميع الميزات الفئوية (categorical features) إلى قيم عددية (numerical values):

```

data["Gender"] = data["Gender"].map({"Male": 1, "Female": 0})
data["Marital Status"] = data["Marital
Status"].map({"Married": 2,
"
          Single": 1,
"
          Prefer not to say": 0})
data["Occupation"] = data["Occupation"].map({"Student": 1,
"
          Employee": 2,
"
          Self Employeed": 3,
"
          House wife": 4})
data["Educational Qualifications"] = data["Educational
Qualifications"].map({"Graduate": 1,
"
          Post Graduate": 2,
"
          Ph.D": 3, "School": 4,
"
          Uneducated": 5})
data["Monthly Income"] = data["Monthly Income"].map({"No
Income": 0,
25001"
          to 50000": 5000,
"
          More than 50000": 7000,
10001"
          to 25000": 25000,
"
          Below Rs.10000": 10000})
data["Feedback"] = data["Feedback"].map({"Positive": 1,
"Negative ": 0})
print(data.head())

```

```

  Age  Gender  Marital Status  Occupation  Monthly Income \
0  20      0              1           1           0
1  24      0              1           1      10000
2  22      1              1           1      10000
3  22      0              1           1           0
4  22      1              1           1      10000

  Educational Qualifications  Family size  latitude  longitude  Pin code \
0                          2            4  12.9766   77.5993   560001
1                          1            3  12.9770   77.5773   560009
2                          2            3  12.9551   77.6593   560017
3                          1            6  12.9473   77.5616   560019
4                          2            4  12.9850   77.5533   560010

Output Feedback Unnamed: 12
0  Yes      1      Yes
1  Yes      1      Yes
2  Yes      0      Yes
3  Yes      1      Yes
4  Yes      1      Yes

```

نموذج التنبؤ بطلب الطعام عبر الإنترنت

دعنا الآن ندرّب نموذج التعلم الآلي للتنبؤ بما إذا كان العميل سيطلب مرة أخرى أم لا. سأبدأ بتقسيم البيانات إلى مجموعات تدريب واختبار:

```
#splitting data
from sklearn.model_selection import train_test_split
x = np.array(data[["Age", "Gender", "Marital Status",
"Occupation",
"    Monthly Income", "Educational Qualifications",
"    Family size", "Pin code", "Feedback(]]]
y = np.array(data[["Output"]])
```

دعنا الآن ندرّب نموذج التعلم الآلي:

```
#training a machine learning model
from sklearn.ensemble import RandomForestClassifier
xtrain, xtest, ytrain, ytest = train_test_split(x, y,
        test_size=0.10,
        random_state=42(
model = RandomForestClassifier()
model.fit(xtrain, ytrain)
print(model.score(xtest, ytest))
```

0.9487179487179487

دعنا الآن نجهز نموذجًا لإدخال بيانات العميل ونتوقع ما إذا كان العميل سيطلب الطعام مرة أخرى أم لا:

```
print("Enter Customer Details to Predict If the Customer Will
Order Again")
a = int(input("Enter the Age of the Customer: "))
b = int(input("Enter the Gender of the Customer (1 = Male, 0 =
Female): "))
c = int(input("Marital Status of the Customer (1 = Single, 2 =
Married, 3 = Not Revealed): "))
d = int(input("Occupation of the Customer (Student = 1,
Employee = 2, Self Employed = 3, House wife = 4): "))
e = int(input("Monthly Income: "))
f = int(input("Educational Qualification (Graduate = 1, Post
Graduate = 2, Ph.D = 3, School = 4, Uneducated = 5): "))
g = int(input("Family Size: "))
h = int(input("Pin Code: "))
i = int(input("Review of the Last Order (1 = Positive, 0 =
Negative): "))
features = np.array([[a, b, c, d, e, f, g, h, i]])
print("Finding if the customer will order again: ",
model.predict(features))
```

```
Enter Customer Details to Predict If the Customer Will Order Again
Enter the Age of the Customer: 22
Enter the Gender of the Customer (1 = Male, 0 = Female): 1
Marital Status of the Customer (1 = Single, 2 = Married, 3 = Not Revealed): 1
Occupation of the Customer (Student = 1, Employee = 2, Self Employeed = 3, House wife = 4): 1
Monthly Income: 0
Educational Qualification (Graduate = 1, Post Graduate = 2, Ph.D = 3, School = 4, Uneducated = 5): 1
Family Size: 3
Pin Code: 560010
Review of the Last Order (1 = Positive, 0 = Negative): 1

Finding if the customer will order again: ['Yes']
```

الملخص

هذه هي الطريقة التي يمكنك بها توقع ما إذا كان العميل سيطلب الطعام عبر الإنترنت مرة أخرى أم لا. يعد نظام التنبؤ بطلب الطعام أحد الأساليب المفيدة التي يمكن لشركات توصيل الطعام استخدامها لتسريع عملية التسليم بأكملها. أتمنى أن تكون قد أحببت هذه المقالة حول توقع توصيل الطعام عبر الإنترنت باستخدام التعلم الآلي.

7) نظام توصية Instagram مع تعلم الآلة Recommendation System with Machine Learning

Instagram هو أحد تطبيقات الوسائط الاجتماعية الشائعة اليوم. يستخدم الناس Instagram لمشاركة الصور ومقاطع الفيديو. أحد أسباب شعبية Instagram هو نظام التوصية (recommendation system) الخاص به. يساعد في جذب انتباه المستخدم لفترة أطول. لذلك، إذا كنت تريد معرفة كيفية استخدام التعلم الآلي للتوصية بمنتجات Instagram، فهذه المقالة مناسبة لك. في هذه المقالة، سوف أطلعك على كيفية إنشاء نظام توصية Instagram مع التعلم الآلي باستخدام بايثون.

كيف يعمل نظام توصيات Instagram؟

المنشور الذي تراه كمنشور مقترح على Instagram عندما تتصفح خلاصتك هو المكان الذي يستخدم فيه Instagram نظام توصية للتوصية بالمنشورات التي قد تهتمك.

يستخدم Instagram أيضًا نظام التوصية لاقتراح المزيد من الحسابات لاتباعها، ولكن هنا سأطلعك على كيفية توصية نظام التوصية في Instagram بمزيد من المنشورات.

يوصى بالمنشورات المقترحة التي تراها على Instagram بناءً على أنشطتك على Instagram، مثل:

1. ما نوع الحسابات التي تتابعها، وما نوع المنشورات (posts) التي تتفاعل معها.
2. تلعب التسمية التوضيحية (caption) للمشاركات التي تتفاعل معها دورًا في اقتراح المزيد من المنشورات المشابهة.
3. كيف يتفاعل المستخدمون الآخرون الذين لديهم اهتمامات مماثلة لاهتماماتك في المنشورات.

لذلك كانت هذه هي العوامل الأكثر شيوعًا لاقتراح المزيد من المنشورات على Instagram. في القسم أدناه، سأطلعك على كيفية إنشاء نظام توصية Instagram باستخدام التسميات التوضيحية لمنشورات Instagram.

نظام توصية Instagram باستخدام بايثون

يتم جمع مجموعة البيانات التي أستخدمها لإنشاء نظام توصية Instagram من حساب [Instagram](#) الخاص بي. يمكنك تنزيل مجموعة البيانات من [هنا](#). دعنا الآن نستورد مكتبات بايثون ومجموعة البيانات اللازمة للبدء بهذه المهمة:

```
import pandas as pd
import numpy as np
from sklearn.feature_extraction import text
from sklearn.metrics.pairwise import cosine_similarity

data = pd.read_csv("Instagram data.csv")
print(data.head())
```

	Date	Impressions	From Home	From Hashtags	From Explore	\
0	2021-12-10	3920	2586	1028	619	
1	2021-12-11	5394	2727	1838	1174	
2	2021-12-12	4021	2085	1188	0	
3	2021-12-13	4528	2700	621	932	
4	2021-12-14	2518	1704	255	279	

	From Other	Saves	Comments	Shares	Likes	Profile Visits	Follows	\
0	56	98	9	5	162	35	2	
1	78	194	7	14	224	48	10	
2	533	41	11	1	131	62	12	
3	73	172	10	7	213	23	8	
4	37	96	5	4	123	8	0	

	Conversion Rate	Caption	\
0	5.714286	Here are some of the most important data visua...	
1	20.833333	Here are some of the best data science project...	
2	19.354839	Learn how to train a machine learning model an...	
3	34.782609	Here's how you can write a Python program to d...	
4	0.000000	Plotting annotations while visualizing your da...	

	Hashtags
0	#finance #money #business #investing #investme...
1	#healthcare #health #covid #data #datascience ...
2	#data #datascience #dataanalysis #dataanalytic...
3	#python #pythonprogramming #pythonprojects #py...
4	#datavisualization #datascience #data #dataana...

سأختار فقط عمود التسمية التوضيحية (caption) وعلامات الهاشتاك (hashtags) لبقية المهمة:

```
data = data[["Caption", "Hashtags"]]
print(data.head())
```

```

Caption \
0 Here are some of the most important data visua...
1 Here are some of the best data science project...
2 Learn how to train a machine learning model an...
3 Here's how you can write a Python program to d...
4 Plotting annotations while visualizing your da...

Hashtags
0 #finance #money #business #investing #investme...
1 #healthcare #health #covid #data #datascience ...
2 #data #datascience #dataanalysis #dataanalytic...
3 #python #pythonprogramming #pythonprojects #py...
4 #datavisualization #datascience #data #dataana...

```

سأستخدم هنا تشابه جيب التمام ([cosine similarity](#)) في التعلم الآلي للعثور على أوجه التشابه بين التسميات التوضيحية. بعد العثور على أوجه التشابه بين المنشورات، يمكننا التوصية بها للمستخدم بناءً على أوجه التشابه مع المنشور الذي تفاعل معه المستخدم للتو. فيما يلي كيف يمكننا التوصية بمنشورات Instagram:

```

captions = data["Caption"].tolist()
uni_tfidf = text.TfidfVectorizer(input=captions,
stop_words="english")
uni_matrix = uni_tfidf.fit_transform(captions)
uni_sim = cosine_similarity(uni_matrix)

def recommend_post(x):
    return ", ".join(data["Caption"].loc[x.argsort()[-5:-1]])

data["Recommended Post"] = [recommend_post(x) for x in
uni_sim]
print(data.head())

```

```

Caption \
0 Here are some of the most important data visua...
1 Here are some of the best data science project...
2 Learn how to train a machine learning model an...
3 Here's how you can write a Python program to d...
4 Plotting annotations while visualizing your da...

Hashtags \
0 #finance #money #business #investing #investme...
1 #healthcare #health #covid #data #datascience ...
2 #data #datascience #dataanalysis #dataanalytic...
3 #python #pythonprogramming #pythonprojects #py...
4 #datavisualization #datascience #data #dataana...

Recommended Post
0 Here are some of the most important tools that...
1 Here are some of the best data science project...
2 Data Science Use Cases: Here's how Zomato is u...
3 Here's how to write a Python function to rever...
4 Practice these 90+ Data Science Projects For B...

```

دعنا الآن نلقي نظرة على توصيات منشور Instagram من مجموعة البيانات:

```
print(data["Recommended Post"][3])
```

```
Here's how to write a Python function to reverse a string.,  
To calculate the execution time of the program, we need to calculate the time taken by the program  
from its initiation to the final result. Here's how to calculate the execution time of a Python  
program.,  
Here's how to calculate execution time of a Python program.,  
Grouping anagrams is one of the popular questions in coding interviews. Here you will be given a list  
of words, and you have to write an algorithm to group all the words which are anagrams of each other.  
Here's how to group anagrams using Python.  
[ ]
```

هذه هي الطريقة التي يمكنك بها التوصية بمنشورات Instagram بناءً على تسميات المنشورات.

الملخص

المنشور الذي تراه كمنشور مقترح على Instagram عند التمرير عبر خلاصتك هو المكان الذي يستخدم فيه Instagram نظام التوصية للتوصية بالمنشورات التي قد تهتمك. يساعدني جذب انتباه المستخدم لفترة أطول. أتمنى أن تكون قد أحببت هذه المقالة حول إنشاء نظام توصية Instagram مع التعلم الآلي باستخدام بايثون.

8) التنبؤ بدرجات الطالب مع التعلم الآلي Student Marks Prediction with Machine Learning

التنبؤ بدرجات الطالب (Student marks prediction) هي دراسة حالة علمية شائعة تستند إلى مشكلة الانحدار (regression). إنها مشكلة انحدار جيدة للمبتدئين في علم البيانات (data science) حيث يسهل حلها وفهمها. لذلك إذا كنت تريد معرفة كيفية التنبؤ بعلامات الطالب باستخدام التعلم الآلي (machine learning)، فهذه المقالة مناسبة لك. في هذه المقالة، سوف آخذك خلال مهمة التنبؤ بدرجات الطلاب باستخدام التعلم الآلي باستخدام بايثون.

التنبؤ بدرجات الطالب (دراسة حالة)

يتم إعطاؤك بعض المعلومات حول الطلاب مثل:

1. عدد الكورسات التي اختاروها.

2. متوسط الوقت الذي يدرسه الطلاب يوميًا.

3. الدرجات التي حصل عليها الطلاب.

باستخدام هذه المعلومات، تحتاج إلى التنبؤ بدرجات الطلاب الآخرين. يمكنك تنزيل مجموعة البيانات من [هنا](#).

التنبؤ بدرجات الطالب باستخدام بايثون

يتم تنزيل مجموعة البيانات التي أستخدمها لمهمة توقع علامات الطلاب من Kaggle. لنبدأ الآن بهذه المهمة عن طريق استيراد مكتبات بايثون ومجموعة البيانات الضرورية:

```
import numpy as np
import pandas as pd
import plotly.express as px
from sklearn.model_selection import train_test_split
from sklearn.linear_model import LinearRegression

data = pd.read_csv("Student_Marks.csv")
print(data.head(10))
```

	number_courses	time_study	Marks
0	3	4.508	19.202
1	4	0.096	7.734
2	4	3.133	13.811
3	6	7.909	53.018
4	8	7.811	55.299
5	6	3.211	17.822
6	3	6.063	29.889
7	5	3.413	17.264
8	4	4.410	20.348
9	3	6.173	30.862

لذلك لا يوجد سوى ثلاثة أعمدة في مجموعة البيانات. عمود الدرجات (marks column) هو العمود المستهدف حيث يتعين علينا التنبؤ بدرجات الطالب.

الآن قبل المضي قدماً، دعنا نلقي نظرة على ما إذا كانت مجموعة البيانات هذه تحتوي على أي قيم فارغة أم لا:

```
print(data.isnull().sum())
```

مجموعة البيانات جاهزة للاستخدام نظراً لعدم وجود قيم خالية في البيانات. يوجد عمود في البيانات يحتوي على معلومات حول عدد الكورسات التي اختارها الطلاب. لنلقِ نظرة على عدد قيم جميع قيم هذا العمود:

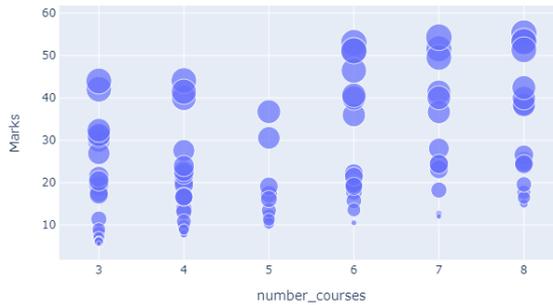
```
data["number_courses"].value_counts()
```

```
3    22
4    21
6    16
8    16
7    15
5    10
Name: number_courses, dtype: int64
```

لذلك هناك ما لا يقل عن ثلاث كورسات كحد أدنى وثمانية كورسات كحد أقصى اختارها الطلاب. دعنا نلقي نظرة على مخطط مبعثر (scatter plot) لمعرفة ما إذا كان عدد الكورسات التدريبية يؤثر على درجات الطالب:

```
figure = px.scatter(data_frame=data, x = "number_courses",
                    y = "Marks", size = "time_study",
                    title="Number of Courses and Marks Scored")
figure.show ()
```

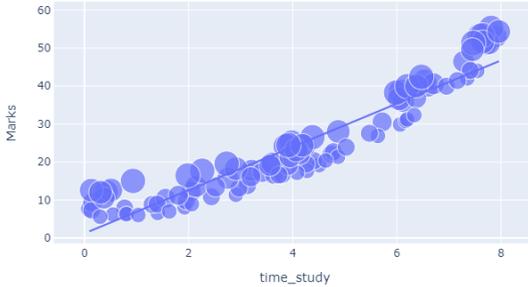
Number of Courses and Marks Scored



وفقاً لتصوير البيانات أعلاه، يمكننا القول إن عدد الكورسات قد لا يؤثر على درجات الطالب إذا كان الطالب يدرس لمزيد من الوقت يومياً. فلنلقِ نظرة على العلاقة بين الوقت الذي يدرس فيه يومياً والدرجات التي سجلها الطالب:

```
figure = px.scatter(data_frame=data, x = "time_study"
                    y = "Marks", size = "number_courses",
                    title="Time Spent and Marks Scored", trendline="ols")
figure.show()
```

Time Spent and Marks Scored



يمكنك أن ترى أن هناك علاقة خطية بين الوقت المدروس (**time studied**) والدرجات التي تم الحصول عليها. هذا يعني أنه كلما زاد الوقت الذي يقضيه الطلاب في الدراسة، كان بإمكانهم تحقيق نتائج أفضل.

دعنا الآن نلقي نظرة على العلاقة بين الدرجات التي سجلها الطلاب والعمودان الآخران في البيانات:

```
correlation = data.corr()
print(correlation["Marks"].sort_values(ascending=False))
```

```
Marks          1.000000
time_study     0.942254
number_courses 0.417335
Name: Marks, dtype: float64
```

لذا فإن العمود **time studied** يكون أكثر ارتباطاً بعمود الدرجات أكثر من العمود الآخر.

نموذج التنبؤ بعلامات الطالب

دعنا الآن ننتقل إلى مهمة تدريب نموذج التعلم الآلي للتنبؤ بدرجات الطالب. هنا، سأبدأ أولاً بتقسيم البيانات إلى مجموعات تدريب واختبار:

```
x = np.array(data[["time_study", "number_courses"]])
y = np.array(data["Marks"])
xtrain, xtest, ytrain, ytest = train_test_split(x, y,
```

```
test_size=0.2,  
random_state=42)
```

الآن سأقوم بتدريب نموذج التعلم الآلي باستخدام خوارزمية الانحدار الخطي (`linear regression`):

```
model = LinearRegression()  
model.fit(xtrain, ytrain)  
model.score(xtest, ytest)
```

```
0.9459936100591212
```

دعنا الآن نختبر أداء نموذج التعلم الآلي هذا من خلال تقديم المدخلات بناءً على الميزات التي استخدمناها لتدريب النموذج والتنبؤ بدرجات الطالب:

```
#Features = [ ["time_study", "number_courses" ] ]  
features = np.array([[3,4.508]])  
model.predict(features)
```

```
array([22.30738483])
```

هذه هي الطريقة التي يمكنك بها التنبؤ بدرجات الطالب الذي لديه التعلم الآلي باستخدام بايثون.

الملخص

هذه هي الطريقة التي يمكنك بها حل مشكلة التنبؤ بدرجات الطلاب باستخدام التعلم الآلي. إنها مشكلة انحدار جيدة للمبتدئين في علم البيانات حيث يسهل حلها وفهمها. أمل أن تكون قد أحببت هذه المقالة حول التنبؤ بدرجات الطلاب باستخدام التعلم الآلي باستخدام بايثون.

9) كشف الاحتيال في المدفوعات عبر الإنترنت باستخدام التعلم الآلي Machine Learning

ساعد إدخال أنظمة الدفع عبر الإنترنت كثيراً في سهولة الدفع. لكن في الوقت نفسه، زادت عمليات الاحتيال في الدفع (payment frauds). يمكن أن تحدث عمليات الاحتيال في الدفع عبر الإنترنت مع أي شخص يستخدم أي نظام دفع، خاصة أثناء إجراء المدفوعات باستخدام بطاقة الائتمان. هذا هو السبب في أن اكتشاف الاحتيال في الدفع عبر الإنترنت مهم جداً لشركات بطاقات الائتمان لضمان عدم تحصيل رسوم من العملاء مقابل المنتجات والخدمات التي لم يدفعوها مطلقاً. إذا كنت تريد معرفة كيفية اكتشاف عمليات الاحتيال في الدفع عبر الإنترنت، فهذه المقالة مناسبة لك. في هذه المقالة، سوف أطلعك على مهمة الكشف عن الاحتيال في المدفوعات عبر الإنترنت باستخدام التعلم الآلي باستخدام بايثون.

كشف الاحتيال في المدفوعات عبر الإنترنت باستخدام التعلم الآلي

لتحديد الاحتيال في الدفع عبر الإنترنت باستخدام التعلم الآلي، نحتاج إلى تدريب نموذج التعلم الآلي لتصنيف المدفوعات الاحتمالية وغير الاحتمالية. لهذا، نحتاج إلى مجموعة بيانات تحتوي على معلومات حول الاحتيال في الدفع عبر الإنترنت، حتى تتمكن من فهم نوع المعاملات التي تؤدي إلى الاحتيال. لهذه المهمة، جمعت [مجموعة بيانات](#) من Kaggle، والتي تحتوي على معلومات تاريخية حول المعاملات الاحتمالية التي يمكن استخدامها للكشف عن الاحتيال في المدفوعات عبر الإنترنت. فيما يلي جميع الأعمدة من مجموعة البيانات التي أستخدمها هنا:

1. step: تمثل وحدة زمنية حيث تساوي الخطوة الواحدة ساعة واحدة.

1. type: نوع المعاملة (transaction) عبر الإنترنت.

2. amount: مبلغ المعاملة.

3. nameOrig: العميل الذي يبدأ المعاملة.

4. oldbalanceOrg: الرصيد قبل المعاملة.

5. newbalanceOrig: الرصيد بعد المعاملة.

6. nameDest: مستلم المعاملة.

7. oldbalanceDest: الرصيد المبدئي للمستلم قبل المعاملة.

8. newbalanceDest: الرصيد الجديد للمستلم بعد المعاملة.

9. isFraud: معاملة احتيالي.

أتمنى أن تعرف الآن البيانات التي أستخدمها في مهمة الكشف عن الاحتيال في الدفع عبر الإنترنت. الآن في القسم أدناه، سأشرح كيف يمكننا استخدام التعلم الآلي للكشف عن الاحتيال في الدفع عبر الإنترنت باستخدام بايثون.

كشف الاحتيال للمدفوعات عبر الإنترنت باستخدام بايثون

سأبدأ هذه المهمة عن طريق استيراد مكتبات بايثون الضرورية ومجموعة البيانات التي نحتاجها لهذه المهمة:

```
import pandas as pd
import numpy as np
data = pd.read_csv("credit card.csv")
print(data.head())
```

	step	type	amount	nameOrig	oldbalanceOrg	newbalanceOrig	\
0	1	PAYMENT	9839.64	C1231006815	170136.0	160296.36	
1	1	PAYMENT	1864.28	C1666544295	21249.0	19384.72	
2	1	TRANSFER	181.00	C1305486145	181.0	0.00	
3	1	CASH_OUT	181.00	C840083671	181.0	0.00	
4	1	PAYMENT	11668.14	C2048537720	41554.0	29885.86	

	nameDest	oldbalanceDest	newbalanceDest	isFraud	isFlaggedFraud
0	M1979787155	0.0	0.0	0	0
1	M2044282225	0.0	0.0	0	0
2	C553264065	0.0	0.0	1	0
3	C38997010	21182.0	0.0	1	0
4	M1230701703	0.0	0.0	0	0

الآن، دعنا نلقي نظرة على ما إذا كانت مجموعة البيانات هذه تحتوي على أي قيم فارغة أم لا:

```
print(data.isnull().sum())
```

```
step          0
type          0
amount        0
nameOrig      0
oldbalanceOrg 0
newbalanceOrig 0
nameDest      0
oldbalanceDest 0
newbalanceDest 0
isFraud       0
isFlaggedFraud 0
dtype: int64
```

لذلك لا تحتوي مجموعة البيانات هذه على أي قيم فارغة. قبل المضي قدماً، دعنا الآن نلقي نظرة على نوع المعاملة المذكورة في مجموعة البيانات:

```
#Exploring transaction type
print(data.type.value_counts())
```

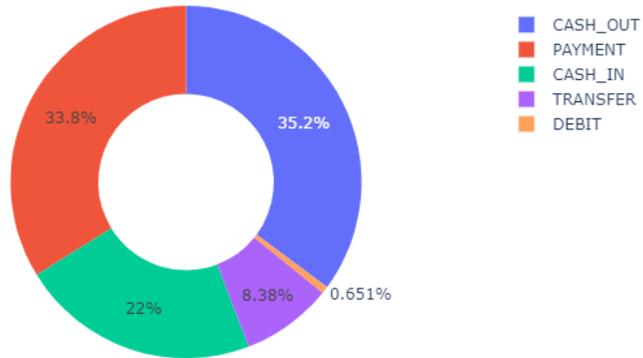
```
CASH_OUT    2237500
PAYMENT     2151495
CASH_IN     1399284
TRANSFER    532909
DEBIT        41432
Name: type, dtype: int64
```

```
type = data["type"].value_counts()
transactions = type.index
quantity = type.values

import plotly.express as px
figure = px.pie(data,
                values=quantity,
                names=transactions, hole = 0.5,

                title="Distribution of Transaction Type")
figure.show()
```

Distribution of Transaction Type



دعنا الآن ننظر على العلاقة بين ميزات البيانات مع عمود isFraud:

```
#Checking correlation
correlation = data.corr()
```

```
print (correlation["isFraud"].sort_values(ascending=False))
```

```
isFraud      1.000000
amount       0.076688
isFlaggedFraud 0.044109
step         0.031578
oldbalanceOrg 0.010154
newbalanceDest 0.000535
oldbalanceDest -0.005885
newbalanceOrig -0.008148
Name: isFraud, dtype: float64
```

دعنا الآن نحول السمات الفئوية (categorical) إلى عددية (numerical). سأقوم هنا أيضاً بتحويل قيم عمود isFraud إلى تسميات No Fraud و Fraud للحصول على فهم أفضل للمخرجات:

```
data["type"] = data["type"].map({"CASH_OUT": 1, "PAYMENT": 2,
                                "CASH_IN": 3, "TRANSFER": 4,
                                "DEBIT": 5})
data["isFraud"] = data["isFraud"].map({0: "No Fraud", 1:
                                        "Fraud"})
print(data.head())
```

step	type	amount	nameOrig	oldbalanceOrg	newbalanceOrig	\
0	1	2	9839.64	C1231006815	170136.0	160296.36
1	1	2	1864.28	C1666544295	21249.0	19384.72
2	1	4	181.00	C1305486145	181.0	0.00
3	1	1	181.00	C840083671	181.0	0.00
4	1	2	11668.14	C2048537720	41554.0	29885.86

	nameDest	oldbalanceDest	newbalanceDest	isFraud	isFlaggedFraud
0	M1979787155	0.0	0.0	No Fraud	0
1	M2044282225	0.0	0.0	No Fraud	0
2	C553264065	0.0	0.0	Fraud	0
3	C38997010	21182.0	0.0	Fraud	0
4	M1230701703	0.0	0.0	No Fraud	0

نموذج كشف الاحتيال للمدفوعات عبر الإنترنت

دعنا الآن ندرّب نموذج تصنيف لتصنيف المعاملات الاحتمالية وغير الاحتمالية. قبل تدريب النموذج، سأقسم البيانات إلى مجموعات تدريب واختبار:

```
#splitting the data
from sklearn.model_selection import train_test_split
x = np.array(data[["type", "amount", "oldbalanceOrg",
                  "newbalanceOrig"]])
y = np.array(data[["isFraud"]])
```

الآن دعنا ندرّب على نموذج الكشف عن الاحتيال في المدفوعات عبر الإنترنت:

```
#training a machine learning model
from sklearn.tree import DecisionTreeClassifier
```

```
xtrain, xtest, ytrain, ytest = train_test_split(x, y,
test_size=0.10, random_state=42)
model = DecisionTreeClassifier()
model.fit(xtrain, ytrain)
print(model.score(xtest, ytest))
```

```
0.9997391011878755
```

دعنا الآن نصنف ما إذا كانت المعاملة عبارة عن عملية احتيال أم لا من خلال تقديم معلومات حول معاملة في النموذج:

```
#prediction
#features = [type, amount, oldbalanceOrg, newbalanceOrig]
features = np.array([[0.0,9000.60,9000.60,4]])
print(model.predict(features))
```

```
['Fraud']
```

الملخص

هذه هي الطريقة التي يمكننا بها اكتشاف الاحتيال في المدفوعات عبر الإنترنت باستخدام التعلم الآلي باستخدام بايثون. يعد الكشف عن عمليات الاحتيال في الدفع عبر الإنترنت أحد تطبيقات علم البيانات في مجال التمويل. أمل أن تكون قد أحببت هذه المقالة حول اكتشاف الاحتيال في المدفوعات عبر الإنترنت باستخدام التعلم الآلي باستخدام بايثون.

10) التنبؤ باكرامية النادل مع التعلم الآلي Waiver Tips Prediction with Machine Learning

يعتمد تقديم اكرامية للنادل (Tipping waiter) لتقديم الطعام على العديد من العوامل مثل نوع المطعم وعدد الأشخاص الذين تتعامل معهم والمبلغ الذي تدفعه كفاتورتك وما إلى ذلك. يُعد تحليل اكرامية النادل أحد دراسات الحالة الشائعة في علم البيانات حيث نحتاج إلى التنبؤ بالاكرامية التي تُعطى للنادل لتقديم الطعام في المطعم. لذلك إذا كنت تريد معرفة كيفية حل دراسة الحالة هذه، فهذه المقالة مناسبة لك. في هذه المقالة، سوف آخذك خلال مهمة التنبؤ باكرامية النادل مع التعلم الآلي باستخدام بايثون.

اكرامية النادل (دراسة حالة)

سجل خادم الطعام في مطعم بيانات حول الاكراميات المعطاة للنادل لتقديم الطعام. البيانات التي سجلها خادم الطعام هي كما يلي:

1. `total_bill`: إجمالي الفاتورة بالدولار بما في ذلك الضرائب.
2. `tip`: اكرامية تُعطى للنادل بالدولار.
3. `sex`: جنس الشخص الذي يدفع الفاتورة.
4. `smoker`: سواء كان الشخص مدخنًا أم لا.
5. `day`: يوم الأسبوع.
6. `time`: غداء أو عشاء.
7. `size`: عدد الأشخاص على الطاولة.

إذن هذه هي البيانات التي سجلها المطعم. بناءً على هذه البيانات، تتمثل مهمتنا في العثور على العوامل التي تؤثر على اكرامية النادل وتدريب نموذج تعلم الآلة للتنبؤ باكرامية النادل.

التنبؤ باكرامية النادل باستخدام بايثون

لنبدأ الآن مهمة تحليل والتنبؤ باكرامية النادل عن طريق استيراد مكتبات بايثون ومجموعة البيانات الضرورية:

```
import pandas as pd
import numpy as np
import plotly.express as px
import plotly.graph_objects as go
data = pd.read_csv("tips.csv")
```

```
print(data.head())
```

	total_bill	tip	sex	smoker	day	time	size
0	16.99	1.01	Female	No	Sun	Dinner	2
1	10.34	1.66	Male	No	Sun	Dinner	3
2	21.01	3.50	Male	No	Sun	Dinner	3
3	23.68	3.31	Male	No	Sun	Dinner	2
4	24.59	3.61	Female	No	Sun	Dinner	4

فيما يلي الوصف الكامل لمجموعة البيانات هذه:

1. **total_bill**: إجمالي الفاتورة بالدولار بما في ذلك الضريبة.

2. **tip**: اكرامية تُعطى للنادل بالدولار.

3. **sex**: جنس الشخص الذي يدفع الفاتورة.

4. **smoker**: سواء كان الشخص مدخنًا أم لا.

5. **day**: يوم الأسبوع.

6. **time**: غداء أو عشاء.

7. **size**: عدد الأشخاص.

دعنا الآن ننتقل إلى الأمام من خلال تحليل جميع العوامل التي تؤثر على اكرامية النادل.

تحليل اكرامية النادل

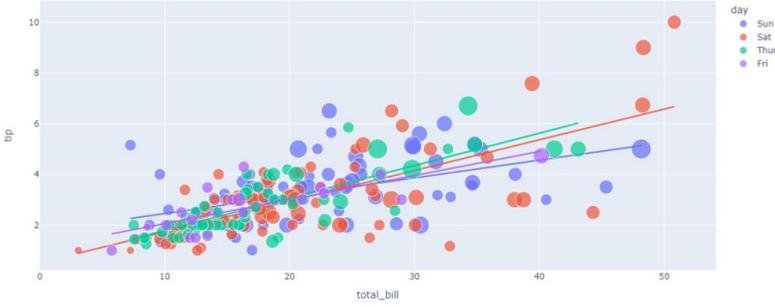
دعونا نلقي نظرة على اكرامية المقدمة للنادل وفقًا لما يلي:

1. إجمالي الفاتورة المدفوعة.

2. عدد الأشخاص على الطاولة.

3. ويوم الأسبوع.

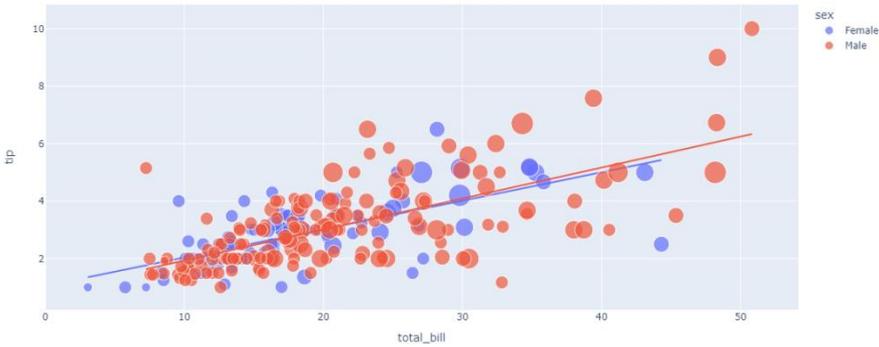
```
figure = px.scatter(data_frame = data, x="total_bill",
                    y="tip", size="size", color="day", trendline="ols")
figure.show()
```



الآن دعنا نلقي نظرة على الاكرامية المعطاة للنادل وفقاً لما يلي:

1. إجمالي الفاتورة المدفوعة.
2. عدد الأشخاص على الطاولة.
3. وجنس الشخص الذي يدفع الفاتورة.

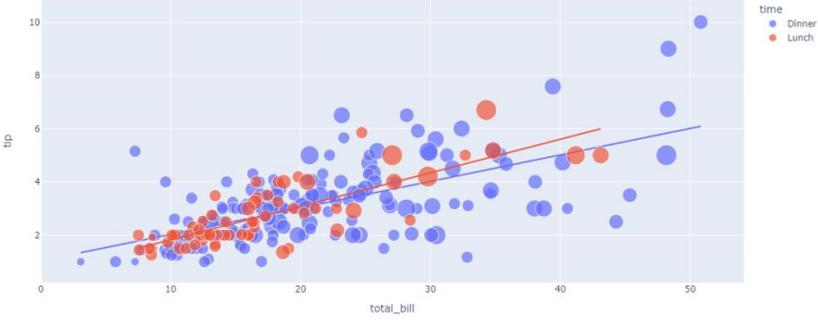
```
figure = px.scatter(data_frame = data, x="total_bill",
                    y="tip", size="size", color= "sex", trendline="ols")
figure.show()
```



الآن دعنا نلقي نظرة على الاكرامية المعطاة للنادل وفقاً لما يلي:

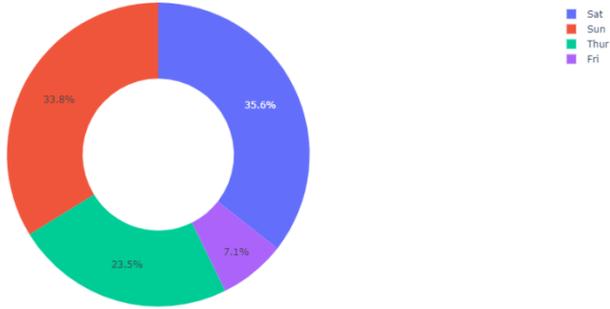
1. إجمالي الفاتورة المدفوعة.
2. عدد الأشخاص على الطاولة.
3. ووقت الوجبة.

```
figure = px.scatter(data_frame = data, x="total_bill",
                    y="tip", size="size", color= "time", trendline="ols")
figure.show()
```



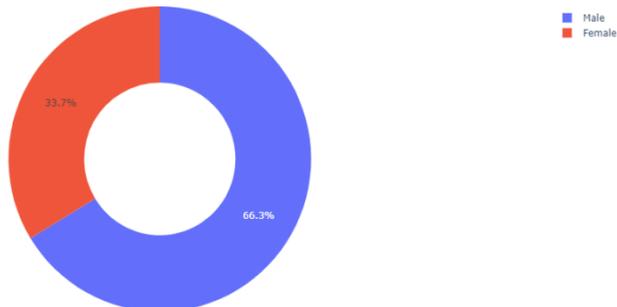
دعنا الآن نرى الاكرامية المقدمة للنادل وفقاً للأيام لمعرفة اليوم الذي يتم فيه تقديم معظم الاكراميات للنادل:

```
figure = px.pie(data,
  values='tip',
  names='day',hole = 0.5)
figure.show()
```



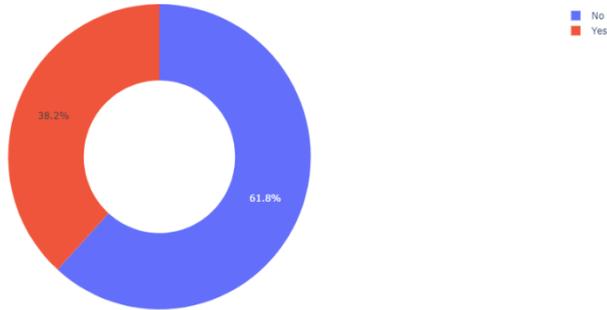
وفقاً للرسم أعلاه، يتم تقديم معظم الاكراميات في أيام السبت إلى النادلين. لنلقِ الآن نظرة على عدد الاكراميات التي تُعطى للنادل حسب جنس الشخص الذي يدفع الفاتورة لمعرفة من الذي يعطي النادلين أكثر من غيرهم:

```
figure = px.pie(data,
  values='tip',
  names='sex',hole = 0.5)
figure.show()
```



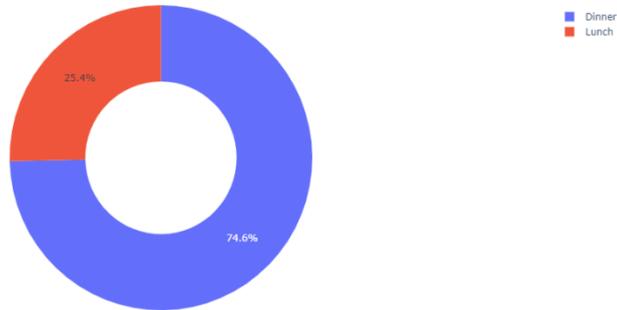
وفقاً للتصوير أعلاه، يتم تقديم معظم الاكراميات من قبل الرجال. دعنا الآن نرى ما إذا كان المدخن يقدم اكراميات أكثر أم أنه غير مدخن:

```
figure = px.pie(data,
                 values='tip',
                 names='smoker',hole = 0.5)
figure.show()
```



وفقاً للتصوير أعلاه، فإن اكراميات غير المدخنين هي أكثر من المدخنين. دعنا الآن نرى ما إذا كان يتم تقديم معظم الاكراميات أثناء الغداء أو العشاء:

```
figure = px.pie(data,
                 values='tip',
                 names='time',hole = 0.5)
figure.show()
```



وفقاً للتصوير أعلاه، يعطى اكرامية للنادل أكثر أثناء العشاء.

هذه هي الطريقة التي يمكننا بها تحليل جميع العوامل التي تؤثر على اكرامية النادل. الآن في القسم أدناه، سوف أخذك في جولة حول كيفية تدريب نموذج التعلم الآلي لمهمة التنبؤ باكرامية النادل.

نموذج التنبؤ بإكرامية النادل

قبل تدريب نموذج التنبؤ بإكرامية النادل، سأقوم ببعض تحويل البيانات عن طريق تحويل القيم الفئوية (categorical) إلى قيم عددية (numerical):

```
data["sex"] = data["sex"].map({"Female": 0, "Male": 1})
data["smoker"] = data["smoker"].map({"No": 0, "Yes": 1})
data["day"] = data["day"].map({"Thur": 0, "Fri": 1, "Sat": 2,
"Sun": 3})
data["time"] = data["time"].map({"Lunch": 0, "Dinner": 1})
data.head()
```

	total_bill	tip	sex	smoker	day	time	size
0	16.99	1.01	0	0	3	1	2
1	10.34	1.66	1	0	3	1	3
2	21.01	3.50	1	0	3	1	3
3	23.68	3.31	1	0	3	1	2
4	24.59	3.61	0	0	3	1	4

الآن سأقسم البيانات إلى مجموعات تدريب واختبار:

```
x = np.array(data[["total_bill", "sex", "smoker", "day",
"time", "size"]])
y = np.array(data["tip"])

from sklearn.model_selection import train_test_split
xtrain, xtest, ytrain, ytest = train_test_split(x, y ,
test_size=0.2 , random_state=42)
```

الآن فيما يلي كيفية تدريب نموذج التعلم الآلي لمهمة التنبؤ بإكرامية النادل باستخدام بايثون:

```
from sklearn.linear_model import LinearRegression
model = LinearRegression()
model.fit(xtrain, ytrain)
```

دعنا الآن نختبر أداء هذا النموذج من خلال إعطاء مدخلات لهذا النموذج وفقاً للميزات التي استخدمناها لتدريب هذا النموذج:

```
#features = [[total_bill, "sex", "smoker", "day", "time",
"size"]]
features = np.array([[4,1,0,0,1,24.50]])
model.predict(features)
```

```
array([3.73742609])
```

الملخص

هذه هي الطريقة التي يمكنك بها توقع اكرامية النادل باستخدام التعلم الآلي باستخدام بايثون . يعد تحليل اكرامية النادل أحد دراسات الحالة الشائعة في مجال علوم البيانات حيث نحتاج إلى التنبؤ بالإكرامية التي يتم تقديمها للنادل لتقديم الطعام في مطعم. أمل أن تكون قد أحببت هذه المقالة حول التنبؤ بإكرامية النادل مع التعلم الآلي باستخدام بايثون.

11] تجميع أنواع الموسيقى باستخدام التعلم الآلي Clustering Music Genres with Machine Learning

التجميع (Clustering) هو أسلوب تعلم آلي لتجميع نقاط البيانات التي تتميز بميزات محددة. تجميع أنواع الموسيقى هو مهمة تجميع الموسيقى بناءً على أوجه التشابه في خصائصها الصوتية. إذا كنت تريد معرفة كيفية إجراء تحليل المجموعات على أنواع الموسيقى، فهذه المقالة مناسبة لك. في هذه المقالة، سوف آخذك خلال مهمة تجميع أنواع الموسيقى مع التعلم الآلي باستخدام بايثون.

تجميع أنواع الموسيقى (بيان المشكلة)

لكل شخص ذوق مختلف في الموسيقى. لا يمكننا تحديد نوع الموسيقى التي يحبها الشخص بمجرد معرفة أسلوب حياته أو هواياته أو مهنته. لذلك يصعب على تطبيقات دفع الموسيقى التوصية بالموسيقى لشخص ما. ولكن إذا عرفنا نوع الأغاني التي يستمع إليها الشخص يوميًا، فيمكننا إيجاد أوجه تشابه في جميع ملفات الموسيقى والتوصية بموسيقى مماثلة للشخص.

هذا هو المكان الذي يأتي فيه التحليل العنقودي (cluster analysis) لأنواع الموسيقى. هنا تحصل على مجموعة بيانات من الأغاني الشعبية على Spotify، والتي تحتوي على أسماء الفنانين والموسيقى مع جميع الخصائص الصوتية لكل موسيقى. هدفك هو تجميع أنواع الموسيقى بناءً على أوجه التشابه في خصائصها الصوتية.

يمكنك تنزيل مجموعة البيانات من [هنا](#).

تجميع أنواع الموسيقى باستخدام لغة بايثون

أمل أن تكون قد فهمت بيان المشكلة المذكور أعلاه حول تجميع أنواع الموسيقى مع التعلم الآلي. لنبدأ الآن بهذه المهمة عن طريق استيراد مكتبات بايثون ومجموعة البيانات الضرورية:

```
import pandas as pd
import numpy as np
from sklearn import cluster

data = pd.read_csv("Spotify-2000.csv")
print(data.head())
```

	Index	Title	Artist	Top Genre	\
0	1	Sunrise	Norah Jones	adult standards	
1	2	Black Night	Deep Purple	album rock	
2	3	Clint Eastwood	Gorillaz	alternative hip hop	
3	4	The Pretender	Foo Fighters	alternative metal	
4	5	Waitin' On A Sunny Day	Bruce Springsteen	classic rock	

	Year	Beats Per Minute (BPM)	Energy	Danceability	Loudness (dB)	\
0	2004	157	30	53	-14	
1	2000	135	79	50	-11	
2	2001	168	69	66	-9	
3	2007	173	96	43	-4	
4	2002	106	82	58	-5	

	Liveness	Valence	Length (Duration)	Acousticness	Speechiness	Popularity
0	11	68	201	94	3	71
1	17	81	207	17	7	39
2	7	52	341	2	17	69
3	3	37	269	0	4	76
4	10	87	256	1	3	59

يمكنك رؤية جميع أعمدة مجموعة البيانات في الإخراج أعلاه. يحتوي على جميع الميزات الصوتية للموسيقى التي تكفي للعثور على أوجه التشابه. قبل المضي قدماً، سأقوم بإسقاط عمود الفهرس (`index column`)، لأنه لا فائدة منه:

```
data = data.drop("Index", axis=1)
```

دعنا الآن ننظر على الارتباط (`correlation`) بين جميع ميزات الصوت في مجموعة البيانات:

```
print(data.corr())
```

	Year	Beats Per Minute (BPM)	Energy	\
Year	1.000000		0.012570	0.147235
Beats Per Minute (BPM)	0.012570	1.000000	0.156644	
Energy	0.147235	0.156644	1.000000	
Danceability	0.077493	-0.140602	0.139616	
Loudness (dB)	0.343764	0.092927	0.735711	
Liveness	0.019017	0.016256	0.174118	
Valence	-0.166163	0.059653	0.405175	
Acousticness	-0.132946	-0.122472	-0.665156	
Speechiness	0.054097	0.085598	0.205865	
Popularity	-0.158962	-0.003181	0.103393	

	Danceability	Loudness (dB)	Liveness	Valence	\
Year	0.077493	0.343764	0.019017	-0.166163	
Beats Per Minute (BPM)	-0.140602	0.092927	0.016256	0.059653	
Energy	0.139616	0.735711	0.174118	0.405175	
Danceability	1.000000	0.044235	-0.103063	0.514564	
Loudness (dB)	0.044235	1.000000	0.098257	0.147041	
Liveness	-0.103063	0.098257	1.000000	0.050667	
Valence	0.514564	0.147041	0.050667	1.000000	
Acousticness	-0.135769	-0.451635	-0.046206	-0.239729	
Speechiness	0.125229	0.125090	0.092594	0.107102	
Popularity	0.144344	0.165527	-0.111978	0.095911	

	Acousticness	Speechiness	Popularity
Year	-0.132946	0.054097	-0.158962
Beats Per Minute (BPM)	-0.122472	0.085598	-0.003181
Energy	-0.665156	0.205865	0.103393
Danceability	-0.135769	0.125229	0.144344
Loudness (dB)	-0.451635	0.125090	0.165527
Liveness	-0.046206	0.092594	-0.111978
Valence	-0.239729	0.107102	0.095911
Acousticness	1.000000	-0.098256	-0.087604
Speechiness	-0.098256	1.000000	0.111689
Popularity	-0.087604	0.111689	1.000000

التحليل العنقودي للميزات الصوتية

سأستخدم الآن خوارزمية التجميع **K-mean** للعثور على أوجه التشابه بين جميع ميزات الصوت. ثم سأضيف مجموعات في مجموعة البيانات بناءً على أوجه التشابه التي وجدناها. لذلك دعونا ننشئ مجموعة بيانات جديدة لجميع خصائص الصوت ونجري تحليل المجموعات باستخدام خوارزمية **K-mean clustering**:

```
data2 = data[["Beats Per Minute (BPM)", "Loudness (dB)",
             "Liveness", "Valence", "Acousticness",
             "Speechiness"]]

from sklearn.preprocessing import MinMaxScaler
for i in data.columns:
    MinMaxScaler(i)

from sklearn.cluster import KMeans
kmeans = KMeans(n_clusters=10)
clusters = kmeans.fit_predict(data2)
```

سأضيف الآن المجموعات كما تنبأت خوارزمية التجميع **K-mean** إلى مجموعة البيانات الأصلية:

```
data["Music Segments"] = clusters
MinMaxScaler(data["Music Segments"])
data["Music Segments"] = data["Music Segments"].map({1:
"Cluster 1", 2:
" Cluster 2", 3: "Cluster 3", 4: "Cluster 4", 5: "Cluster 5",
":6 Cluster 6", 7: "Cluster 7", 8: "Cluster 8",
":9 Cluster 9", 10: "Cluster 10"})
```

دعنا الآن نلقي نظرة على مجموعة البيانات ذات المجموعات (**clusters**):

```
print(data.head())
```

	Title	Artist	Top Genre	Year	\
0	Sunrise	Norah Jones	adult standards	2004	
1	Black Night	Deep Purple	album rock	2000	
2	Clint Eastwood	Gorillaz	alternative hip hop	2001	
3	The Pretender	Foo Fighters	alternative metal	2007	
4	Waitin' On A Sunny Day	Bruce Springsteen	classic rock	2002	

	Beats Per Minute (BPM)	Energy	Danceability	Loudness (dB)	Liveness	\
0	157	30	53	-14	11	
1	135	79	50	-11	17	
2	168	69	66	-9	7	
3	173	96	43	-4	3	
4	106	82	58	-5	10	

	Valence	Length (Duration)	Acousticness	Speechiness	Popularity	\
0	68	201	94	3	71	
1	81	207	17	7	39	
2	52	341	2	17	69	
3	37	269	0	4	76	
4	87	256	1	3	59	

	Music Segments
0	Cluster 1
1	Cluster 6
2	Cluster 2
3	Cluster 2
4	Cluster 3

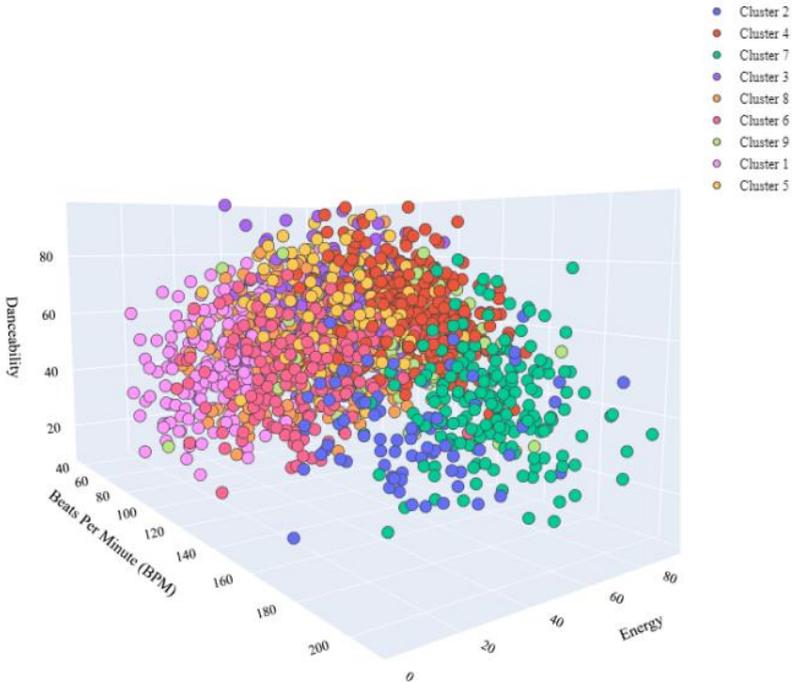
الآن دعنا نتخيل المجموعات بناءً على بعض ميزات الصوت :

```
import plotly.graph_objects as go
PLOT = go.Figure()
for i in list(data["Music Segments"].unique()):

    PLOT.add_trace(go.Scatter3d(x = data[data["Music Segments"]==
i]['Beats Per Minute (BPM)'],(
        y = data[data["Music Segments"] == i]['Energy'],
        z = data[data["Music Segments"] ==
i]['Danceability']
        ,
        mode = 'markers',marker_size = 6,
marker_line_width = 1,
        name = str(i)))
PLOT.update_traces(hovertemplate='Beats Per Minute (BPM): %{x}
<br>Energy: %{y} <br>Danceability: %{z}')

PLOT.update_layout(width = 800, height = 800, autosize = True,
showlegend = True,
        scene = dict(xaxis=dict(title = 'Beats Per Minute
(BPM)', titlefont_color = 'black'),
        yaxis=dict(title = 'Energy', titlefont_color =
'black'),
```

```
zaxis=dict(title = 'Danceability',
titlefont_color = 'black'),(
font = dict(family = "Gilroy", color = 'black', size =
12))
```



هذه هي الطريقة التي يمكننا بها إجراء التحليل العنقودي لأنواع الموسيقى باستخدام التعلم الآلي.

الملخص

هذه هي الطريقة التي يمكنك بها إجراء التحليل العنقودي لأنواع الموسيقى باستخدام التعلم الآلي باستخدام بايثون. تجميع أنواع الموسيقى هو مهمة تجميع الموسيقى بناءً على أوجه التشابه في ميزات الصوت الخاصة بها. أمل أن تكون قد أحببت هذه المقالة حول تجميع أنواع الموسيقى مع التعلم الآلي.

12) التنبؤ بأسعار العملات المشفرة باستخدام التعلم الآلي Cryptocurrency Price Prediction with Machine Learning

يجب أن تكون قد سمعت أو استثمرت في أي عملة مشفرة مرة (cryptocurrency) واحدة في حياتك. إنها وسيلة تبادل رقمية مشفرة وغير مركزية. كثير من الناس يستخدمون العملات المشفرة كشكل من أشكال الاستثمار لأنها تعطي عوائد كبيرة حتى في فترة قصيرة. تعد Bitcoin وEthereum وBinance Coin من بين العملات المشفرة الشائعة اليوم. إذا كنت تريد معرفة كيفية التنبؤ بالأسعار المستقبلية لأي عملة مشفرة باستخدام التعلم الآلي، فهذه المقالة مناسبة لك. في هذه المقالة، سوف أطلعك على مهمة التنبؤ بأسعار العملات المشفرة (cryptocurrency price prediction) مع التعلم الآلي باستخدام بايثون.

التنبؤ بأسعار العملات المشفرة باستخدام التعلم الآلي

يعد التنبؤ بسعر العملات المشفرة أحد دراسات الحالة الشائعة في مجتمع علوم البيانات. لا تعتمد أسعار الأسهم والعملات المشفرة فقط على عدد الأشخاص الذين يشترونها أو يبيعونها. اليوم، يعتمد التغيير في أسعار هذه الاستثمارات أيضاً على التغييرات في السياسات المالية للحكومة فيما يتعلق بأي عملة مشفرة. إن مشاعر الناس تجاه عملة مشفرة معينة أو شخصية معينة تصادق بشكل مباشر أو غير مباشر على عملة مشفرة تؤدي أيضاً إلى عمليات شراء وبيع ضخمة لعملة مشفرة معينة، مما يؤدي إلى حدوث تغيير في الأسعار.

باختصار، يؤدي الشراء والبيع إلى تغيير سعر أي عملة مشفرة، لكن اتجاهات البيع والشراء تعتمد على العديد من العوامل. لا يمكن استخدام التعلم الآلي للتنبؤ بأسعار العملات المشفرة إلا في المواقف التي تتغير فيها الأسعار بسبب الأسعار التاريخية التي يراها الناس قبل شراء وبيع عملاتهم المشفرة. لذلك، في القسم أدناه، سأطلعك على كيفية توقع أسعار البيتكوين (وهي واحدة من أكثر العملات المشفرة شيوعاً) خلال الثلاثين يوماً القادمة.

التنبؤ بأسعار العملات المشفرة باستخدام بايثون

سأبدأ مهمة التنبؤ بأسعار العملات المشفرة عن طريق استيراد مكتبات بايثون الضرورية ومجموعة البيانات التي نحتاجها. لهذه المهمة، سأجمع أحدث بيانات أسعار البيتكوين من Yahoo Finance، باستخدام API yfinance. سيساعدك هذا في جمع أحدث البيانات في كل مرة تقوم فيها بتشغيل هذا الكود:

```
import pandas as pd
import yfinance as yf
```

```
import datetime
from datetime import date, timedelta
today = date.today()

d1 = today.strftime("%Y-%m-%d")
end_date = d1
d2 = date.today() - timedelta(days=730)
d2 = d2.strftime("%Y-%m-%d")
start_date = d2

data = yf.download('BTC-USD',
                  start=start_date,
                  end=end_date,
                  progress=False)
data["Date"] = data.index
data = data[["Date", "Open", "High", "Low", "Close", "Adj
Close", "Volume"]]
data.reset_index(drop=True, inplace=True)
print(data.head())
```

	Date	Open	High	...	Close	Adj Close	Volume
0	2019-12-28	7289.031250	7399.041016	...	7317.990234	7317.990234	21365673026
1	2019-12-29	7317.647461	7513.948242	...	7422.652832	7422.652832	22445257702
2	2019-12-30	7420.272949	7454.824219	...	7292.995117	7292.995117	22874131672
3	2019-12-31	7294.438965	7335.290039	...	7193.599121	7193.599121	21167946112
4	2020-01-01	7194.892090	7254.330566	...	7200.174316	7200.174316	18565664997

[5 rows x 7 columns]

في الكود أعلاه، قمت بجمع أحدث بيانات أسعار البيتكوين على مدار الـ 730 يوماً الماضية، ثم أعدتها لأي مهمة تتعلق بعلم البيانات. الآن، دعنا نلقي نظرة على شكل مجموعة البيانات هذه لمعرفة ما إذا كنا نعمل مع 730 صفًا أم لا:

```
data.shape
```

```
(731, 7)
```

لذلك تحتوي مجموعة البيانات على 731 صفًا، حيث يحتوي الصف الأول على أسماء كل عمود. الآن دعنا نتخيل التغيير في أسعار البيتكوين حتى اليوم باستخدام مخطط الشموع (candlestick chart):

```
import plotly.graph_objects as go
figure = go.Figure(data=[go.Candlestick(x=data["Date", ["
open=data["Open"] ,
high=data["High"],
low=data["Low"] ,
close=data["Close"] ])]
figure.update_layout(title = "Bitcoin Price Analysis , "
xaxis_rangeslider_visible=False (
figure.show()
```

Bitcoin Price Analysis



يحتوي عمود الإغلاق (**Close column**) في مجموعة البيانات على القيم التي نحتاج إلى توقعها. لذلك، دعنا نلقي نظرة على ارتباط جميع الأعمدة في البيانات المتعلقة بعمود الإغلاق:

```
correlation = data.corr()
print (correlation["Close"].sort_values(ascending=False))
```

```
Adj Close    1.000000
Close        1.000000
High         0.998933
Low          0.998740
Open         0.997557
Volume       0.334698
Name: Close, dtype: float64
```

نموذج التنبؤ بأسعار العملات المشفرة

يعتمد توقع الأسعار المستقبلية للعملات المشفرة على مشكلة تحليل السلاسل الزمنية (**Time series analysis**). تعد مكتبة **AutoTS** في بايثون واحدة من أفضل المكتبات لتحليل السلاسل الزمنية. لذلك سأستخدم هنا مكتبة **AutoTS** للتنبؤ بأسعار البيتكوين للأيام الثلاثين القادمة:

```
from autots import AutoTS
model = AutoTS(forecast_length=30, frequency='infer',
ensemble='simple')
model = model.fit(data, date_col='Date', value_col='Close',
id_col=None)
prediction = model.predict()
forecast = prediction.forecast
print (forecast)
```

```
Close
2021-12-28 57865.012345
2021-12-29 54259.592685
2021-12-30 53794.634938
2021-12-31 54365.964301
2022-01-01 55371.531945
2022-01-02 57220.503886
2022-01-03 57132.487546
```

2022-01-05	58376.081818
2022-01-06	59931.323291
2022-01-07	60168.816716
2022-01-08	60617.974204
2022-01-09	58785.722512
2022-01-10	55180.302852
2022-01-11	54715.345105
2022-01-12	55286.674468
2022-01-13	56292.242112
2022-01-14	58141.214053
2022-01-15	58053.197713
2022-01-16	58942.437232
2022-01-17	59296.791985
2022-01-18	60852.033458
2022-01-19	61089.526883
2022-01-20	61538.684371
2022-01-21	59706.432679
2022-01-22	56101.013019
2022-01-23	55636.055272
2022-01-24	56207.384635
2022-01-25	57212.952279
2022-01-26	59061.924220

هذه هي الطريقة التي يمكنك بها استخدام التعلم الآلي للتنبؤ بسعر أي عملة مشفرة باستخدام لغة برمجة بايثون.

الملخص

ينتج عن الشراء والبيع تغيير في سعر أي عملة مشفرة، لكن اتجاهات البيع والشراء تعتمد على العديد من العوامل. لا يمكن استخدام التعلم الآلي للتنبؤ بأسعار العملات المشفرة إلا في المواقف التي تتغير فيها الأسعار بسبب الأسعار التاريخية التي يراها الناس قبل شراء وبيع عملاتهم المشفرة. أمل أن تكون قد أحببت هذه المقالة حول التنبؤ بأسعار العملات المشفرة باستخدام التعلم الآلي باستخدام بايثون.

13) التنبؤ بسعر السهم باستخدام التعلم الآلي Stock Price Prediction using Machine Learning

يعد التنبؤ بسوق الأوراق المالية (stock market prediction) أحد أهم تطبيقات التعلم الآلي في مجال التمويل. في هذه المقالة، سوف نخوض في مشروع بسيط لعلم البيانات حول التنبؤ بأسعار الأسهم باستخدام لغة بايثون للتعلم الآلي.

في نهاية هذه المقالة، سنتعلم كيفية التنبؤ بأسعار الأسهم باستخدام نموذج الانحدار الخطي (Linear Regression model) من خلال تطبيق لغة برمجة بايثون.

التنبؤ بسعر السهم

لقد كان توقع سوق الأوراق المالية لعنة وهدف المستثمرين منذ نشأته. يتم تداول مليارات الدولارات يوميًا في البورصة، وخلف كل دولار يوجد مستثمر يأمل في تحقيق ربح بطريقة أو بأخرى.

الشركات بأكملها ترتفع وتنخفض يوميًا اعتمادًا على سلوك السوق. إذا كان المستثمر قادرًا على التنبؤ بدقة بحركات السوق، فإنه يقدم وعدًا محيرًا بالثروة والتأثير.

اليوم، يكسب الكثير من الناس المال من البقاء في المنزل في التداول في سوق الأوراق المالية. إنها نقطة إضافية بالنسبة لك إذا كنت تستخدم خبرتك في سوق الأوراق المالية ومهارات التعلم الآلي الخاصة بك لمهمة التنبؤ بسعر السهم.

دعنا نرى كيفية توقع أسعار الأسهم باستخدام التعلم الآلي ولغة برمجة بايثون. سأبدأ هذه المهمة عن طريق استيراد جميع مكتبات بايثون الضرورية التي نحتاجها لهذه المهمة:

```
import numpy as np
import pandas as pd
from sklearn import preprocessing
from sklearn.model_selection import train_test_split
from sklearn.linear_model import LinearRegression
```

تحضير البيانات

في القسم أعلاه، بدأت مهمة التنبؤ بسعر السهم عن طريق استيراد مكتبات بايثون. سأكتب الآن دالة من شأنها إعداد مجموعة البيانات حتى تتمكن من ملاءمتها بسهولة في نموذج الانحدار الخطي:

```
def prepare_data(df, forecast_col, forecast_out, test_size):
    label = df[forecast_col].shift(-forecast_out) #creating
    new column called label with the last 5 rows are nan
    X = np.array(df[[forecast_col]]) #creating the feature
    array
```

```

X = preprocessing.scale(X) #processing the feature array
X_lately = X[-forecast_out:] #creating the column i want
to use later in the predicting method
X = X[:-forecast_out] # X that will contain the training
and testing
label.dropna(inplace=True) #dropping na values
y = np.array(label) # assigning Y
X_train, X_test, Y_train, Y_test = train_test_split(X, y,
test_size=test_size, random_state=0) #cross validation

response = [X_train,X_test , Y_train, Y_test , X_lately]
return response

```

يمكنك بسهولة فهم الدالة المذكورة أعلاه لأنني قد دونت طريقة عمل كل سطر خطوة بخطوة. الآن الشيء التالي الذي يجب فعله هو قراءة البيانات:

```

df = pd.read_csv("prices.csv")
df = df[df.symbol == "GOOG"]

```

نحتاج الآن إلى إعداد ثلاث متغيرات إدخال كما تم إعدادها بالفعل في الدالة التي تم إنشاؤها في القسم أعلاه. نحتاج إلى إعلان متغير إدخال مع ذكر العمود الذي نريد التنبؤ به. المتغير التالي الذي نحتاج إلى الإعلان عنه هو إلى أي مدى نريد التنبؤ.

والمتغير الأخير الذي نحتاج إلى الإعلان عنه هو المقدار الذي يجب أن يكون حجم مجموعة الاختبار. الآن دعنا نعلن عن جميع المتغيرات:

```

forecast_col = 'close'
forecast_out = 5
test_size = 0.2

```

تطبيق تعلم الآلة للتنبؤ بأسعار الأسهم

الآن سأقسم البيانات وملائمة (fit) نموذج الانحدار الخطي:

```

X_train, X_test, Y_train, Y_test , X_lately
=prepare_data(df,forecast_col,forecast_out,test_size);
#calling the method were the cross validation and data
preparation is in
learner = LinearRegression() #initializing linear regression
model

learner.fit(X_train,Y_train) #training the linear regression
model

```

الآن دعونا نتنبأ بالمخرجات ونلقي نظرة على أسعار الأسهم:

```

score=learner.score(X_test,Y_test)#testing the linear
regression model
forecast= learner.predict(X_lately) #set that will contain the
forecasted data
response={}#creting json object
response['test_score']=score
response['forecast_set']=forecast
print(response)

```

```
{'test_score': 0.9481024935723803, 'forecast_set': array([[786.54352516, 788.13020371, 781.84159626, 779.65508615, 769.04187979]])}
```

الملخص

إذن هذه هي الطريقة التي يمكننا بها التنبؤ بأسعار الأسهم باستخدام التعلم الآلي. آمل أن تكون قد أحببت هذه المقالة حول تنبؤات أسعار الأسهم باستخدام بايثون مع التعلم الآلي من خلال تطبيق نموذج الانحدار الخطي.

14) التنبؤ بالنجاة من سرطان الثدي مع التعلم الآلي Breast Cancer Survival Prediction with Machine Learning

سرطان الثدي (Breast cancer) هو أحد أنواع السرطانات التي تبدأ في الثدي. يحدث عند النساء، لكن يمكن أن يصاب الرجال أيضاً بسرطان الثدي. إنه السبب الرئيسي الثاني للوفاة عند النساء. نظراً لأن استخدام البيانات في الرعاية الصحية أمر شائع جداً اليوم، يمكننا استخدام التعلم الآلي للتنبؤ بما إذا كان المريض سينجو من مرض مميت مثل سرطان الثدي أم لا. لذلك إذا كنت تريد معرفة كيفية التنبؤ بنجاة مريضة بسرطان الثدي، فهذه المقالة لك. في هذه المقالة، سوف آخذك خلال مهمة التنبؤ بالنجاة من سرطان الثدي مع التعلم الآلي باستخدام بايثون.

التنبؤ بالنجاة من سرطان الثدي مع التعلم الآلي

لديك مجموعة بيانات تضم أكثر من 400 مريض بسرطان الثدي خضعن لعملية جراحية لعلاج سرطان الثدي. فيما يلي معلومات عن جميع الأعمدة في مجموعة البيانات:

1. Patient_ID: معرف المريض.
2. Age: عمر المريض.
3. Gender: جنس المريض.
4. Protein1, Protein2, Protein3, Protein4: مستويات التعبير.
5. Tumor_Stage: مرحلة سرطان الثدي لدى المريضة.
6. Histology: تسلل سرطان الأبنية Infiltrating Ductal Carcinoma ، تسلل سرطاني فصيصي Infiltration Lobular Carcinoma ، سرطانة مخاطية Mucinous Carcinoma.
7. ER status: إيجابي / سلبي.
8. PR status: إيجابي / سلبي.
9. HER2 status: إيجابي / سلبي.

10. **Surgery_type**: استئصال الكتلة الورمية Lumpectomy ، استئصال الثدي البسيط Simple Mastectomy ، استئصال الثدي الجذري المعدل Modified Radical Mastectomy ، أخرى.

11. **DateofSurgery**: تاريخ الجراحة.

12. **DateofLast_Visit**: تاريخ آخر زيارة للمريض.

13. **Patient_Status**: حي / ميت.

لذلك، باستخدام مجموعة البيانات هذه، تتمثل مهمتنا في التنبؤ بما إذا كانت مريضة سرطان الثدي ستنجو أم لا بعد الجراحة.

أمل أن يكون لديك نظرة عامة على مجموعة البيانات التي نستخدمها لمهمة التنبؤ بالبقاء على قيد الحياة من سرطان الثدي. تم جمع مجموعة البيانات هذه من Kaggle. يمكنك تنزيل مجموعة البيانات هذه من [هنا](#). الآن، في القسم أدناه، سأوجهك خلال مهمة التنبؤ بالبقاء على قيد الحياة من سرطان الثدي باستخدام التعلم الآلي باستخدام بايثون.

التنبؤ بالنجاة من سرطان الثدي باستخدام لغة بايثون

سأبدأ مهمة التنبؤ بالبقاء على قيد الحياة من سرطان الثدي عن طريق استيراد مكتبات بايثون الضرورية ومجموعة البيانات التي نحتاجها:

```
import pandas as pd
import numpy as np
import plotly.express as px
from sklearn.model_selection import train_test_split
from sklearn.svm import SVC

data = pd.read_csv("BRCA.csv")
print(data.head())
```

	Patient_ID	Age	Gender	Protein1	Protein2	Protein3	Protein4	\
0	TCGA-D8-A1XD	36.0	FEMALE	0.080353	0.42638	0.54715	0.273680	
1	TCGA-EW-A10X	43.0	FEMALE	-0.420320	0.57807	0.61447	-0.031505	
2	TCGA-A8-A079	69.0	FEMALE	0.213980	1.31140	-0.32747	-0.234260	
3	TCGA-D8-A1XR	56.0	FEMALE	0.345090	-0.21147	-0.19304	0.124270	
4	TCGA-BH-A0BF	56.0	FEMALE	0.221550	1.90680	0.52045	-0.311990	

	Tumour_Stage	Histology	ER status	PR status	HER2 status	\
0	III	Infiltrating Ductal Carcinoma	Positive	Positive	Negative	
1	II	Mucinous Carcinoma	Positive	Positive	Negative	
2	III	Infiltrating Ductal Carcinoma	Positive	Positive	Negative	
3	II	Infiltrating Ductal Carcinoma	Positive	Positive	Negative	
4	II	Infiltrating Ductal Carcinoma	Positive	Positive	Negative	

```

Surgery_type Date_of_Surgery Date_of_Last_Visit \
0 Modified Radical Mastectomy 15-Jan-17 19-Jun-17
1 Lumpectomy 26-Apr-17 09-Nov-18
2 Other 08-Sep-17 09-Jun-18
3 Modified Radical Mastectomy 25-Jan-17 12-Jul-17
4 Other 06-May-17 27-Jun-19

Patient_Status
0 Alive
1 Dead
2 Alive
3 Alive
4 Dead

```

دعونا نلقي نظرة على ما إذا كانت أعمدة مجموعة البيانات هذه تحتوي على أي قيم فارغة أم لا :

```
print(data.isnull().sum())
```

```

Patient_ID      7
Age             7
Gender          7
Protein1       7
Protein2       7
Protein3       7
Protein4       7
Tumour_Stage   7
Histology      7
ER_status      7
PR_status      7
HER2_status    7
Surgery_type   7
Date_of_Surgery 7
Date_of_Last_Visit 24
Patient_Status 20
dtype: int64

```

إذن، تحتوي مجموعة البيانات هذه على بعض القيم الخالية في كل عمود، وسوف أسقط هذه القيم الفارغة:

```
data = data.dropna()
```

دعنا الآن نلقي نظرة على الإحصاءات حول أعمدة هذه البيانات:

```
data.info()
```

```

<class 'pandas.core.frame.DataFrame'>
Int64Index: 317 entries, 0 to 333
Data columns (total 16 columns):
#   Column          Non-Null Count  Dtype
---  -
0   Patient_ID      317 non-null   object
1   Age             317 non-null   float64
2   Gender          317 non-null   object
3   Protein1        317 non-null   float64
4   Protein2        317 non-null   float64
5   Protein3        317 non-null   float64

```

```

6 Protein4      317 non-null  float64
7 Tumour_Stage 317 non-null  object
8 Histology     317 non-null  object
9 ER status     317 non-null  object
10 PR status    317 non-null  object
11 HER2 status  317 non-null  object
12 Surgery_type 317 non-null  object
13 Date_of_Surgery 317 non-null object
14 Date_of_Last_Visit 317 non-null object
15 Patient_Status 317 non-null object
dtypes: float64(5), object(11)
memory usage: 42.1+ KB

```

تم العثور على سرطان الثدي في الغالب عند الإناث، لذلك دعونا نلقي نظرة على عمود الجنس (Gender column) لمعرفة عدد الإناث والذكور هناك:

```
print(data.Gender.value_counts())
```

```

FEMALE    313
MALE       4
Name: Gender, dtype: int64

```

كما هو متوقع، فإن نسبة الإناث أكثر من الذكور في عمود الجنس. الآن دعونا نلقي نظرة على مرحلة الورم (stage of tumor) لدى المرضى:

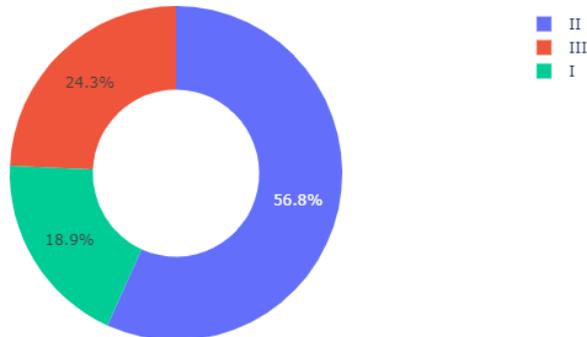
```

#Tumour Stage
stage = data["Tumour_Stage"].value_counts()
transactions = stage.index
quantity = stage.values

figure = px.pie(data,
    values=quantity,
    names=transactions, hole = 0.5,
    title="Tumour Stages of Patients("
figure.show()

```

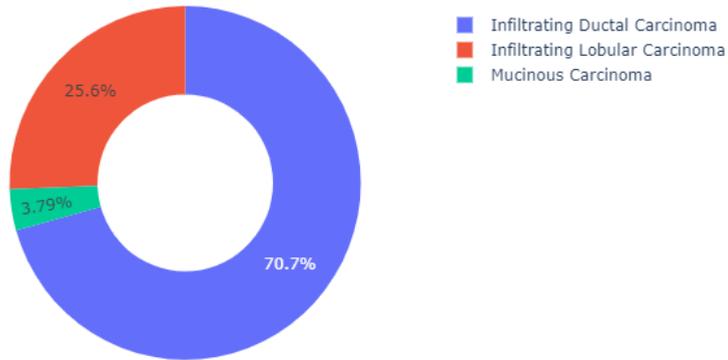
Tumour Stages of Patients



لذلك معظم المرضى في المرحلة الثانية. الآن دعونا نلقي نظرة على أنسجة (histology) مرضى سرطان الثدي. (علم الأنسجة هو وصف للورم بناءً على مدى تشوه الخلايا والأنسجة السرطانية تحت المجهر ومدى سرعة نمو وانتشار السرطان):

```
#Histology
histology = data["Histology"].value_counts()
transactions = histology.index
quantity = histology.values
figure = px.pie(data,
                values=quantity,
                names=transactions, hole = 0.5,
                title="Histology of Patients")
figure.show()
```

Histology of Patients



دعنا الآن نلقي نظرة على قيم ER status و PR status و HER2 status للمرضى:

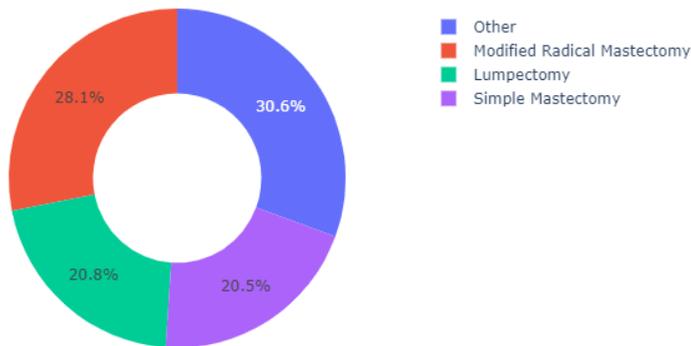
```
#ER status
print(data["ER status"].value_counts())
#PR status
print(data["PR status"].value_counts())
#HER2 status
print(data["HER2 status"].value_counts())
```

```
Positive    317
Name: ER status, dtype: int64
Positive    317
Name: PR status, dtype: int64
Negative    288
Positive     29
Name: HER2 status, dtype: int64
```

الآن دعونا نلقي نظرة على نوع العمليات الجراحية (type of surgeries) التي أجريت للمرضى:

```
#Surgery_type
surgery = data["Surgery_type"].value_counts()
transactions = surgery.index
quantity = surgery.values
figure = px.pie(data,
                values=quantity,
                names=transactions, hole = 0.5,
                title="Type of Surgery of Patients")
figure.show()
```

Type of Surgery of Patients



لذلك اكتشفنا البيانات، تحتوي مجموعة البيانات على الكثير من الميزات الفئوية (categorical features). لاستخدام هذه البيانات لتدريب نموذج التعلم الآلي، نحتاج إلى تحويل قيم جميع الأعمدة الفئوية. إليك كيف يمكننا تحويل قيم الميزات الفئوية:

```
data["Tumour_Stage"] = data["Tumour_Stage"].map({"I": 1, "II": 2, "III": 3})
data["Histology"] = data["Histology"].map({"Infiltrating Ductal Carcinoma": 1, "Infiltrating Lobular Carcinoma": 2, "Mucinous Carcinoma": 3})
data["ER status"] = data["ER status"].map({"Positive": 1})
data["PR status"] = data["PR status"].map({"Positive": 1})
data["HER2 status"] = data["HER2 status"].map({"Positive": 1, "Negative": 2})
data["Gender"] = data["Gender"].map({"MALE": 0, "FEMALE": 1})
data["Surgery_type"] = data["Surgery_type"].map({"Other": 1, "Modified Radical Mastectomy": 2, "Lumpectomy": 3, "Simple Mastectomy": 4})
print(data.head())
```

	Patient_ID	Age	Gender	Protein1	Protein2	Protein3	Protein4	\
0	TCGA-D8-A1XD	36.0	1	0.080353	0.42638	0.54715	0.273680	
1	TCGA-EW-A10X	43.0	1	-0.420320	0.57807	0.61447	-0.031505	
2	TCGA-A8-A079	69.0	1	0.213980	1.31140	-0.32747	-0.234260	
3	TCGA-D8-A1XR	56.0	1	0.345090	-0.21147	-0.19304	0.124270	
4	TCGA-BH-A0BF	56.0	1	0.221550	1.90680	0.52045	-0.311990	

	Tumour_Stage	Histology	ER status	PR status	HER2 status	Surgery_type	\
0	3	1	1	1	1	2	2
1	2	3	1	1	1	2	3
2	3	1	1	1	1	2	1
3	2	1	1	1	1	2	2
4	2	1	1	1	1	2	1

	Date_of_Surgery	Date_of_Last_Visit	Patient_Status
0	15-Jan-17	19-Jun-17	Alive
1	26-Apr-17	09-Nov-18	Dead
2	08-Sep-17	09-Jun-18	Alive
3	25-Jan-17	12-Jul-17	Alive
4	06-May-17	27-Jun-19	Dead

نموذج التنبؤ بالنجاة من سرطان الثدي

يمكننا الآن الانتقال إلى تدريب نموذج التعلم الآلي للتنبؤ ببقاء مريض سرطان الثدي على قيد الحياة. قبل تدريب النموذج، نحتاج إلى تقسيم البيانات إلى مجموعة تدريب واختبار:

```
#Splitting data
x = np.array(data[['Age', 'Gender', 'Protein1', 'Protein2',
'Protein3', 'Protein4',
'Tumour_Stage', 'Histology', 'ER status', 'PR status',
'HER2 status', 'Surgery_type']])
y = np.array(data[['Patient_Status']])
xtrain, xtest, ytrain, ytest = train_test_split(x, y,
test_size=0.10, random_state=42)
```

إليك الآن كيف يمكننا تدريب نموذج التعلم الآلي:

```
model = SVC()
model.fit(xtrain, ytrain)
```

دعنا الآن ندخل جميع الميزات التي استخدمناها لتدريب نموذج التعلم الآلي هذا والتنبؤ بما إذا كان المريض سينجو من سرطان الثدي أم لا:

```
#Prediction
#features = [['Age', 'Gender', 'Protein1', 'Protein2',
'Protein3', 'Protein4', 'Tumour_Stage', 'Histology', 'ER
status', 'PR status', 'HER2 status', 'Surgery_type']]
features = np.array ([[36.0, 1, 0.080353, 0.42638, 0.54715,
0.273680, 3, 1, 1, 1, 1, 2, 2]])
print(model.predict(features))
```

```
['Alive']
```

الملخص

هذه هي الطريقة التي يمكننا بها استخدام التعلم الآلي لمهمة التنبؤ بالبقاء على قيد الحياة من سرطان الثدي. نظراً لأن استخدام البيانات في الرعاية الصحية أمر شائع جداً اليوم، يمكننا استخدام التعلم الآلي للتنبؤ بما إذا كان المريض سينجو من مرض مميت مثل سرطان الثدي أم لا. أمل أن تكون قد أحببت هذه المقالة حول التنبؤ بالبقاء على قيد الحياة من سرطان الثدي مع التعلم الآلي باستخدام بايثون.

15) التنبؤ بوفيات Covid-19 باستخدام التعلم الآلي Covid-19 Deaths Prediction with Machine Learning

يعد Covid-19 أحد أكثر الفيروسات فتكًا التي سمعتها على الإطلاق. الطفرات في Covid-19 تجعله إما أكثر فتكًا أو معديًا. لقد رأينا الكثير من الوفيات بسبب Covid-19 بينما كانت هناك موجة أعلى من الحالات. يمكننا استخدام البيانات التاريخية الخاصة بحالات Covid-19 والوفيات للتنبؤ بعدد الوفيات في المستقبل. لذلك إذا كنت تريد معرفة كيفية التنبؤ بوفيات Covid-19 باستخدام التعلم الآلي، فهذه المقالة مناسبة لك. في هذه المقالة، سوف آخذك خلال مهمة التنبؤ بوفيات Covid-19 مع التعلم الآلي باستخدام بايثون.

التنبؤ بوفيات كوفيد-19 (دراسة حالة)

لقد حصلت على مجموعة بيانات لـ Covid-19 في الهند من 30 يناير 2020 إلى 18 يناير 2022. تحتوي مجموعة البيانات على معلومات حول الحالات والوفيات المؤكدة يوميًا. فيما يلي جميع أعمدة مجموعة البيانات:

1. **Date**: يحتوي على تاريخ السجل.
2. **Date_YMD**: يحتوي على التاريخ بتنسيق Year-Month-Day.
3. **Daily Confirmed**: يحتوي على الحالات المؤكدة اليومية لـ Covid-19.
4. **Daily Deceased**: يحتوي على الوفيات اليومية بسبب Covid-19.

تحتاج إلى استخدام هذه البيانات التاريخية لحالات covid-19 والوفيات للتنبؤ بعدد الوفيات خلال الثلاثين يومًا القادمة. يمكنك تنزيل مجموعة البيانات هذه من [هنا](#).

التنبؤ بوفيات Covid-19 باستخدام بايثون

أمل أن تكون قد فهمت الآن بيان المشكلة المذكور أعلاه. سأقوم الآن باستيراد جميع مكتبات بايثون الضرورية ومجموعة البيانات التي نحتاجها لمهمة التنبؤ بوفيات covid-19:

```
import pandas as pd
import numpy as np
data = pd.read_csv("COVID19 data for overall INDIA.csv")
print(data.head())
```

	Date	Date_YMD	Daily Confirmed	Daily Deceased
0	30 January 2020	2020-01-30	1	0
1	31 January 2020	2020-01-31	0	0
2	1 February 2020	2020-02-01	0	0
3	2 February 2020	2020-02-02	1	0
4	3 February 2020	2020-02-03	1	0

قبل المضي قدماً، دعنا نلقي نظرة سريعة على ما إذا كانت مجموعة البيانات هذه تحتوي على أي قيم فارغة أم لا:

```
data.isnull().sum()
```

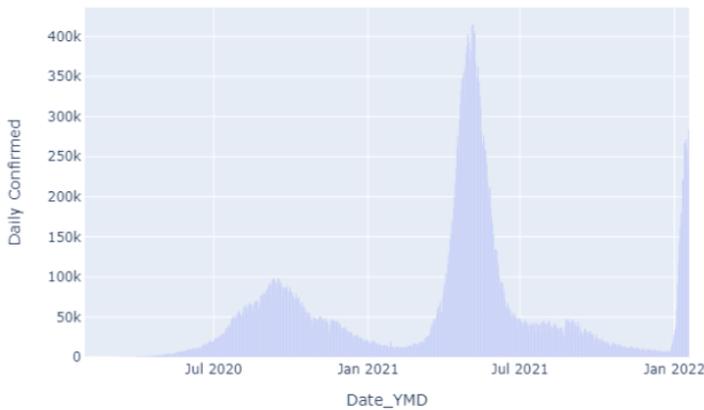
```
Date          0
Date_YMD      0
Daily Confirmed 0
Daily Deceased 0
dtype: int64
```

لسنا بحاجة إلى عمود التاريخ (`date column`)، لذا دعنا نسقط هذا العمود من مجموعة البيانات الخاصة بنا:

```
data = data.drop("Date", axis=1)
```

دعونا نلقي نظرة على الحالات المؤكدة اليومية لـ Covid-19:

```
import plotly.express as px
fig = px.bar(data, x='Date_YMD', y='Daily Confirmed')
fig.show()
```



في تصوير البيانات أعلاه، يمكننا أن نرى موجة عالية من حالات كوفيد - 19 بين أبريل 2021 ومايو 2021.

تحليل معدل الوفيات Covid-19

الآن دعونا نصور معدل الوفيات (`death rate`) بسبب Covid-19:

```

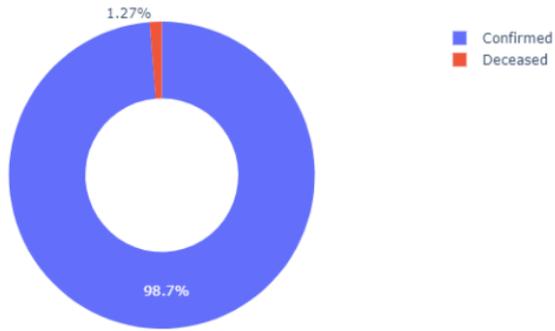
cases = data["Daily Confirmed"].sum()
deceased = data["Daily Deceased"].sum()

labels = ["Confirmed", "Deceased"]
values = [cases, deceased]

fig = px.pie(data, values=values,
             names=labels,
             title='Daily Confirmed Cases vs Daily Deaths', hole=0.5)
fig.show()

```

Daily Confirmed Cases vs Daily Deaths



دعونا نحسب معدل الوفيات لـ Covid-19:

```

death_rate = (data["Daily Deceased"].sum() / data["Daily Confirmed"].sum()) * 100
print(death_rate)

```

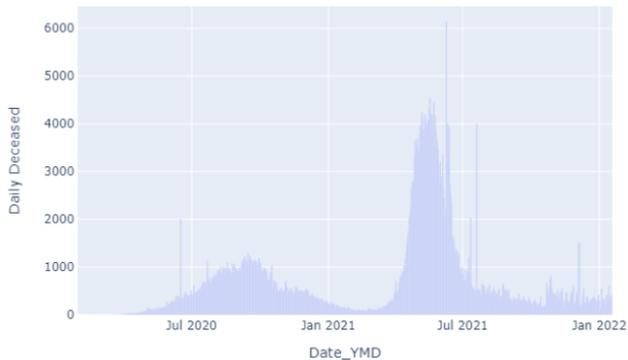
1.2840580507834722

الآن دعونا نلقي نظرة على الوفيات اليومية (daily deaths) لمرض Covid-19:

```

import plotly.express as px
fig = px.bar(data, x='Date_YMD', y='Daily Deceased')
fig.show()

```



يمكننا أن نرى عددًا كبيرًا من الوفيات خلال الموجة العالية من حالات الإصابة بـ covid-19 .

نموذج التنبؤ بوفيات Covid-19

الآن دعنا ننتقل إلى مهمة التنبؤ بوفيات Covid-19 للأيام الثلاثين القادمة. سأستخدم هنا مكتبة **AutoTS** ، والتي تعد واحدة من أفضل مكتبات التعلم الآلي التلقائية لتحليل السلاسل الزمنية. إذا لم تكن قد استخدمت هذه المكتبة من قبل، فيمكنك تثبيتها عن طريق تنفيذ الأمر المذكور أدناه في موجه الأوامر أو التيرمينال:

```
pip install autots
```

إليك الآن كيفية توقع وفيات Covid-19 باستخدام التعلم الآلي للأيام الثلاثين القادمة:

```
from autots import AutoTS
model = AutoTS(forecast_length=30, frequency='infer',
ensemble='simple')
model = model.fit(data, date_col="Date_YMD", value_col='Daily
Deceased', id_col=None)
prediction = model.predict()
forecast = prediction.forecast
print (forecast)
```

	Daily Deceased
2022-01-19	271.950000
2022-01-20	310.179787
2022-01-21	297.500000
2022-01-22	310.179787
2022-01-23	271.950000
2022-01-24	258.518302
2022-01-25	340.355520
2022-01-26	296.561343
2022-01-27	296.561343
2022-01-28	284.438262
2022-01-29	323.400000
2022-01-30	271.950000
2022-01-31	245.750000
2022-02-01	284.438262
2022-02-02	258.518302
2022-02-03	239.969607
2022-02-04	271.950000
2022-02-05	334.118953
2022-02-06	323.400000
2022-02-07	271.950000
2022-02-08	284.438262
2022-02-09	323.400000
2022-02-10	258.518302
2022-02-11	245.750000
2022-02-12	245.750000
2022-02-13	326.442185
2022-02-14	323.400000
2022-02-15	394.343619
2022-02-16	228.117431
2022-02-17	358.200000

الملخص

هذه الطريقة التي يمكننا بها توقع وفيات Covid-19 باستخدام التعلم الآلي باستخدام لغة برمجة بايثون. يمكننا استخدام البيانات التاريخية لحالات Covid-19 والوفيات للتنبؤ بعدد الوفيات في المستقبل. يمكنك تنفيذ نفس الطريقة للتنبؤ بوفيات وموجات Covid-19 على أحدث مجموعة بيانات. أمل أن تكون قد أحببت هذا المقال عن التنبؤ بوفيات Covid-19 باستخدام التعلم الآلي.

Stock Price LSTM مع التنبؤ بسعر السهم مع LSTM Prediction with LSTM

LSTM تعني شبكات الذاكرة طويلة قصيرة المدى (Long Short-Term Memory Networks). إنها نوع من الشبكات العصبية المتكررة (recurrent neural network) التي تُستخدم بشكل شائع للتنبؤ بالانحدار (regression) والتنبؤ بالسلاسل الزمنية (time series) في التعلم الآلي. يمكنه حفظ البيانات لفترات طويلة، مما يميز الشبكات العصبية LSTM عن الشبكات العصبية الأخرى. إذا كنت تريد معرفة كيفية التنبؤ بأسعار الأسهم باستخدام LSTM، فهذه المقالة مناسبة لك. في هذه المقالة، سوف أطلعك على مهمة التنبؤ بأسعار الأسهم باستخدام LSTM باستخدام بايثون.

التنبؤ بسعر السهم مع LSTM

يعد استخدام LSTM أحد أفضل أساليب التعلم الآلي للتنبؤ بالسلسلة الزمنية. LSTMs هي شبكات عصبية متكررة مصممة لتذكر البيانات لفترة أطول. لذلك، كلما كنت تعمل على مشكلة حيث فشلت شبكتك العصبية في حفظ البيانات، يمكنك استخدام الشبكة العصبية LSTM. يمكنك قراءة المزيد عن LSTM [هنا](#).

الآن في هذا القسم، سوف آخذك خلال مهمة توقع أسعار الأسهم باستخدام LSTM باستخدام لغة برمجة بايثون. سأبدأ هذه المهمة عن طريق استيراد جميع مكتبات بايثون الضرورية وجمع أحدث بيانات أسعار أسهم Apple:

```
import pandas as pd
import yfinance as yf
import datetime
from datetime import date, timedelta
today = date.today()

d1 = today.strftime("%Y-%m-%d")
end_date = d1
d2 = date.today() - timedelta(days=5000)
d2 = d2.strftime("%Y-%m-%d")
start_date = d2

data = yf.download('AAPL',
                  start=start_date,
                  end=end_date,
                  progress=False)
data["Date"] = data.index
data = data[["Date", "Open", "High", "Low", "Close",
            "Adj Close", "Volume"]]
data.reset_index(drop=True, inplace=True)
data.tail()
```

	Date	Open	High	...	Close	Adj Close	Volume
3441	2021-12-27	177.089996	180.419998	...	180.330002	180.330002	74919600
3442	2021-12-28	180.160004	181.330002	...	179.289993	179.289993	79144300
3443	2021-12-29	179.330002	180.630005	...	179.380005	179.380005	62348900
3444	2021-12-30	179.470001	180.570007	...	178.199997	178.199997	59773000
3445	2021-12-31	178.089996	179.229996	...	177.570007	177.570007	64025500

[5 rows x 7 columns]

يعطي مخطط الشموع اليابانية (candlestick chart) صورة واضحة عن الزيادة والانخفاض في أسعار الأسهم، لذلك دعونا نتخيل مخطط الشموع للبيانات قبل الماضي قدمًا:

```
import plotly.graph_objects as go
figure = go.Figure(data=[go.Candlestick(x=data["Date"],
                                       open=data["Open"],
                                       high=data["High"],
                                       low=data["Low"],
                                       close=data["Close"])]])
figure.update_layout(title = "Apple Stock Price Analysis",
                    xaxis_rangeslider_visible=False)
figure.show()
```

Apple Stock Price Analysis



دعنا الآن نلقي نظرة على ارتباط (correlation) جميع الأعمدة بعمود الإغلاق لأنه العمود الهدف:

```
correlation = data.corr()
print(correlation["Close"].sort_values(ascending=False))
```

```
Close      1.000000
Low        0.999890
High       0.999887
Adj Close  0.999845
Open       0.999783
Volume     -0.496325
Name: Close, dtype: float64
```

تدريب LSTM للتنبؤ بسعر السهم

سأبدأ الآن بتدريب نموذج LSTM للتنبؤ بأسعار الأسهم. سأقسم البيانات أولاً إلى مجموعات تدريب واختبار:

```
x = data[["Open", "High", "Low", "Volume"]]
y = data["Close"]
x = x.to_numpy()
y = y.to_numpy()
y = y.reshape(-1, 1)

from sklearn.model_selection import train_test_split
xtrain, xtest, ytrain, ytest = train_test_split(x, y,
test_size=0.2, random_state=42)
```

الآن سأقوم بإعداد هيكل شبكة عصبية لـ LSTM:

```
from keras.models import Sequential
from keras.layers import Dense, LSTM
model = Sequential()
model.add(LSTM(128, return_sequences=True, input_shape=
(xtrain.shape[1], 1)))
model.add(LSTM(64, return_sequences=False))
model.add(Dense(25))
model.add(Dense(1))
model.summary()
```

Model: "sequential_6"

Layer (type)	Output Shape	Param #
lstm_12 (LSTM)	(None, 4, 128)	66560
lstm_13 (LSTM)	(None, 64)	49408
dense_12 (Dense)	(None, 25)	1625
dense_13 (Dense)	(None, 1)	26

=====
Total params: 117,619
Trainable params: 117,619
Non-trainable params: 0
=====

الآن إليك كيف يمكننا تدريب نموذج شبكتنا العصبية للتنبؤ بأسعار الأسهم:

```
model.compile(optimizer='adam', loss='mean_squared_error')
model.fit(xtrain, ytrain, batch_size=1, epochs=30)
```

```
Epoch 1/30
2756/2756 [=====] - 18s 5ms/step - loss: 6.7984
Epoch 2/30
2756/2756 [=====] - 15s 5ms/step - loss: 4.4978
Epoch 3/30
2756/2756 [=====] - 15s 5ms/step - loss: 5.6511
Epoch 4/30
2756/2756 [=====] - 15s 5ms/step - loss: 6.8347
Epoch 5/30
2756/2756 [=====] - 15s 5ms/step - loss: 9.5083
Epoch 6/30
2756/2756 [=====] - 15s 5ms/step - loss: 7.4367
Epoch 7/30
2756/2756 [=====] - 15s 5ms/step - loss: 4.3043
Epoch 8/30
2756/2756 [=====] - 15s 6ms/step - loss: 4.2213
Epoch 9/30
2756/2756 [=====] - 15s 5ms/step - loss: 5.7352
Epoch 10/30
2756/2756 [=====] - 15s 6ms/step - loss: 5.2137
Epoch 11/30
2756/2756 [=====] - 15s 5ms/step - loss: 6.0945
Epoch 12/30
2756/2756 [=====] - 14s 5ms/step - loss: 4.1032
Epoch 13/30
2756/2756 [=====] - 15s 5ms/step - loss: 4.3637
Epoch 14/30
2756/2756 [=====] - 15s 5ms/step - loss: 6.2240
Epoch 15/30
2756/2756 [=====] - 15s 5ms/step - loss: 1.9857
```

```
Epoch 16/30
2756/2756 [=====] - 15s 5ms/step - loss: 6.3982
Epoch 17/30
2756/2756 [=====] - 15s 5ms/step - loss: 3.3015
Epoch 18/30
2756/2756 [=====] - 15s 5ms/step - loss: 3.9104
Epoch 19/30
2756/2756 [=====] - 15s 5ms/step - loss: 4.6564
Epoch 20/30
2756/2756 [=====] - 15s 5ms/step - loss: 3.3215
Epoch 21/30
2756/2756 [=====] - 15s 6ms/step - loss: 4.3116
Epoch 22/30
2756/2756 [=====] - 15s 5ms/step - loss: 2.8147
Epoch 23/30
2756/2756 [=====] - 15s 5ms/step - loss: 5.7586
Epoch 24/30
2756/2756 [=====] - 16s 6ms/step - loss: 4.1890
Epoch 25/30
2756/2756 [=====] - 17s 6ms/step - loss: 3.6991
Epoch 26/30
2756/2756 [=====] - 15s 6ms/step - loss: 4.0951
Epoch 27/30
2756/2756 [=====] - 15s 5ms/step - loss: 3.5940
Epoch 28/30
2756/2756 [=====] - 16s 6ms/step - loss: 3.7180
Epoch 29/30
2756/2756 [=====] - 15s 6ms/step - loss: 3.5864
Epoch 30/30
2756/2756 [=====] - 15s 5ms/step - loss: 3.7422
<keras.callbacks.History at 0x7f8c37686790>
```

الآن دعنا نختبر هذا النموذج من خلال إعطاء قيم الإدخال وفقاً للميزات التي استخدمناها لتدريب هذا النموذج والتنبؤ بالنتيجة النهائية:

```
import numpy as np
#features = [Open, High, Low, Adj Close, Volume]
features = np.array([177.070007, 180.419998, 177.089996, 74919600])
model.predict(features)
```

```
array([[179.95299]], dtype=float32)
```

إذن هذه هي الطريقة التي يمكننا بها استخدام هيكل الشبكة العصبية LSTM لمهمة التنبؤ بسعر السهم.

الملخص

LSTM تعني شبكات الذاكرة طويلة قصيرة المدى. إنها شبكة عصبية متكررة مصممة لتذكر البيانات لفترة أطول. يعد استخدام LSTM أحد أفضل أساليب التعلم الآلي للتنبؤ بالسلسلة الزمنية. أمل أن تكون قد أحببت هذه المقالة حول توقع أسعار الأسهم باستخدام LSTM باستخدام بايثون.

17) نظام توصية المقالات مع التعلم الآلي Article Recommendation System with Machine Learning

نظام التوصية (recommendation system) هو أحد تطبيقات علم البيانات التي يستخدمها أي تطبيق أو موقع ويب تقريباً اليوم. تستخدم العديد من مواقع الويب اليوم نظام توصية للتوصية بالمقالات لقراءها. على سبيل المثال، يستخدم موقع Medium.com وحتى موقع الويب الذي تقرأ عليه هذه المقالة حالياً نظاماً للتوصية بالمقالات لقراءه. لذلك، إذا كنت ترغب في معرفة كيفية إنشاء نظام توصية بالمقالات باستخدام التعلم الآلي، فهذه المقالة مناسبة لك. في هذه المقالة، سوف أطلعك على كيفية إنشاء نظام توصيات المقالة باستخدام التعلم الآلي باستخدام بايثون.

نظام التوصية بالمقالات

هناك العديد من الطرق لإنشاء أنظمة التوصية. لإنشاء نظام توصية بالمقالات، نحتاج إلى التركيز على المحتوى (content) بدلاً من اهتمام المستخدم. على سبيل المثال، إذا قرأ المستخدم مقالة تستند إلى المجموعات، فيجب أن تستند جميع المقالات الموصى بها أيضاً إلى المجموعات. لذلك للتوصية بالمقالات بناءً على المحتوى:

1. نحن بحاجة إلى فهم محتوى المقال.
2. تطابق المحتوى مع جميع المقالات الأخرى.
3. والتوصية بالمقالات الأكثر ملاءمة للمقالة التي يقرأها القارئ بالفعل.

لهذه المهمة، يمكننا استخدام مفهوم تشابه جيب التمام (cosine similarity) في التعلم الآلي. تشابه جيب التمام هو طريقة لبناء أنظمة التوصية بناءً على المحتوى. يتم استخدامه لإيجاد أوجه التشابه بين قطعتين مختلفتين من المستندات النصية. لذلك يمكننا استخدام تشابه جيب التمام لبناء نظام توصية بالمقالات. في القسم أدناه، سوف أطلعك على كيفية إنشاء نظام توصية بالمقالات باستخدام التعلم الآلي باستخدام بايثون.

نظام التوصية بالمقالات باستخدام بايثون

لإنشاء نظام توصية بالمقالات، قمت بجمع بيانات حول بعض المقالات على هذا الموقع نفسه. لذلك دعونا نستورد مكتبات بايثون الضرورية ومجموعة البيانات التي نحتاجها لإنشاء نظام توصية بالمقالات:

```
import pandas as pd
import numpy as np
from sklearn.feature_extraction import text
from sklearn.metrics.pairwise import cosine_similarity
```

```
data =
pd.read_csv("https://raw.githubusercontent.com/amankharwal/Web
site-data/master/articles.csv", encoding='latin1')
data.head()
```

	Article	Title
0	Data analysis is the process of inspecting and...	Best Books to Learn Data Analysis
1	The performance of a machine learning algorithm...	Assumptions of Machine Learning Algorithms
2	You must have seen the news divided into categ...	News Classification with Machine Learning
3	When there are only two classes in a classific...	Multiclass Classification Algorithms in Machin...
4	The Multinomial Naive Bayes is one of the vari...	Multinomial Naive Bayes in Machine Learning

مجموعة البيانات هذه جاهزة تماماً للاستخدام لإنشاء نظام توصية، لذلك دعونا نستخدم خوارزمية تشابه جيب التمام ونكتب دالة بايثون للتوصية بالمقالات:

```
articles = data["Article"].tolist()
uni_tfidf = text.TfidfVectorizer(input=articles,
stop_words="english")
uni_matrix = uni_tfidf.fit_transform(articles)
uni_sim = cosine_similarity(uni_matrix)
def recommend_articles(x):
    return ", ".join(data["Title"].loc[x.argsort()[-5:-1]])
data["Recommended Articles"] = [recommend_articles(x) for x in
uni_sim]
data.head()
```

	Article	Title	Recommended Articles
0	Data analysis is the process of inspecting and...	Best Books to Learn Data Analysis	Introduction to Recommendation Systems, Best B...
1	The performance of a machine learning algorithm...	Assumptions of Machine Learning Algorithms	Applications of Deep Learning, Best Books to L...
2	You must have seen the news divided into categ...	News Classification with Machine Learning	Language Detection with Machine Learning, Appl...
3	When there are only two classes in a classific...	Multiclass Classification Algorithms in Machin...	Assumptions of Machine Learning Algorithms, Be...
4	The Multinomial Naive Bayes is one of the vari...	Multinomial Naive Bayes in Machine Learning	Assumptions of Machine Learning Algorithms, Me...

كما ترى من الإخراج أعلاه، تمت إضافة عمود جديد إلى مجموعة البيانات التي تحتوي على عناوين جميع المقالات الموصى بها. دعنا الآن نرى جميع التوصيات لمقالة:

```
print(data["Recommended Articles"][22])
```

```
BIRCH Clustering in Machine Learning, Clustering Algorithms in Machine Learning, DBSCAN Clustering in
Machine Learning, K-Means Clustering in Machine Learning
```

يحتوي الفهرس 22 على مقال عن التجميع المتكامل ([agglomerated clustering](#))، وتستند جميع المقالات الموصى بها أيضاً إلى مفاهيم التجميع، لذلك يمكننا القول إن نظام التوصية هذا يمكن أيضاً أن يعطي نتائج رائعة في الوقت الفعلي.

الملخص

هذه هي الطريقة التي يمكنك بها بناء نظام توصية بالمقالات. تستخدم الكثير من مواقع الويب اليوم نظام توصية للتوصية بالمقالات لقراءها. أمل أن تكون قد أحببت هذه المقالة حول كيفية إنشاء نظام توصية بالمقالات باستخدام التعلم الآلي باستخدام بايثون.

18) التنبؤ بالمبيعات المستقبلية مع التعلم الآلي

Future Sales Prediction with Machine Learning

يساعد التنبؤ بالمبيعات المستقبلية (Future Sales Prediction) لمنتج ما الشركة في إدارة تكلفة التصنيع والإعلان للمنتج. هناك العديد من الفوائد للتنبؤ بالمبيعات المستقبلية للمنتج. لذلك إذا كنت تريد أن تتعلم التنبؤ بالمبيعات المستقبلية لمنتج ما باستخدام التعلم الآلي، فهذه المقالة مناسبة لك. في هذه المقالة، سوف آخذك خلال مهمة التنبؤ بالمبيعات المستقبلية من خلال التعلم الآلي باستخدام بايثون.

التنبؤ بالمبيعات المستقبلية (دراسة حالة)

تحتوي مجموعة البيانات الواردة هنا على بيانات حول مبيعات المنتج. تتعلق مجموعة البيانات بتكلفة الإعلان التي يتكبدها النشاط التجاري على منصات إعلانية مختلفة. فيما يلي وصف لجميع الأعمدة في مجموعة البيانات:

1. **TV**: تكلفة الإعلان بالدولار للإعلان على التلفزيون؛
2. **Radio**: تكلفة الإعلان بالدولار للإعلان على الراديو؛
3. **Newspaper**: تكلفة الإعلان التي تنفق بالدولار للإعلان في الجريدة؛
4. **Sales**: عدد الوحدات المباعة؛

لذلك، في مجموعة البيانات أعلاه، تعتمد مبيعات المنتج على تكلفة الإعلان عن المنتج. أمل أن تكون قد فهمت الآن كل شيء عن مجموعة البيانات هذه. الآن في القسم أدناه، سوف آخذك خلال مهمة التنبؤ بالمبيعات المستقبلية باستخدام التعلم الآلي باستخدام بايثون.

التنبؤ بالمبيعات المستقبلية باستخدام بايثون

لنبدأ مهمة التنبؤ بالمبيعات المستقبلية باستخدام التعلم الآلي عن طريق استيراد مكتبات بايثون ومجموعة البيانات الضرورية:

```
import pandas as pd
import numpy as np
from sklearn.model_selection import train_test_split
from sklearn.linear_model import LinearRegression

data =
pd.read_csv("https://raw.githubusercontent.com/amankharwal/Web
site-data/master/advertising.csv")
print(data.head())
```

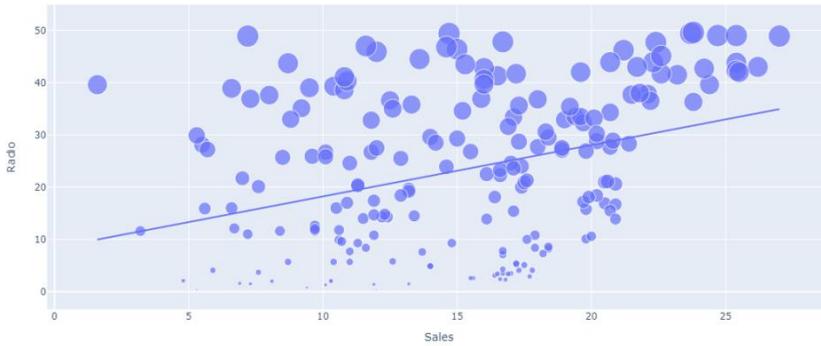
دعونا نلقي نظرة على ما إذا كانت مجموعة البيانات هذه تحتوي على أي قيم فارغة أم لا:

```
print(data.isnull().sum())
```

	TV	Radio	Newspaper	Sales
0	230.1	37.8	69.2	22.1
1	44.5	39.3	45.1	10.4
2	17.2	45.9	69.3	12.0
3	151.5	41.3	58.5	16.5
4	180.8	10.8	58.4	17.9

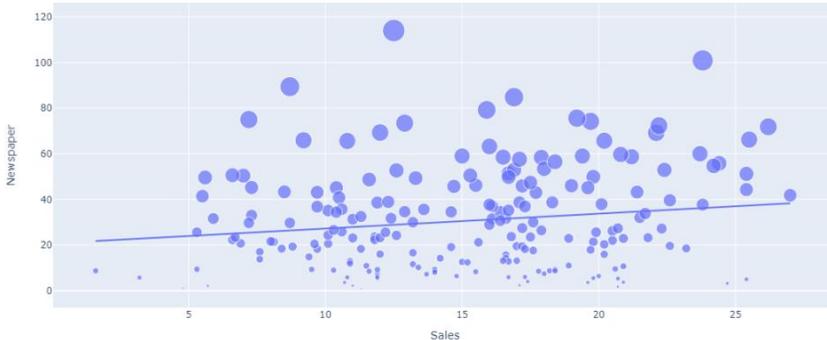
لذلك لا تحتوي مجموعة البيانات هذه على أي قيم فارغة. دعنا الآن نرسم العلاقة بين المبلغ الذي يتم إنفاقه على الإعلان على التلفزيون والوحدات المباعة (units sold):

```
figure = px.scatter(data_frame = data, x="Sales ",
                    y="Newspaper", size="Newspaper",
                    trendline="ols")
figure.show()
```



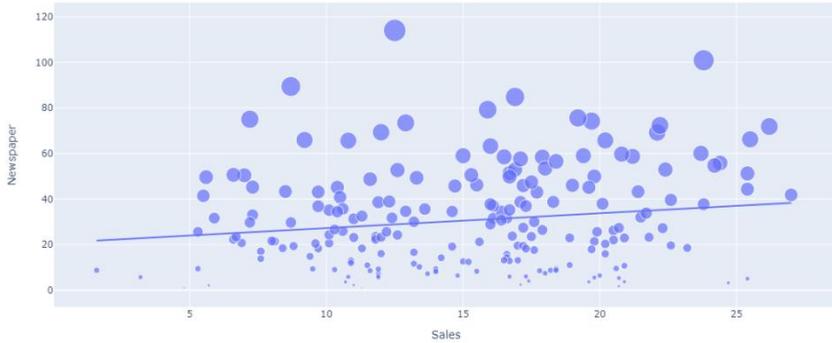
دعنا الآن نرسم العلاقة بين المبلغ الذي يتم إنفاقه على الإعلان على الراديو والوحدات المباعة:

```
figure = px.scatter(data_frame = data, x="Sales ",
                    y="Radio", size="Radio", trendline="ols ")
figure.show()
```



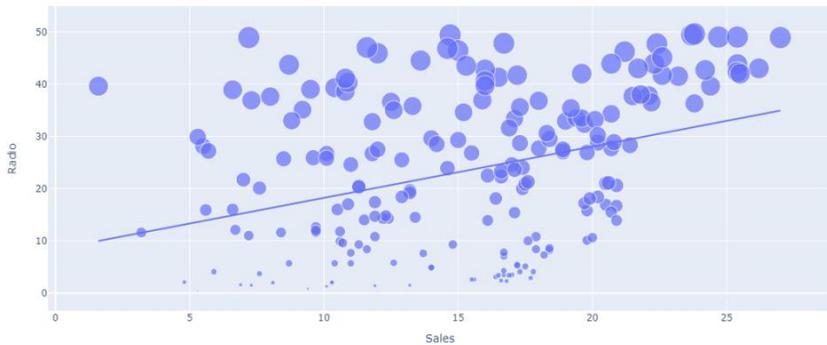
دعنا الآن نرسم العلاقة بين المبلغ الذي يتم إنفاقه على الإعلان في الصحف والوحدات المباعة:

```
figure = px.scatter(data_frame = data, x="Sales ",
                    y="Newspaper", size="Newspaper", trendline="ols ")
figure.show()
```



دعنا الآن نرسم العلاقة بين المبلغ الذي يتم إنفاقه على الإعلان على الراديو والوحدات المباعة:

```
figure = px.scatter(data_frame = data, x="Sales",
                    y="Radio", size="Radio", trendline="ols")
figure.show()
```



من بين كل المبلغ الذي يتم إنفاقه على الإعلان على منصات مختلفة، أستطيع أن أرى أن المبلغ الذي يتم إنفاقه على الإعلان عن المنتج على التلفزيون يؤدي إلى زيادة مبيعات المنتج. دعنا الآن نلقي نظرة على ارتباط جميع الأعمدة بعمود المبيعات:

```
correlation = data.corr()
print (correlation["Sales"].sort_values(ascending=False))
```

```
Sales      1.000000
TV         0.901208
Radio      0.349631
Newspaper  0.157960
Name: Sales, dtype: float64
```

نموذج التنبؤ بالمبيعات المستقبلية

الآن في هذا القسم، سأقوم بتدريب نموذج التعلم الآلي للتنبؤ بالمبيعات المستقبلية للمنتج. ولكن قبل تدريب النموذج، دعنا نقسم البيانات إلى مجموعات تدريب واختبار:

```
x = np.array(data.drop(["Sales"], 1))
y = np.array(data["Sales"])
xtrain, xtest, ytrain, ytest = train_test_split(x, y,
                                                test_size=0.2,
                                                random_state=42)
```

دعنا الآن ندرّب النموذج للتنبؤ بالمبيعات المستقبلية:

```
model = LinearRegression()
model.fit(xtrain, ytrain)
print(model.score(xtest, ytest))
```

دعنا الآن قيم الإدخال في النموذج وفقاً للميزات التي استخدمناها لتدريبه والتنبؤ بعدد وحدات المنتج التي يمكن بيعها بناءً على المبلغ الذي يتم إنفاقه على إعلاناته على منصات مختلفة:

```
#features = [[TV, Radio, Newspaper]]
features = np.array([[69.2, 37.8, 230.1]])
print(model.predict(features))
```

```
[21.37254028]
```

الملخص

هذه هي الطريقة التي يمكننا بها تدريب نموذج التعلم الآلي للتنبؤ بالمبيعات المستقبلية للمنتج. يساعد توقع المبيعات المستقبلية لمنتج ما الشركة في إدارة تكلفة التصنيع والإعلان للمنتج. أمل أن تكون قد أحببت هذه المقالة حول تنبؤات المبيعات المستقبلية باستخدام التعلم الآلي.

19) التنبؤ بسعر سهم Netflix مع التعلم الآلي Netflix Stock Price Prediction with Machine Learning

Netflix هي واحدة من أكثر منصات بث خدمة وسائط فائقة (OTT) شيوعًا. تقدم مجموعة كبيرة من المسلسلات التلفزيونية والأفلام وتمتلك منتجاتها المعروفة باسم Netflix Originals. دائمًا ما يراقب الأشخاص الناشطون للغاية في استثمارات سوق الأوراق المالية شركات مثل Netflix نظرًا لشعبيتها. إذا كنت أحدهم ممن يرغبون في التعرف على كيفية التنبؤ بسعر أسهم Netflix باستخدام التعلم الآلي، فهذه المقالة مناسبة لك. في هذه المقالة، سوف آخذك خلال مهمة توقع أسعار أسهم Netflix باستخدام التعلم الآلي باستخدام بايثون.

التنبؤ بسعر سهم Netflix مع التعلم الآلي

للتنبؤ بأسعار أسهم Netflix مع التعلم الآلي، سأستخدم الشبكة العصبية [LSTM](#) لأنها واحدة من أفضل الطرق لتحليل الانحدار والتنبؤ بالسلسلة الزمنية. لذلك هنا، سأبدأ باستيراد مكتبات بايثون الضرورية وجمع أحدث بيانات أسعار أسهم Netflix:

```
import pandas as pd
import yfinance as yf
import datetime
from datetime import date, timedelta
today = date.today()

d1 = today.strftime("%Y-%m-%d")
end_date = d1
d2 = date.today() - timedelta(days=5000)
d2 = d2.strftime("%Y-%m-%d")
start_date = d2

data = yf.download('NFLX',
                  start=start_date,
                  end=end_date,
                  progress=False)
data["Date"] = data.index
data = data[["Date", "Open", "High", "Low", "Close", "Adj
Close", "Volume"]]
data.reset_index(drop=True, inplace=True)
print(data.tail())
```

	Date	Open	High	...	Close	Adj Close	Volume
3442	2022-02-01	432.959991	458.480011	...	457.130005	457.130005	22568100
3443	2022-02-02	448.250000	451.980011	...	429.480011	429.480011	14346000
3444	2022-02-03	421.440002	429.260010	...	405.600006	405.600006	9905200
3445	2022-02-04	407.309998	412.769989	...	410.170013	410.170013	7782400
3446	2022-02-07	410.170013	412.350006	...	402.100006	402.100006	8228000

[5 rows x 7 columns]

يتم جمع مجموعة البيانات أعلاه باستخدام API في finance بايثون. يمكنك معرفة المزيد عنها من [هنا](#). الآن دعنا نرسم بيانات أسعار الأسهم في Netflix باستخدام مخطط الشموع ([candlestick chart](#)) لأنه يعطي صورة واضحة عن الزيادة والنقصان في أسعار الأسهم:

```
import plotly.graph_objects as go
figure = go.Figure(data=[go.Candlestick(x=data["Date", [
    open=data["Open"],
    high=data["High"],
    low=data["Low"],
    close=data["Close"]]])
figure.update_layout(title = "Netflix Stock Price Analysis",
    xaxis_rangeslider_visible=False)
figure.show()
```

Netflix Stock Price Analysis



دعنا الآن نلقي نظرة على ارتباط ([correlation](#)) جميع الأعمدة بعمود الإغلاق ([Close](#) column):

```
correlation = data.corr()
print(correlation["Close"].sort_values(ascending=False))
```

```
Close      1.000000
Adj Close  1.000000
High       0.999837
Low        0.999831
Open       0.999643
Volume     -0.395022
Name: Close, dtype: float64
```

تدريب LSTM على التنبؤ بسعر سهم Netflix

سأقوم الآن بتدريب نموذج الشبكة العصبية LSTM لمهمة توقع أسعار سهم Netflix باستخدام بايثون. سأقوم هنا أولاً بتقسيم البيانات إلى مجموعات تدريب واختبار:

```
x = data[["Open", "High", "Low", "Volume"]]
y = data["Close"]
x = x.to_numpy()
y = y.to_numpy()
```

```

y = y.reshape(1,-1)

from sklearn.model_selection import train_test_split
xtrain, xtest, ytrain, ytest = train_test_split(x, y,
                                              test_size=0.2,
                                              random_state=42)

```

الآن سأقوم بإعداد هيكل الشبكة العصبية LSTM :

```

from keras.models import Sequential
from keras.layers import Dense, LSTM
model = Sequential()
model.add(LSTM(128, return_sequences=True, input_shape=
(xtrain.shape[1], 1)))
model.add(LSTM(64, return_sequences=False))
model.add(Dense(25))
model.add(Dense(1))
model.summary()

```

Model: "sequential"

Layer (type)	Output Shape	Param #
lstm (LSTM)	(None, 4, 128)	66560
lstm_1 (LSTM)	(None, 64)	49408
dense (Dense)	(None, 25)	1625
dense_1 (Dense)	(None, 1)	26

```

Total params: 117,619
Trainable params: 117,619
Non-trainable params: 0

```

الآن إليك كيف يمكننا تدريب نموذج شبكة عصبية LSTM للتنبؤ بأسعار سهم Netflix باستخدام بايثون:

```

model.compile(optimizer='adam', loss='mean_squared_error')
model.fit(xtrain, ytrain, batch_size=1, epochs=30)

```

```

Epoch 1/30
2757/2757 [=====] - 26s 8ms/step - loss: 7604.0146
Epoch 2/30
2757/2757 [=====] - 21s 8ms/step - loss: 631.5478
Epoch 3/30
2757/2757 [=====] - 21s 8ms/step - loss: 464.4248
Epoch 4/30
2757/2757 [=====] - 21s 8ms/step - loss: 372.2728
Epoch 5/30
2757/2757 [=====] - 23s 8ms/step - loss: 393.3465

```

```

Epoch 6/30
2757/2757 [=====] - 23s 8ms/step - loss: 388.6576
Epoch 7/30
2757/2757 [=====] - 24s 9ms/step - loss: 256.3762
Epoch 8/30
2757/2757 [=====] - 24s 9ms/step - loss: 233.4001
Epoch 9/30
2757/2757 [=====] - 24s 9ms/step - loss: 277.1848
Epoch 10/30
2757/2757 [=====] - 24s 9ms/step - loss: 271.6196
Epoch 11/30
2757/2757 [=====] - 21s 8ms/step - loss: 314.4778
Epoch 12/30
2757/2757 [=====] - 22s 8ms/step - loss: 310.0940
Epoch 13/30
2757/2757 [=====] - 22s 8ms/step - loss: 230.9971
Epoch 14/30
2757/2757 [=====] - 22s 8ms/step - loss: 320.0016
Epoch 15/30
2757/2757 [=====] - 21s 8ms/step - loss: 266.8751
Epoch 16/30
2757/2757 [=====] - 22s 8ms/step - loss: 184.3275
Epoch 17/30
2757/2757 [=====] - 23s 8ms/step - loss: 187.5371
Epoch 18/30
2757/2757 [=====] - 23s 8ms/step - loss: 262.0464
Epoch 19/30
2757/2757 [=====] - 23s 9ms/step - loss: 124.5728
Epoch 20/30
2757/2757 [=====] - 22s 8ms/step - loss: 235.3674
Epoch 21/30
2757/2757 [=====] - 22s 8ms/step - loss: 210.1229
Epoch 22/30
2757/2757 [=====] - 22s 8ms/step - loss: 149.8269
Epoch 23/30
2757/2757 [=====] - 22s 8ms/step - loss: 137.0508
Epoch 24/30
2757/2757 [=====] - 22s 8ms/step - loss: 182.6988
Epoch 25/30
2757/2757 [=====] - 22s 8ms/step - loss: 139.5222
Epoch 26/30
2757/2757 [=====] - 23s 8ms/step - loss: 174.5475
Epoch 27/30
2757/2757 [=====] - 23s 9ms/step - loss: 139.0385
Epoch 28/30
2757/2757 [=====] - 23s 8ms/step - loss: 135.3190
Epoch 29/30
2757/2757 [=====] - 21s 8ms/step - loss: 122.6136
Epoch 30/30
2757/2757 [=====] - 21s 8ms/step - loss: 182.0294
<keras.callbacks.History at 0x7f0057f21790>

```

الآن دعنا نختبر النموذج من خلال إعطاء المدخلات وفقاً للميزات التي استخدمناها لتدريب هذا النموذج للتنبؤ بالنتائج النهائية :

```

import numpy as np
#features = [Open, High, Low, Adj Close, Volume]

```

```
features = np.array([[ ,398.200012 ,427.700012 ,401.970001  
20047500]])  
model.predict(features)
```

```
array([[408.57364]], dtype=float32)
```

هذه هي الطريقة التي يمكننا بها تدريب نموذج شبكة عصبية LSTM لمهمة للتنبؤ بأسعار أسهم Netflix مع التعلم الآلي باستخدام بايثون.

الملخص

هذه هي الطريقة التي يمكننا بها استخدام التعلم الآلي للتنبؤ بأسعار أسهم Netflix. Netflix هي واحدة من أكثر منصات بث OTT شيوعًا. دائمًا ما يراقب الأشخاص الناشطون للغاية في استثمارات سوق الأوراق المالية شركات مثل Netflix نظرًا لشعبيتها. آمل أن تكون قد أحببت هذه المقالة حول مهمة توقع أسعار أسهم Netflix مع التعلم الآلي باستخدام بايثون.

20) اكتشاف الاجهاد باستخدام التعلم الآلي Stress Detection with Machine Learning

يهدد الاجهاد (Stress) والقلق (anxiety) والاكتئاب (depression) الصحة العقلية (mental health) للناس. كل شخص لديه سبب لعيش حياة مرهقة. غالبًا ما يشارك الأشخاص مشاعرهم على منصات التواصل الاجتماعي مثل Instagram في شكل منشورات وقصص، وعلى Reddit في شكل طلب اقتراحات حول حياتهم على subreddits. في السنوات القليلة الماضية، تقدم العديد من منشئي المحتوى لإنشاء محتوى لمساعدة الأشخاص في صحتهم العقلية. يمكن للعديد من المنظمات استخدام الكشف عن الإجهاد للعثور على مستخدمي الوسائط الاجتماعية الذين يتم الضغط عليهم لمساعدتهم بسرعة. لذلك إذا كنت تريد معرفة كيفية استخدام التعلم الآلي لاكتشاف الضغط على منشورات وسائل التواصل الاجتماعي، فهذه المقالة مناسبة لك. في هذه المقالة، سوف آخذك خلال مهمة الكشف عن الاجهاد باستخدام التعلم الآلي باستخدام بايثون.

اكتشاف الاجهاد باستخدام التعلم الآلي

يعد اكتشاف الاجهاد مهمة صعبة، حيث يوجد الكثير من الكلمات التي يمكن أن يستخدمها الأشخاص في مشاركاتهم والتي يمكن أن توضح ما إذا كان الشخص يعاني من ضغوط نفسية أم لا. أثناء البحث عن مجموعات البيانات التي يمكنني استخدامها لتدريب نموذج التعلم الآلي للكشف عن الإجهاد، وجدت مجموعة بيانات على Kaggle تحتوي على 116 عمودًا. نحتاج فقط إلى استخدام عمود النص (text) والتسمية (label) لهذه المهمة.

تحتوي مجموعة البيانات التي أستخدمها لهذه المهمة على بيانات منشورة على subreddits تتعلق بالصحة العقلية. تحتوي مجموعة البيانات هذه على العديد من مشكلات الصحة العقلية التي يشاركها الأشخاص في حياتهم. لحسن الحظ، تم تصنيف مجموعة البيانات هذه على أنها 0 و 1، حيث يشير 0 إلى عدم وجود إجهاد و 1 يشير إلى الإجهاد. لذلك في القسم أدناه، سوف آخذك خلال مهمة الكشف عن التوتر في منشورات وسائل التواصل الاجتماعي باستخدام بايثون.

اكتشاف الإجهاد باستخدام بايثون

لنبدأ الآن مهمة اكتشاف الإجهاد باستخدام التعلم الآلي. سأبدأ هذه المهمة عن طريق استيراد مكتبات بايثون الضرورية ومجموعة البيانات التي نحتاجها لهذه المهمة:

```
import pandas as pd
import numpy as np
data = pd.read_csv("stress.csv")
print(data.head())
```

```

      subreddit post_id ... syntax_fk_grade sentiment
0          ptsd  8601tu ...      3.253573 -0.002742
1  assistance  81brx9 ...      8.828316  0.292857
2          ptsd  9ch1zh ...      7.841667  0.011894
3  relationships 7rorpp ...      4.104027  0.141671
4  survivorsofabuse 9p2gbc ...      7.910952 -0.204167

[5 rows x 116 columns]

```

دعونا نلقي نظرة على ما إذا كانت مجموعة البيانات هذه تحتوي على أي قيم فارغة أم لا:

```
print(data.isnull().sum())
```

```

subreddit          0
post_id            0
sentence_range     0
text               0
id                 0
..
lex_dal_avg_pleasantness  0
social_upvote_ratio  0
social_num_comments  0
syntax_fk_grade     0
sentiment           0
Length: 116, dtype: int64

```

لذلك لا تحتوي مجموعة البيانات هذه على أي قيم فارغة. دعنا الآن نجهز عمود النصي لمجموعة البيانات هذه لتنظيف عمود النص بكلمات التوقف (**stopwords**) والروابط والرموز الخاصة وأخطاء اللغة:

```

import nltk
import re
nltk.download('stopwords')
stemmer = nltk.SnowballStemmer("english")
from nltk.corpus import stopwords
import string
stopword=set(stopwords.words('english'))

def clean(text):
    text = str(text).lower()
    text = re.sub('\[.*?\]', '', text)
    text = re.sub('https?://\S+|www\.\S+', '', text)
    text = re.sub('<.*?>+', '', text)
    text = re.sub('[%s]' % re.escape(string.punctuation), '',
text)
    text = re.sub('\n', '', text)
    text = re.sub('\w*\d\w*', '', text)
    text = [word for word in text.split(' ') if word not in
stopword]
    text=" ".join(text)

```



```
print(data.head())
```

	text	label
0	said felt way suggest go rest trigger ahead you...	Stress
1	hey rassist sure right place post goe im curr...	No Stress
2	mom hit newspaper shock would know dont like pla...	Stress
3	met new boyfriend amaz kind sweet good student...	Stress
4	octob domest violenc awar month domest violenc...	Stress

الآن سأقسم مجموعة البيانات هذه إلى مجموعات تدريب واختبار:

```
from sklearn.feature_extraction.text import CountVectorizer
from sklearn.model_selection import train_test_split
```

```
x = np.array(data["text"])
y = np.array(data["label"])
```

```
cv = CountVectorizer()
X = cv.fit_transform(x)
xtrain, xtest, ytrain, ytest = train_test_split(X, y,
                                                test_size=0.33,
                                                random_state=42)
```

نظرًا لأن هذه المهمة تستند إلى مشكلة التصنيف الثنائي (binary classification)، فسوف أستخدم خوارزمية **Bernoulli Naive Bayes**، والتي تعد واحدة من أفضل الخوارزميات لمشاكل التصنيف الثنائي. لذلك دعونا ندرّب على نموذج الكشف عن الاجهاد:

```
from sklearn.naive_bayes import BernoulliNB
model = BernoulliNB()
model.fit(xtrain, ytrain)
```

دعنا الآن نختبر أداء نموذجنا على بعض الجمل العشوائية بناءً على الصحة العقلية:

```
user = input("Enter a Text: ")
data = cv.transform([user]).toarray()
output = model.predict(data)
print(output)
```

```
Enter a Text: People need to take care of their mental health
['No Stress']
```

```
user = input("Enter a Text: ")
data = cv.transform([user]).toarray()
output = model.predict(data)
print(output)
```

```
Enter a Text: Sometime I feel like I need some help
['Stress']
```

كما ترون، يمكننا أن نرى نتائج جيدة من نموذج التعلم الآلي الخاص بنا. هذه هي الطريقة التي يمكنك بها تدريب نموذج كشف الإجهاد لاكتشاف الاجهاد من منشورات وسائل التواصل الاجتماعي. يمكن تحسين نموذج التعلم الآلي هذا عن طريق تزويده بمزيد من البيانات.

الملخص

هذه هي الطريقة التي يمكنك بها تدريب نموذج التعلم الآلي لاكتشاف الإجهاد من منشورات وسائل التواصل الاجتماعي. غالبًا ما يشارك الناس مشاعرهم على منصات التواصل الاجتماعي. يمكن للعديد من المنظمات استخدام الكشف عن الإجهاد للعثور على مستخدمي الوسائط الاجتماعية الذين يتم الضغط عليهم لمساعدتهم بسرعة. أمل أن تكون قد أحببت هذه المقالة حول اكتشاف الإجهاد باستخدام التعلم الآلي باستخدام بايثون.

21) التنبؤ بالطلب على المنتج باستخدام التعلم الآلي Product Demand Prediction with Machine Learning

يجب أن تكون قد درست أن الطلب على المنتج (demand for a product) يختلف باختلاف سعره. إذا أخذت أمثلة من العالم الحقيقي، فستري ما إذا كان المنتج ليس ضرورة، ثم يتناقص الطلب مع زيادة سعره ويزداد الطلب مع انخفاض سعره. إذا كنت تريد معرفة كيف يمكننا التنبؤ بالطلب على منتج باستخدام التعلم الآلي، فهذه المقالة مناسبة لك. في هذه المقالة، سوف أطلعك على مهمة التنبؤ بالطلب على المنتج باستخدام التعلم الآلي باستخدام بايثون.

التنبؤ بالطلب على المنتج (دراسة حالة)

تخطط شركة منتج لتقديم خصومات على منتجاتها خلال موسم العطلات القادم. تريد الشركة العثور على السعر الذي يمكن أن يكون فيه منتجها صفقة أفضل مقارنة بمنافسيها. بالنسبة لهذه المهمة، قدمت الشركة مجموعة بيانات بالتغييرات السابقة في المبيعات بناءً على تغيرات الأسعار. تحتاج إلى تدريب نموذج يمكنه التنبؤ بالطلب على المنتج في السوق بشرائح أسعار مختلفة.

تحتوي مجموعة البيانات التي لدينا لهذه المهمة على بيانات حول:

1. معرف المنتج (the product id)؛
2. معرف المتجر (store id).
3. السعر الإجمالي (total price) الذي تم بيع المنتج به؛
4. السعر الأساسي (base price) الذي تم بيع المنتج به؛
5. الوحدات المباعة (Units sold) (الكمية المطلوبة)؛

أمل أن تفهم الآن نوع بيانات المشكلة التي ستحصل عليها لمهمة التنبؤ بالطلب على المنتج. في القسم أدناه، سوف أطلعك على التنبؤ بالطلب على المنتج باستخدام التعلم الآلي باستخدام بايثون.

التنبؤ بالطلب على المنتج باستخدام بايثون

لنبدأ باستيراد مكتبات بايثون الضرورية ومجموعة البيانات التي نحتاجها لمهمة التنبؤ بالطلب على المنتج:

```
import pandas as pd
```

```
import numpy as np
import plotly.express as px
import seaborn as sns
import matplotlib.pyplot as plt
from sklearn.model_selection import train_test_split
from sklearn.tree import DecisionTreeRegressor

data =
pd.read_csv("https://raw.githubusercontent.com/amankharwal/Web
site-data/master/demand.csv")
data.head()
```

	ID	Store ID	Total Price	Base Price	Units Sold
0	1	8091	99.0375	111.8625	20
1	2	8091	99.0375	99.0375	28
2	3	8091	133.9500	133.9500	19
3	4	8091	133.9500	133.9500	44
4	5	8091	141.0750	141.0750	52

دعنا الآن نلقي نظرة على ما إذا كانت مجموعة البيانات هذه تحتوي على أي قيم فارغة أم لا:

```
data.isnull().sum()
```

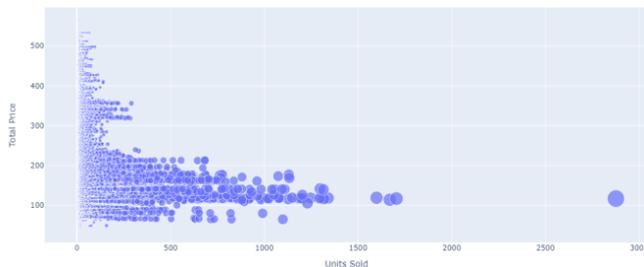
```
ID          0
Store ID    0
Total Price 1
Base Price  0
Units Sold  0
dtype: int64
```

لذلك، تحتوي مجموعة البيانات على قيمة واحدة مفقودة فقط في عمود السعر الإجمالي (Total Price)، سأقوم بإزالة هذا الصف بالكامل في الوقت الحالي:

```
data = data.dropna()
```

دعونا الآن نحلل العلاقة بين السعر والطلب على المنتج. سأستخدم هنا مخطط مبعثر (scatter plot) لمعرفة كيف يختلف الطلب على المنتج مع تغير السعر:

```
fig = px.scatter(data, x="Units Sold", y="Total Price,"
                 size='Units Sold ')
fig.show()
```



يمكننا أن نرى أن معظم نقاط البيانات تظهر أن مبيعات المنتج تزايدت حيث أن السعر يتناقص مع بعض الاستثناءات. دعنا الآن نلقي نظرة على الارتباط (**correlation**) بين ميزات مجموعة البيانات:

```
print(data.corr())
```

	ID	Store ID	Total Price	Base Price	Units Sold
ID	1.000000	0.007464	0.008473	0.018932	-0.010616
Store ID	0.007464	1.000000	-0.038315	-0.038848	-0.004372
Total Price	0.008473	-0.038315	1.000000	0.958885	-0.235625
Base Price	0.018932	-0.038848	0.958885	1.000000	-0.140032
Units Sold	-0.010616	-0.004372	-0.235625	-0.140032	1.000000

```
correlations = data.corr(method='pearson')
plt.figure(figsize=(15, 12))
sns.heatmap(correlations, cmap="coolwarm", annot=True)
plt.show()
```



نموذج التنبؤ بالطلب على المنتج

دعنا الآن ننتقل إلى مهمة تدريب نموذج التعلم الآلي للتنبؤ بالطلب على المنتج بأسعار مختلفة. سأختار عمود السعر الإجمالي (**Total Price**) والسعر الأساسي (**Base Price**) كميزات لتدريب النموذج، وعمود الوحدات المباعة (**Units sold**) كعناوين للنموذج:

```
x = data[["Total Price", "Base Price"]]
y = data["Units Sold"]
```

دعنا الآن نقسم البيانات إلى مجموعات تدريب واختبار ونستخدم خوارزمية انحدار شجرة القرار (**decision tree regression**) لتدريب نموذجنا:

```
xtrain, xtest, ytrain, ytest = train_test_split(x, y,
                                                test_size=0.2,
                                                random_state=42)
from sklearn.tree import DecisionTreeRegressor
```

```
model = DecisionTreeRegressor()
model.fit(xtrain, ytrain)
```

الآن دعنا ندخل الميزات (السعر الإجمالي، السعر الأساسي) في النموذج ونتوقع الكمية التي يمكن طلبها بناءً على هذه القيم:

```
#features = [["Total Price", "Base Price"]]
features = np.array([[140.00, 133.00]])
model.predict(features)
```

```
array([27.])
```

الملخص

هذه هي الطريقة التي يمكنك بها تدريب نموذج التعلم الآلي لمهمة التنبؤ بالطلب على المنتج باستخدام بايثون. السعر هو أحد العوامل الرئيسية التي تؤثر على الطلب على المنتج. إذا لم يكن المنتج ضروريًا، فإن قلة من الناس فقط هم من يشترون المنتج حتى لو ارتفع السعر. أمل أن تكون قد أحببت هذه المقالة حول التنبؤ بالطلب على المنتج من خلال التعلم الآلي باستخدام بايثون.

22) التنبؤ بأسعار الكهرباء مع التعلم الآلي Electricity Price Prediction with Machine Learning

يعتمد سعر الكهرباء (Electricity Price) على عدة عوامل. يساعد التنبؤ بسعر الكهرباء العديد من الشركات على فهم مقدار الكهرباء التي يتعين عليهم دفعها كل عام. تعتمد مهمة التنبؤ بأسعار الكهرباء على دراسة حالة تحتاج فيها إلى توقع السعر اليومي للكهرباء بناءً على الاستهلاك اليومي للألات الثقيلة التي تستخدمها الشركات. لذلك إذا كنت تريد معرفة كيفية التنبؤ بسعر الكهرباء، فهذه المقالة مناسبة لك. في هذه المقالة، سوف أطلعك على مهمة التنبؤ بأسعار الكهرباء مع التعلم الآلي باستخدام بايثون.

التنبؤ بأسعار الكهرباء (دراسة حالة)

افترض أن عملك يعتمد على خدمات الحوسبة حيث تختلف الطاقة التي تستهلكها أجهزتك على مدار اليوم. لا تعرف التكلفة الفعلية للكهرباء التي تستهلكها الآلات على مدار اليوم، لكن المنظمة زودتك ببيانات تاريخية عن سعر الكهرباء التي تستهلكها الآلات. فيما يلي معلومات البيانات المتوفرة لدينا لمهمة التنبؤ بأسعار الكهرباء:

1. **DateTime**: تاريخ ووقت السجل.
2. **Holiday**: يحتوي على اسم العطلة إذا كان اليوم عطلة وطنية.
3. **HolidayFlag**: يحتوي على 1 إذا كانت عطلة البنوك وإلا 0.
4. **DayOfWeek**: يحتوي على قيم بين 0-6 حيث يكون 0 هو يوم الإثنين.
5. **WeekOfYear**: أسبوع من السنة.
6. **Day**: يوم التاريخ.
7. **Month**: شهر التاريخ.
8. **Year**: سنة التاريخ.
9. **PeriodOfDay**: فترة نصف ساعة من اليوم.
10. **ForecastWindProduction**: توقعات إنتاج الرياح.
11. **SystemLoadEA**: توقع الحمل الوطني المتوقع.
12. **SMPEA**: السعر المتوقع.
13. **ORKTemperature**: قياس درجة الحرارة الفعلية.
14. **ORKWindspeed**: قياس سرعة الرياح الفعلية.
15. **CO2Intensity**: الكثافة الفعلية لثاني أكسيد الكربون للكهرباء المنتجة.
16. **ActualWindProduction**: إنتاج طاقة الرياح الفعلي.
17. **SystemLoadEP2**: الحمل الفعلي للنظام الوطني.
18. **SMPEP2**: السعر الفعلي للكهرباء المستهلكة (علامات أو قيم يمكن توقعها).

لذا فإن مهمتك هنا هي استخدام هذه البيانات لتدريب نموذج التعلم الآلي للتنبؤ بسعر الكهرباء التي تستهلكها الآلات. في القسم أدناه، سأطلعك على مهمة التنبؤ بأسعار الكهرباء باستخدام التعلم الآلي باستخدام بايثون.

التنبؤ بأسعار الكهرباء باستخدام لغة بايثون

سأبدأ مهمة التنبؤ بأسعار الكهرباء عن طريق استيراد مكتبات بايثون الضرورية ومجموعة البيانات التي نحتاجها لهذه المهمة:

```
import pandas as pd
import numpy as np
data =
pd.read_csv("https://raw.githubusercontent.com/amankharwal/Website-
data/master/electricity.csv")
print(data.head())
```

```
      DateTime Holiday ... SystemLoadEP2 SMPEP2
0  01/11/2011 00:00  None ...      3159.60  54.32
1  01/11/2011 00:30  None ...      2973.01  54.23
2  01/11/2011 01:00  None ...      2834.00  54.23
3  01/11/2011 01:30  None ...      2725.99  53.47
4  01/11/2011 02:00  None ...      2655.64  39.87
```

[5 rows x 18 columns]

دعونا نلقي نظرة على جميع أعمدة مجموعة البيانات هذه:

```
data.info()
```

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 38014 entries, 0 to 38013
Data columns (total 18 columns):
#   Column                                Non-Null Count  Dtype
---  -
0   DateTime                              38014 non-null  object
1   Holiday                               38014 non-null  object
2   HolidayFlag                           38014 non-null  int64
3   DayOfWeek                             38014 non-null  int64
4   WeekOfYear                            38014 non-null  int64
5   Day                                    38014 non-null  int64
6   Month                                 38014 non-null  int64
7   Year                                  38014 non-null  int64
8   PeriodOfDay                           38014 non-null  int64
9   ForecastWindProduction                38014 non-null  object
10  SystemLoadEA                           38014 non-null  object
11  SMPEA                                  38014 non-null  object
12  ORKTemperature                         38014 non-null  object
13  ORKWindspeed                           38014 non-null  object
14  CO2Intensity                           38014 non-null  object
15  ActualWindProduction                   38014 non-null  object
16  SystemLoadEP2                          38014 non-null  object
17  SMPEP2                                  38014 non-null  object
dtypes: int64(7), object(11)
memory usage: 5.2+ MB
```

أستطيع أن أرى أن العديد من الميزات ذات القيم العددية هي قيم سلسلة في مجموعة البيانات وليست أعدادًا صحيحة أو قيمًا عائمة. لذا قبل المضي قدمًا، يتعين علينا تحويل قيم السلسلة النصية هذه إلى قيم عائمة float values:

```
data["ForecastWindProduction"] =
pd.to_numeric(data["ForecastWindProduction"], errors= 'coerce')
data["SystemLoadEA"] = pd.to_numeric(data["SystemLoadEA"], errors=
'coerce')
data["SMPEA"] = pd.to_numeric(data["SMPEA"], errors= 'coerce')
data["ORKTemperature"] = pd.to_numeric(data["ORKTemperature"], errors=
'coerce')
data["ORKWindspeed"] = pd.to_numeric(data["ORKWindspeed"], errors=
'coerce')
data["CO2Intensity"] = pd.to_numeric(data["CO2Intensity"], errors=
'coerce')
data["ActualWindProduction"] =
pd.to_numeric(data["ActualWindProduction"], errors= 'coerce')
data["SystemLoadEP2"] = pd.to_numeric(data["SystemLoadEP2"], errors=
'coerce')
data["SMPEP2"] = pd.to_numeric(data["SMPEP2"], errors= 'coerce')
```

دعنا الآن نلقي نظرة على ما إذا كانت مجموعة البيانات هذه تحتوي على أي قيم فارغة أم لا:

```
data.isnull().sum()
```

```
DateTime          0
Holiday           0
HolidayFlag       0
DayOfWeek         0
WeekOfYear        0
Day               0
Month             0
Year              0
PeriodOfDay       0
ForecastWindProduction    5
SystemLoadEA           2
SMPEA                 2
ORKTemperature         295
ORKWindspeed          299
CO2Intensity           7
ActualWindProduction    5
SystemLoadEP2          2
SMPEP2                2
dtype: int64
```

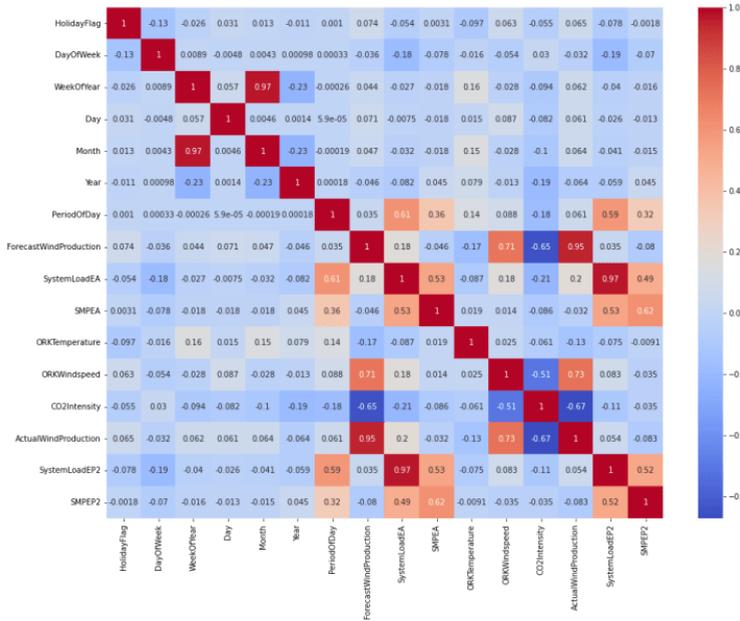
لذلك هناك بعض الأعمدة التي تحتوي على قيم خالية، سأقوم بإسقاط كل هذه الصفوف التي تحتوي على قيم خالية من مجموعة البيانات:

```
data = data.dropna()
```

دعنا الآن نلقي نظرة على الارتباط بين جميع الأعمدة في مجموعة البيانات:

```
import seaborn as sns
import matplotlib.pyplot as plt
correlations = data.corr(method='pearson')
plt.figure(figsize=(16, 12))
```

```
sns.heatmap(correlations, cmap="coolwarm", annot=True)
plt.show()
```



نموذج التنبؤ بأسعار الكهرباء

دعنا الآن ننقل إلى مهمة تدريب نموذج توقع أسعار الكهرباء. سأضيف هنا أولاً جميع الميزات المهمة إلى x والعمود المستهدف إلى y ، وبعد ذلك سأقسم البيانات إلى مجموعات تدريب واختبار:

```
x = data[["Day", "Month", "ForecastWindProduction", "SystemLoadEA",
          "SMPEA", "ORKTemperature", "ORKWindSpeed", "CO2Intensity",
          "ActualWindProduction", "SystemLoadEP2"]]
y = data["SMPEP2"]
from sklearn.model_selection import train_test_split
xtrain, xtest, ytrain, ytest = train_test_split(x, y,
                                                test_size=0.2,
                                                random_state=42)
```

نظراً لأن هذه هي مشكلة الانحدار، سأختار هنا خوارزمية الغابة العشوائية (Random Forest) لتدريب نموذج التنبؤ بسعر الكهرباء:

```
from sklearn.ensemble import RandomForestRegressor
model = RandomForestRegressor()
model.fit(xtrain, ytrain)
```

```
RandomForestRegressor(bootstrap=True, ccp_alpha=0.0, criterion='mse',
                      max_depth=None, max_features='auto', max_leaf_nodes=None,
                      max_samples=None, min_impurity_decrease=0.0,
                      min_impurity_split=None, min_samples_leaf=1,
                      min_samples_split=2, min_weight_fraction_leaf=0.0,
                      n_estimators=100, n_jobs=None, oob_score=False,
                      random_state=None, verbose=0, warm_start=False)
```

دعنا الآن ندخل جميع قيم الميزات الضرورية التي استخدمناها لتدريب النموذج وإلقاء نظرة على سعر الكهرباء الذي تنبأ به النموذج:

```
#features = [{"Day", "Month", "ForecastWindProduction",
"SystemLoadEA", "SMPEA", "ORKTemperature", "ORKWindspeed",
"CO2Intensity", "ActualWindProduction", "SystemLoadEP2"}]
features = np.array([14.8, 9.0, 49.56, 4241.05, 54.10, 12, 10])
([[4426.84, 54.0, 491.32
model.predict(features)
```

```
array([65.1696])
```

هذه هي الطريقة التي يمكنك بها تدريب نموذج التعلم الآلي للتنبؤ بأسعار الكهرباء.

الملخص

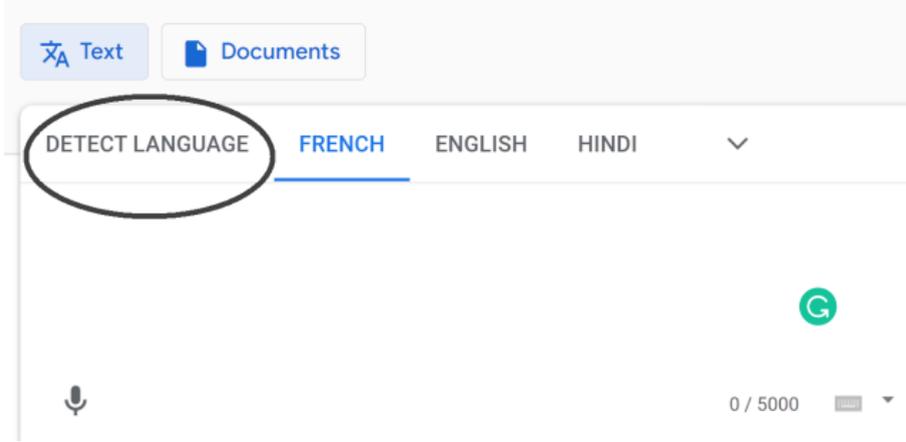
يساعد توقع سعر الكهرباء الكثير من الشركات على فهم مقدار نفقات الكهرباء التي يتعين عليهم دفعها كل عام. أمل أن تكون قد أحببت هذه المقالة حول مهمة التنبؤ بأسعار الكهرباء مع التعلم الآلي باستخدام بايثون.

23) اكتشاف اللغة باستخدام التعلم الآلي Language Detection with Machine Learning

يعد اكتشاف اللغة (Language detection) مهمة معالجة لغة طبيعية (natural language processing) حيث نحتاج إلى تحديد لغة النص أو المستند. كان استخدام التعلم الآلي لتحديد اللغة مهمة صعبة منذ بضع سنوات لأنه لم يكن هناك الكثير من البيانات حول اللغات، ولكن مع توفر البيانات بسهولة، تتوفر بالفعل العديد من نماذج التعلم الآلي القوية لتحديد اللغة. لذا، إذا كنت تريد معرفة كيفية تدريب نموذج التعلم الآلي على اكتشاف اللغة، فهذه المقالة مناسبة لك. في هذه المقالة، سوف أطلعك على مهمة اكتشاف اللغة باستخدام التعلم الآلي باستخدام بايثون.

اكتشاف اللغة

كإنسان، يمكنك بسهولة اكتشاف اللغات التي تعرفها. على سبيل المثال، يمكنك التعرف بسهولة على الهندية والإنجليزية، لكن كوني هندياً، لا يمكنك أيضاً تحديد جميع اللغات الهندية. هذا هو المكان الذي يمكن فيه استخدام مهمة تحديد اللغة. يعد Google Translate أحد أشهر مترجمي اللغات في العالم ويستخدمه الكثير من الأشخاص حول العالم. يتضمن أيضاً نموذجاً للتعلم الآلي لاكتشاف اللغات التي يمكنك استخدامها إذا كنت لا تعرف اللغة التي تريد ترجمتها.



البيانات (Data) هي أهم جزء في تدريب نموذج الكشف عن اللغة. كلما زادت البيانات المتوفرة لديك حول كل لغة، زادت دقة أداء نموذجك في الوقت الفعلي. تم جمع مجموعة البيانات التي أستخدمها من Kaggle، والتي تحتوي على بيانات حول 22 لغة شائعة وتحتوي على 1000 جملة في كل لغة، لذلك ستكون مجموعة بيانات مناسبة لتدريب نموذج اكتشاف اللغة باستخدام التعلم الآلي. لذلك في القسم أدناه، سأطلعك على كيفية تدريب نموذج اكتشاف اللغة باستخدام التعلم الآلي باستخدام بايثون.

اكتشاف اللغة باستخدام بايثون

لنبدأ مهمة اكتشاف اللغة باستخدام التعلم الآلي عن طريق استيراد مكتبات بايثون ومجموعة البيانات الضرورية:

```
import pandas as pd
import numpy as np
from sklearn.feature_extraction.text import CountVectorizer
from sklearn.model_selection import train_test_split
from sklearn.naive_bayes import MultinomialNB
data =
pd.read_csv("https://raw.githubusercontent.com/amankharwal/Web
site-data/master/dataset.csv")
print(data.head())
```

```
      Text language
0 klement gottwaldi surnukeha palsameeriti ning ... Estonian
1 sebes joseph pereira thomas på eng the jesuit... Swedish
2 கனயசரீஷ்கரங் கர்மசர்லாய்மன் thanon charoen krung l... Thai
3 விசாகப்பட்டினம் தமிழ்ச்சங்கத்தை இந்துப் பத்திர... Tamil
4 de spons behoort tot het geslacht haliclona en... Dutch
```

دعونا نلقي نظرة على ما إذا كانت مجموعة البيانات هذه تحتوي على أي قيم فارغة أم لا:

```
data.isnull().sum()
```

```
Text      0
language  0
dtype: int64
```

دعنا الآن نلقي نظرة على جميع اللغات الموجودة في مجموعة البيانات هذه:

```
data["language"].value_counts()
```

```
Persian      1000
Korean       1000
Indonesian   1000
Dutch        1000
Estonian     1000
Hindi        1000
Urdu         1000
French       1000
Turkish      1000
Latin        1000
Arabic       1000
Russian      1000
Thai         1000
Spanish      1000
English      1000
Japanese    1000
Pushhto     1000
Chinese     1000
Tamil       1000
Swedish     1000
Romanian    1000
Portugese   1000
Name: language, dtype: int64
```

تحتوي مجموعة البيانات هذه على 22 لغة مع 1000 جملة من كل لغة. هذه مجموعة بيانات متوازنة للغاية ولا تحتوي على قيم مفقودة، لذلك يمكننا القول إن مجموعة البيانات هذه جاهزة تمامًا لاستخدامها في تدريب نموذج التعلم الآلي.

نموذج اكتشاف اللغة

دعنا الآن نقسم البيانات إلى مجموعات تدريب واختبار:

```
x = np.array(data["Text"])
y = np.array(data["language"])

cv = CountVectorizer()
X = cv.fit_transform(x)
X_train, X_test, y_train, y_test = train_test_split(X, y,
                                                    test_size=0.33,
                                                    random_state=42)
```

نظرًا لأن هذه مشكلة تتعلق بتصنيف متعدد الفئات (**multiclass classification**)، لذلك سأستخدم خوارزمية **Multinomial Naïve Bayes** لتدريب نموذج اكتشاف اللغة لأن هذه الخوارزمية تعمل دائمًا بشكل جيد جدًا على المشكلات القائمة على تصنيف متعدد الفئات:

```
model = MultinomialNB()
model.fit(X_train, y_train)
model.score(X_test, y_test)
```

```
0.953168044077135
```

دعنا الآن نستخدم هذا النموذج لاكتشاف لغة النص من خلال أخذ إدخال المستخدم:

```
user = input("Enter a Text: ")
data = cv.transform([user]).toarray()
output = model.predict(data)
print(output)
```

```
Enter a Text: देखकर अच्छा लगता है
['Hindi']
```

كما ترون أن النموذج يعمل بشكل جيد. شيء واحد يجب ملاحظته هنا هو أن هذا النموذج يمكنه فقط اكتشاف اللغات المذكورة في مجموعة البيانات.

الملخص

كان استخدام التعلم الآلي لتحديد اللغة مهمة صعبة منذ بضع سنوات لأنه لم يكن هناك الكثير من البيانات حول اللغات، ولكن مع توفر البيانات بسهولة، تتوفر بالفعل العديد من نماذج التعلم

الآلي القوية لتحديد اللغة. أمل أن تكون قد أحببت هذه المقالة حول اكتشاف اللغات باستخدام التعلم الآلي باستخدام بايثون.

24) التنبؤ بسعر سهم Tata Motors مع التعلم الآلي Tata Motors Stock Price Prediction with Machine Learning

في الآونة الأخيرة، شهدنا زيادة بأكثر من 10 في المائة في سعر سهم شركة Tata Motors. وقد أدى ذلك إلى مزيد من الاهتمام بأسهم مجموعة تاتا من جميع أنحاء الهند. ولكن مرة أخرى نشهد اليوم انخفاضاً في أسعار أسهم شركة Tata Motors، وهو ما يمكن أن يكون إشارة سلبية للمستثمرين. لذا، إذا كنت تريد معرفة كيفية تحليل سعر سهم شركة Tata Motors والتنبؤ به، فهذه المقالة مناسبة لك. في هذه المقالة، سوف أطلعك على مهمة التنبؤ بأسعار أسهم شركة Tata Motors مع التعلم الآلي باستخدام بايثون.

التنبؤ بسعر سهم Tata Motors

لمهمة التنبؤ بأسعار أسهم شركة Tata Motors، تحتاج إلى تنزيل مجموعة بيانات أسعار أسهم شركة Tata Motors. لذا، لتنزيل أحدث مجموعة بيانات لأسعار الأسهم، ما عليك سوى اتباع الخطوات المذكورة أدناه:

1. قم بزيارة Yahoo Finance.
 2. ابحث عن Tata Motors أو TTM (رمز سهم شركة Tata Motors)
 3. ثم انقر فوق البيانات التاريخية.
 4. وفي النهاية انقر فوق "download".
- بعد هذه الخطوات، ستري ملف CSV في مجلد التنزيلات الخاص بك. الآن في القسم أدناه، سوف أخذك خلال مهمة توقع سعر سهم Tata Motors مع التعلم الآلي باستخدام بايثون.

التنبؤ بأسعار أسهم شركة Tata Motors باستخدام لغة بايثون

لنبدأ مهمة التنبؤ بأسعار أسهم شركة Tata Motors عن طريق استيراد مكتبات بايثون ومجموعة البيانات اللازمة:

```
import numpy as np
import pandas as pd
import plotly.graph_objects as go
data = pd.read_csv("TTM.csv")
print(data.head())
```

	Date	Open	High	Low	Close	Adj Close	Volume
0	2020-10-22	9.08	9.14	9.03	9.12	9.12	1049600
1	2020-10-23	9.30	9.34	9.16	9.32	9.32	1158700
2	2020-10-26	9.03	9.08	8.89	9.06	9.06	2141900
3	2020-10-27	9.15	9.58	9.15	9.48	9.48	1552900
4	2020-10-28	9.02	9.04	8.80	8.85	8.85	2483900

دعنا الآن نرسم تصويراً تفاعلياً لأسعار الأسهم للحصول على صورة واضحة لزيادة وانخفاض أسعار أسهم شركة Tata Motors:

```
figure = go.Figure(data=[go.Candlestick(x=data["Date"],
                                        open=data["Open"],
                                        high=data["High"],
                                        low=data["Low"],
                                        close=data["Close"])]
                    figure.update_layout(title = "Tata Motors Stock Price
                    Analysis", xaxis_ranglider_visible=False)
                    figure.show()
```

Tata Motors Stock Price Analysis



دعنا الآن نلقي نظرة على الارتباط (**correlation**) بين ميزات مجموعة البيانات هذه:

```
print(data.corr())
```

	Open	High	Low	Close	Adj Close	Volume
Open	1.000000	0.998775	0.999278	0.998043	0.998043	0.106946
High	0.998775	1.000000	0.998695	0.999452	0.999452	0.132946
Low	0.999278	0.998695	1.000000	0.998787	0.998787	0.100552
Close	0.998043	0.999452	0.998787	1.000000	1.000000	0.127651
Adj Close	0.998043	0.999452	0.998787	1.000000	1.000000	0.127651
Volume	0.106946	0.132946	0.100552	0.127651	0.127651	1.000000

دعنا الآن ننتقل إلى مهمة التنبؤ بأسعار أسهم شركة Tata Motors. سأستخدم هنا مكتبة **autots** في بايثون لإعداد أسعار أسهم شركة Tata Motors للأيام الخمسة القادمة. إذا لم تستخدم مكتبة بايثون هذه من قبل، فيمكنك تثبيتها بسهولة باستخدام الأمر **pip**:

```
pip install autots
```

الآن فيما يلي كيف يمكنك توقع أسعار أسهم شركة Tata Motors:

```
from autots import AutoTS
model = AutoTS(forecast_length=5, frequency='infer',
ensemble='simple')
model = model.fit(data, date_col='Date', value_col='Close',
id_col=None)
prediction = model.predict()
forecast = prediction.forecast
print(forecast)
```

	Close
2021-10-22	34.060566
2021-10-25	34.525269
2021-10-26	34.955687
2021-10-27	35.478639
2021-10-28	35.850695

هذه هي الطريقة التي يمكنك بها استخدام التعلم الآلي لمهمة التنبؤ بسعر سهم شركة Tata Motors.

الملخص

هذه هي الطريقة التي يمكنك من خلالها توقع أسعار أسهم شركة Tata Motors من خلال التعلم الآلي. تحظى شركة Tata Motors باهتمام كبير في سوق الأسهم، لذلك سيكون هذا هو أفضل وقت لتحليل أسعار أسهم شركة Tata Motors. أمل أن تكون قد أحببت هذه المقالة حول التنبؤ بأسعار أسهم شركة Tata Motors مع التعلم الآلي باستخدام بايثون.

25) التنبؤ بأقساط التأمين الصحي باستخدام التعلم الآلي Health Insurance Premium Prediction with Machine Learning

التأمين الصحي (Health Insurance) هو نوع من التأمين يغطي النفقات الطبية. يحصل الشخص الذي حصل على بوليصة تأمين صحي على تغطية تأمين صحي بدفع مبلغ قسط معين. هناك الكثير من العوامل التي تحدد قسط التأمين الصحي. لذلك إذا كنت تريد معرفة كيف يمكننا استخدام التعلم الآلي للتنبؤ بقسط التأمين الصحي، فهذه المقالة مناسبة لك. في هذه المقالة، سوف آخذك خلال مهمة التنبؤ بأقساط التأمين الصحي مع التعلم الآلي باستخدام بايثون.

التنبؤ بأقساط التأمين الصحي

يعتمد مبلغ قسط بوليصة التأمين الصحي من شخص لآخر، حيث تؤثر العديد من العوامل على مبلغ قسط بوليصة التأمين الصحي. لنفترض أن العمر، الشاب أقل عرضة للإصابة بمشاكل صحية كبيرة مقارنة بالشخص الأكبر سناً. وبالتالي، فإن علاج كبار السن سيكون مكلفاً مقارنة بالشباب. هذا هو السبب في أن الشخص الأكبر سناً مطالب بدفع أقساط عالية مقارنة بالشباب.

تماماً مثل العمر، هناك العديد من العوامل الأخرى التي تؤثر على قسط التأمين الصحي. أمل أن تكون قد فهمت الآن ماهية التأمين الصحي وكيف يتم تحديد قسط التأمين الصحي. في القسم أدناه، سوف آخذك خلال مهمة التنبؤ بأقساط التأمين الصحي باستخدام التعلم الآلي باستخدام بايثون.

التنبؤ بأقساط التأمين الصحي باستخدام بايثون

يتم جمع [مجموعة البيانات](#) التي أستخدمها لمهمة التنبؤ بأقساط التأمين الصحي من Kaggle. يحتوي على بيانات حول:

1. عمر الشخص (the age of the person).
2. جنس الشخص (gender of the person).
3. مؤشر كتلة الجسم للشخص (Body Mass Index of the person).
4. كم عدد الأطفال الذين ينجبهم الشخص (how many children the person is having).
5. سواء كان الشخص يدخن أم لا (whether the person smokes or not).
6. المنطقة التي يعيش فيها الشخص (the region where the person lives).

7. ورسوم قسط التأمين (the charges of the insurance premium).

لذلك دعونا نستورد مجموعة البيانات ومكتبات بايثون الضرورية التي نحتاجها لهذه المهمة:

```
import numpy as np
import pandas as pd
data = pd.read_csv("Health_insurance.csv")
data.head()
```

	age	sex	bmi	children	smoker	region	charges
0	19	female	27.900	0	yes	southwest	16884.92400
1	18	male	33.770	1	no	southeast	1725.55230
2	28	male	33.000	3	no	southeast	4449.46200
3	33	male	22.705	0	no	northwest	21984.47061
4	32	male	28.880	0	no	northwest	3866.85520

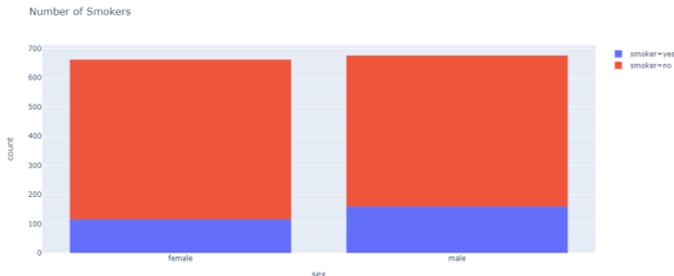
قبل المضي قدماً، دعنا نلقي نظرة على ما إذا كانت مجموعة البيانات هذه تحتوي على أي قيم فارغة أم لا:

```
data.isnull().sum()
```

```
age      0
sex      0
bmi      0
children 0
smoker   0
region   0
charges  0
dtype: int64
```

لذلك فإن مجموعة البيانات جاهزة للاستخدام. بعد الحصول على الانطباعات الأولى عن هذه البيانات، لاحظت عمود المدخن (*smoker*) الذي يشير إلى ما إذا كان الشخص يدخن أم لا. هذه ميزة مهمة لمجموعة البيانات هذه لأن الشخص الذي يدخن يكون أكثر عرضة للإصابة بمشاكل صحية كبيرة مقارنة بالشخص الذي لا يدخن. فلنلق نظرة على توزيع الأشخاص الذين يدخنون والذين لا يدخنون:

```
import plotly.express as px
data = data
figure = px.histogram(data, x = "sex", color = "smoker",
title= "Number of Smokers")
figure.show()
```



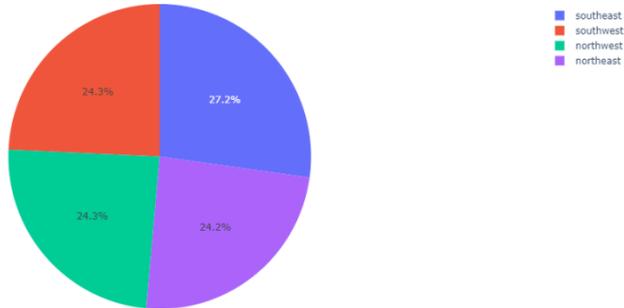
حسب الرسم أعلاه، 547 أنثى، 517 ذكر لا يدخنون، و115 أنثى، 159 ذكر يدخنون. من المهم استخدام هذه الميزة أثناء تدريب نموذج التعلم الآلي، لذلك سأستبدل قيم عمودي الجنس (Sex) والمدخن (smoker) بـ 0 و 1 لأن كلا العمودين يحتويان على قيم سلسلة نصية:

```
data["sex"] = data["sex"].map({"female": 0, "male": 1})
data["smoker"] = data["smoker"].map({"no": 0, "yes": 1})
print(data.head())
```

	age	sex	bmi	children	smoker	region	charges
0	19	0	27.900	0	1	southwest	16884.92400
1	18	1	33.770	1	0	southeast	1725.55230
2	28	1	33.000	3	0	southeast	4449.46200
3	33	1	22.705	0	0	northwest	21984.47061
4	32	1	28.880	0	0	northwest	3866.85520

دعنا الآن نلقي نظرة على توزيع المناطق (distribution of the regions) التي يعيش فيها الأشخاص وفقاً لمجموعة البيانات:

```
import plotly.express as px
pie = data["region"].value_counts()
regions = pie.index
population = pie.values
fig = px.pie(data, values=population, names=regions)
fig.show()
```



دعنا الآن نلقي نظرة على الارتباط (correlation) بين ميزات مجموعة البيانات هذه:

	age	sex	bmi	children	smoker	charges
age	1.000000	-0.020856	0.109272	0.042469	-0.025019	0.299008
sex	-0.020856	1.000000	0.046371	0.017163	0.076185	0.057292
bmi	0.109272	0.046371	1.000000	0.012759	0.003750	0.198341
children	0.042469	0.017163	0.012759	1.000000	0.007673	0.067998
smoker	-0.025019	0.076185	0.003750	0.007673	1.000000	0.787251
charges	0.299008	0.057292	0.198341	0.067998	0.787251	1.000000

نموذج التنبؤ بأقساط التأمين الصحي

دعنا الآن ننتقل إلى تدريب نموذج التعلم الآلي لمهمة التنبؤ بأقساط التأمين الصحي. أولاً، سأقسم البيانات إلى مجموعات تدريب واختبار:

```
x = np.array(data[["age", "sex", "bmi", "smoker"]])
y = np.array(data["charges"])

from sklearn.model_selection import train_test_split
xtrain, xtest, ytrain, ytest = train_test_split(x, y,
test_size=0.2, random_state=42)
```

بعد استخدام خوارزميات مختلفة للتعلم الآلي، وجدت خوارزمية الغابة العشوائية (**random forest**) كأفضل خوارزمية أداء لهذه المهمة. لذلك سأقوم هنا بتدريب النموذج باستخدام خوارزمية الغابة العشوائية للانحدار:

```
from sklearn.ensemble import RandomForestRegressor
forest = RandomForestRegressor()
forest.fit(xtrain, ytrain)
```

```
RandomForestRegressor(bootstrap=True, ccp_alpha=0.0, criterion='mse',
max_depth=None, max_features='auto', max_leaf_nodes=None,
max_samples=None, min_impurity_decrease=0.0,
min_impurity_split=None, min_samples_leaf=1,
min_samples_split=2, min_weight_fraction_leaf=0.0,
n_estimators=100, n_jobs=None, oob_score=False,
random_state=None, verbose=0, warm_start=False)
```

دعنا الآن نلقي نظرة على القيم المتوقعة (**predicted values**) للنموذج:

```
ypred = forest.predict(xtest)
data = pd.DataFrame(data={"Predicted Premium Amount": ypred})
print(data.head())
```

	Predicted Premium Amount
0	11331.111753
1	5366.132261
2	28257.205036
3	9793.356425
4	34720.204296

هذه هي الطريقة التي يمكنك بها تدريب نموذج التعلم الآلي لمهمة التنبؤ بأقساط التأمين الصحي باستخدام بايثون.

الملخص

يعتمد مبلغ قسط بوليصة التأمين الصحي على شخص لآخر حيث أن العديد من العوامل تؤثر على مبلغ قسط بوليصة التأمين الصحي. أمل أن تكون قد أحببت هذه المقالة حول تنبؤات أقساط التأمين الصحي باستخدام التعلم الآلي باستخدام بايثون.

26) التنبؤ بعدد الطلبات باستخدام التعلم الآلي Number of Orders Prediction with Machine Learning

يعد التنبؤ بعدد الطلبات (Predicting the number of orders) لمنتج ما إحدى الاستراتيجيات التي يمكن أن تتبعها الشركة في تحديد مقدار الاستثمار في تسويق منتجها. لذا، فإن التنبؤ بعدد الطلبات هو حالة مهمة لاستخدام علم البيانات للشركات القائمة على المنتجات. إذا كنت تريد معرفة كيفية استخدام التعلم الآلي للتنبؤ بعدد الطلبات، فهذه المقالة مناسبة لك. في هذه المقالة، سوف أطلعك على مهمة التنبؤ بعدد الطلبات باستخدام التعلم الآلي باستخدام بايثون.

التنبؤ بعدد الطلبات

إذا كنت ترغب في التنبؤ بعدد الطلبات التي قد تتلقاها الشركة لمنتج معين، فأنت بحاجة إلى الحصول على بيانات تاريخية حول عدد الطلبات التي تتلقاها الشركة. لذلك في هذه المهمة، سأستخدم بيانات مبيعات المكملات الغذائية (supplements) التي تم جمعها من Kaggle. البيانات التي سأستخدمها لمهمة التنبؤ بعدد الطلبات تحتوي على بيانات حول:

1. معرف المنتج (Product ID).
2. معرف المتجر (Store ID).
3. نوع المتجر الذي تم بيع المكمل فيه (The type of store where the supplement was sold).
4. نوع الموقع الذي تم استلام الطلب منه (The type of location the order was received from).
5. تاريخ المبيعات (Sales Date).
6. رمز المنطقة (Region code).
7. سواء كانت عطلة عامة أم لا وقت الطلب (Whether it is a public holiday or not at the time of order).
8. سواء كان المنتج بسعر مخفض أم لا (Whether the product was on discount or not).

9. عدد الطلبات المقدمة (Number of orders placed).

10. المبيعات (Sales).

أمل أن تكون قد حصلت الآن على نظرة عامة حول المشكلة ومجموعة البيانات التي سأستخدمها لحل المشكلة. الآن في القسم أدناه، سوف آخذك خلال مهمة التنبؤ بعدد الطلبات باستخدام التعلم الآلي باستخدام لغة برمجة بايثون.

التنبؤ بعدد الطلبات باستخدام بايثون

لنبدأ مهمة التنبؤ بعدد الطلبات عن طريق استيراد مكتبات بايثون ومجموعة البيانات اللازمة:

```
import pandas as pd
import numpy as np
data =
pd.read_csv("https://raw.githubusercontent.com/amankharwal/Web
site-data/master/supplement.csv")
data.head()
```

	ID	Store_id	Store_Type	...	Discount	#Order	Sales
0	T1000001	1	S1	...	Yes	9	7011.84
1	T1000002	253	S4	...	Yes	60	51789.12
2	T1000003	252	S3	...	Yes	42	36868.20
3	T1000004	251	S2	...	Yes	23	19715.16
4	T1000005	250	S2	...	Yes	62	45614.52

[5 rows x 10 columns]

دعنا الآن نلقي نظرة على بعض الأفكار الضرورية من مجموعة البيانات هذه لمعرفة نوع مجموعة البيانات التي نعمل معها:

```
data.info()
```

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 188340 entries, 0 to 188339
Data columns (total 10 columns):
#   Column          Non-Null Count  Dtype
---  ---
0   ID              188340 non-null object
1   Store_id       188340 non-null int64
2   Store_Type     188340 non-null object
3   Location_Type  188340 non-null object
4   Region_Code    188340 non-null object
5   Date           188340 non-null object
6   Holiday        188340 non-null int64
7   Discount       188340 non-null object
8   #Order         188340 non-null int64
9   Sales          188340 non-null float64
dtypes: float64(1), int64(3), object(6)
memory usage: 14.4+ MB
```

```
data.isnull().sum()
```

```
ID          0
Store_id    0
Store_Type  0
Location_Type 0
Region_Code 0
Date        0
Holiday     0
Discount    0
#Order      0
Sales       0
dtype: int64
```

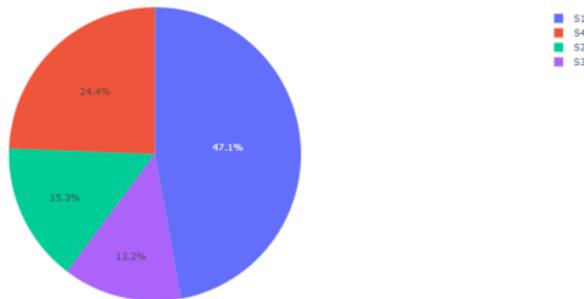
```
data.describe()
```

	Store_id	Holiday	#Order	Sales
count	188340.000000	188340.000000	188340.000000	188340.000000
mean	183.000000	0.131783	68.205692	42784.327982
std	105.366308	0.338256	30.467415	18456.708302
min	1.000000	0.000000	0.000000	0.000000
25%	92.000000	0.000000	48.000000	30426.000000
50%	183.000000	0.000000	63.000000	39678.000000
75%	274.000000	0.000000	82.000000	51909.000000
max	365.000000	1.000000	371.000000	247215.000000

دعنا الآن نستكشف بعض الميزات المهمة من مجموعة البيانات هذه للتعرف على العوامل التي تؤثر على عدد طلبات المكملات:

```
import plotly.express as px
pie = data["Store_Type"].value_counts()
store = pie.index
orders = pie.values

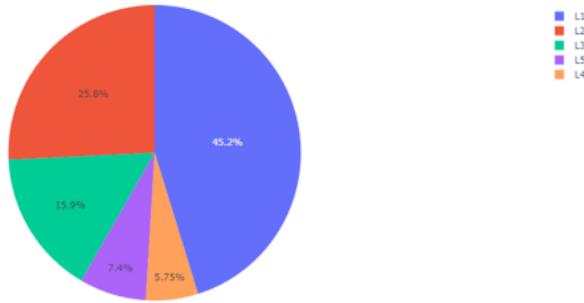
fig = px.pie(data, values=orders, names=store)
fig.show()
```



يوضح الشكل أعلاه توزيع عدد الطلبات المستلمة حسب نوع المتجر. دعنا الآن نلقي نظرة على توزيع عدد الطلبات، حسب الموقع:

```
pie2 = data["Location_Type"].value_counts()
location = pie2.index
orders = pie2.values
```

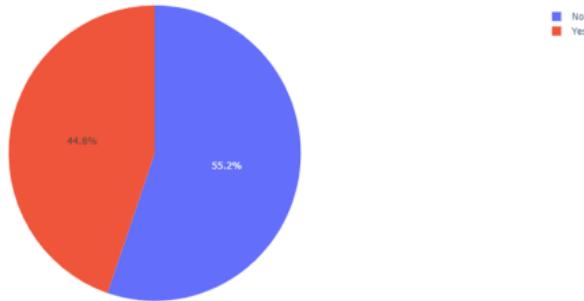
```
fig = px.pie(data, values=orders, names=location)
fig.show()
```



يوضح الشكل أعلاه توزيع عدد الطلبات المستلمة وفقاً للموقع. دعنا الآن نلقي نظرة على توزيع عدد الطلبات، وفقاً للخصم:

```
pie3 = data["Discount"].value_counts()
discount = pie3.index
orders = pie3.values

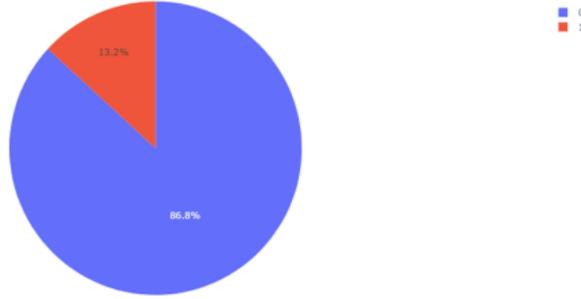
fig = px.pie(data, values=orders, names=discount)
fig.show()
```



وفقاً للرقم أعلاه، لا يزال معظم الناس يشترون المكملات الغذائية إذا لم يكن هناك خصم عليها. دعنا الآن نلقي نظرة على كيفية تأثير العطلات على عدد الطلبات:

```
pie4 = data["Holiday"].value_counts()
holiday = pie4.index
orders = pie4.values

fig = px.pie(data, values=orders, names=holiday)
fig.show()
```



وفقاً للرقم أعلاه، يشتري معظم الناس المكملات الغذائية في أيام العمل.

نموذج التنبؤ بعدد الطلبات

الآن دعنا نجهز البيانات حتى نتمكن من تدريب نموذج التعلم الآلي لمهمة التنبؤ بعدد الطلبات. هنا، سوف أقوم بتغيير بعض قيم السلسلة النصية إلى قيم رقمية:

```
data["Discount"] = data["Discount"].map({"No": 0, "Yes": 1})
data["Store_Type"] = data["Store_Type"].map({"S1": 1, "S2": 2,
"S3": 3, "S4": 4})
data["Location_Type"] = data["Location_Type"].map({"L1": 1,
"L2": 2, "L3": 3, "L4": 4, "L5": 5})
data.dropna()
```

```
x = np.array(data[["Store_Type", "Location_Type", "Holiday",
"Discount"]])
y = np.array(data["#Order"])
```

الآن دعنا نقسم البيانات إلى مجموعة تدريب 80٪ ومجموعة اختبار 20٪:

```
from sklearn.model_selection import train_test_split
xtrain, xtest, ytrain, ytest = train_test_split(x,
y,
test_size=0.2, random_state=42)
```

سأستخدم الآن خوارزمية الانحدار المعزز للتدرج الخفيف (**light gradient boosting regression**) لتدريب النموذج:

```
# Use pip install lightgbm to install it on your system
import lightgbm as ltb
model = ltb.LGBMRegressor()
model.fit(xtrain, ytrain)
```

```
LGBMRegressor(boosting_type='gbdt', class_weight=None, colsample_bytree=1.0,
importance_type='split', learning_rate=0.1, max_depth=-1,
min_child_samples=20, min_child_weight=0.001, min_split_gain=0.0,
n_estimators=100, n_jobs=-1, num_leaves=31, objective=None,
random_state=None, reg_alpha=0.0, reg_lambda=0.0, silent=True,
subsample=1.0, subsample_for_bin=200000, subsample_freq=0)
```

الآن دعنا نلقي نظرة على القيم المتوقعة (**predicted values**):

```
ypred = model.predict(xtest)
data = pd.DataFrame(data={"Predicted Orders": ypred.flatten()})
print(data.head())
```

	Predicted Orders
0	47.351897
1	97.068717
2	66.577788
3	85.143083
4	54.451098

هذه هي الطريقة التي يمكنك بها تدريب نموذج التعلم الآلي على مهمة التنبؤ بعدد الطلبات باستخدام لغة برمجة بايثون.

الملخص

يعد التنبؤ بعدد طلبات المنتج أحد الاستراتيجيات التي يمكن لشركة قائمة على المنتج اتباعها لتحديد المبلغ الذي يجب عليهم استثماره في تسويق منتجهم. أمل أن تكون قد أحببت هذه المقالة حول مهمة التنبؤ بعدد الطلبات باستخدام التعلم الآلي باستخدام بايثون.

27) التنبؤ بسعر سهم Apple مع التعلم الآلي Apple Stock Price Prediction with Machine Learning

أعلنت شركة Apple للتو عن موعد حدث سبتمبر حيث توشك على إطلاق iPhone 13 الجديد. وهو حالياً مركز الاهتمام في سوق الأسهم. يعد تحليل سوق الأوراق المالية أحد التطبيقات الشائعة للتعلم الآلي لأنه يمكننا التنبؤ بأسعار الأسهم باستخدام التعلم الآلي. لذلك إذا كنت تريد معرفة كيفية التنبؤ بأسعار سهم Apple باستخدام التعلم الآلي، فهذه المقالة مناسبة لك. في هذه المقالة، سوف أطلعك على مهمة توقع أسعار سهم Apple مع التعلم الآلي باستخدام بايثون.

التنبؤ بسعر سهم Apple

يعد حدث Apple في سبتمبر أحد الأحداث المفضلة لجميع مستخدمي Apple، حيث يتم إطلاق أجهزة iPhone بشكل أساسي خلال حدث سبتمبر. لذلك أعلنت شركة آبل أنها ستستعد لإطلاق iPhone 13 الجديد في 14 سبتمبر. لذلك يمكن للعديد من المستثمرين في سوق الأسهم أن يجدوا هذا كفرصة لشراء سهم Apple، لأنه في كل مرة تأتي فيها شركة بمنتج مبتكر، فإنها تقود لزيادة سعر سهمها. ومع أخذ ذلك في الاعتبار، يمكننا القول إن هذا هو أفضل وقت لتحليل أسعار سهم Apple.

بالنسبة لمهمة التنبؤ بسعر سهم Apple، فأنت بحاجة إلى تنزيل مجموعة بيانات أسعار سهم Apple. لتنزيل مجموعة بيانات لهذه المهمة، اتبع الخطوات المذكورة أدناه:

1. قم بزيارة Yahoo Finance.
2. ابحث عن Apple أو AAPL (رمز سهم Apple).
3. ثم انقر فوق البيانات التاريخية.
4. وفي النهاية انقر فوق "[download](#)".

بعد هذه الخطوات، ستري ملف CSV في مجلد التنزيل الخاص بك. الآن، في القسم أدناه، سوف أطلعك على مهمة توقع سعر سهم Apple باستخدام التعلم الآلي باستخدام بايثون.

التنبؤ بسعر سهم Apple باستخدام بايثون

لنبدأ مهمة التنبؤ بأسعار سهم Apple عن طريق استيراد مكتبات بايثون ومجموعة البيانات اللازمة:

```
import numpy as np
```

```
import pandas as pd
import plotly.graph_objects as go
data = pd.read_csv("AAPL.csv")
print(data.head())
```

	Date	Open	High	...	Close	Adj Close	Volume
0	2020-09-08	113.949997	118.989998	...	112.820000	112.098999	231366600
1	2020-09-09	117.260002	119.139999	...	117.320000	116.570236	176940500
2	2020-09-10	120.360001	120.500000	...	113.489998	112.764717	182274400
3	2020-09-11	114.570000	115.230003	...	112.000000	111.284241	180860300
4	2020-09-14	114.720001	115.930000	...	115.360001	114.622765	140150100

[5 rows x 7 columns]

الآن دعنا نتخيل بيانات أسعار الأسهم هذه للحصول على صورة واضحة لزيادة وانخفاض أسعار أسهم Apple:

```
figure = go.Figure(data=[go.Candlestick(x=data["Date"],
                                         open=data["Open"],
                                         high=data["High"],
                                         low=data["Low"],
                                         close=data["Close"])]
                    figure.update_layout(title="Apple Stock Price Analysis",
                                         xaxis_rangeslider_visible=False)
                    figure.show())
```



دعنا الآن نلقي نظرة على الارتباط (**correlation**) بين الميزات في مجموعة البيانات هذه:

```
print(data.corr())
```

	Open	High	Low	Close	Adj Close	Volume
Open	1.000000	0.994551	0.993183	0.986214	0.986177	-0.466464
High	0.994551	1.000000	0.992951	0.993586	0.993307	-0.440943
Low	0.993183	0.992951	1.000000	0.993915	0.994187	-0.517453
Close	0.986214	0.993586	0.993915	1.000000	0.999899	-0.489536
Adj Close	0.986177	0.993307	0.994187	0.999899	1.000000	-0.493909
Volume	-0.466464	-0.440943	-0.517453	-0.489536	-0.493909	1.000000

دعنا الآن ننتقل إلى مهمة التنبؤ بأسعار أسهم Apple. سأستخدم هنا مكتبة autots في بايثون للتنبؤ بأسعار أسهم Apple للأيام الخمسة القادمة. إذا لم تستخدمه من قبل، فيمكنك تثبيته بسهولة باستخدام الأمر pip:

```
pip install autots
```

الآن فيما يلي كيف يمكنك توقع أسعار أسهم شركة Apple:

```
from autots import AutoTS
model = AutoTS(forecast_length=5, frequency='infer',
ensemble='simple')
model = model.fit(data, date_col='Date', value_col='Close',
id_col=None)
prediction = model.predict()
forecast = prediction.forecast
print(forecast)
```

	Close
2021-09-08	157.595000
2021-09-09	158.491248
2021-09-10	157.846256
2021-09-13	158.758755
2021-09-14	159.934376

هذه هي الطريقة التي يمكنك بها استخدام التعلم الآلي للتنبؤ بأسعار الأسهم.

الملخص

هذه هي الطريقة التي يمكنك بها التنبؤ بأسعار أسهم Apple باستخدام التعلم الآلي باستخدام لغة برمجة بايثون. يعد تحليل سوق الأوراق المالية أحد التطبيقات الشائعة للتعلم الآلي لأنه يمكننا التنبؤ بأسعار الأسهم باستخدام التعلم الآلي. آمل أن تكون قد أحببت هذه المقالة حول توقع أسعار أسهم Apple مع التعلم الآلي باستخدام بايثون.

28) تصنيف الأخبار مع تعلم الآلة News Classification with Machine Learning

يجب أن تكون قد شاهدت الأخبار مقسمة إلى فئات عندما تذهب إلى موقع إخباري. بعض الفئات الشائعة التي ستشاهدها في أي موقع إخباري تقريباً هي التكنولوجيا والترفيه والرياضة. إذا كنت تريد معرفة كيفية تصنيف فئات الأخبار باستخدام التعلم الآلي، فهذه المقالة مناسبة لك. في هذه المقالة، سوف أطلعك على مهمة تصنيف الأخبار باستخدام التعلم الآلي باستخدام بايثون.

تصنيف الأخبار

يصنف كل موقع إخباري المقال الإخباري قبل نشره بحيث يمكن للزائرين في كل مرة يزورون موقع الويب الخاص بهم النقر بسهولة على نوع الأخبار التي تهمهم. على سبيل المثال، أحب قراءة آخر تحديثات التكنولوجيا، لذلك في كل مرة أزور فيها موقعاً إخبارياً، أنقر على قسم التكنولوجيا. ولكن قد ترغب أو لا ترغب في القراءة عن التكنولوجيا، فقد تكون مهتماً بالسياسة أو الأعمال أو الترفيه أو ربما الرياضة.

حالياً، يتم تصنيف المقالات الإخبارية يدوياً بواسطة مديري المحتوى في مواقع الويب الإخبارية. ولكن لتوفير الوقت، يمكنهم أيضاً تنفيذ نموذج التعلم الآلي على مواقع الويب الخاصة بهم والذي يقرأ عنوان الأخبار أو محتوى الأخبار ويصنف فئة الأخبار. في القسم أدناه، سأطلعك على كيفية تدريب نموذج التعلم الآلي لمهمة تصنيف الأخبار باستخدام لغة برمجة بايثون.

تصنيف الأخبار باستخدام بايثون

بالنسبة لمهمة تصنيف الأخبار باستخدام التعلم الآلي، فقد جمعت مجموعة بيانات من Kaggle، والتي تحتوي على مقالات إخبارية بما في ذلك عناوينها وفئاتها. الفئات المشمولة في مجموعة البيانات هذه هي:

1. رياضة (Sports).
2. أعمال (Business).
3. سياسة (Politics).
4. تقنية (Tech).
5. الترفيه (Entertainment).

لذلك دعونا نستورد مكتبات بايثون الضرورية ومجموعة البيانات التي نحتاجها لهذه المهمة:

```
import pandas as pd
import numpy as np
from sklearn.feature_extraction.text import CountVectorizer
from sklearn.model_selection import train_test_split
from sklearn.naive_bayes import MultinomialNB

data =
pd.read_csv("https://raw.githubusercontent.com/amankharwal/Web
site-data/master/bbc-news-data.csv", sep='\t')
print(data.head())
```

```
   category ... content
0  business ... Quarterly profits at US media giant TimeWarne...
1  business ... The dollar has hit its highest level against ...
2  business ... The owners of embattled Russian oil giant Yuk...
3  business ... British Airways has blamed high fuel prices f...
4  business ... Shares in UK drinks and food firm Allied Dome...

[5 rows x 4 columns]
```

الآن، دعنا نلقي نظرة سريعة على ما إذا كانت مجموعة البيانات هذه تحتوي على أي قيم فارغة أم لا:

```
data.isnull().sum()
```

```
category    0
filename    0
title       0
content     0
dtype: int64
```

توجد التسميات (labels) التي نحتاج إلى تصنيفها من مجموعة البيانات هذه في عمود الفئة (category column) بهذه البيانات، دعنا نلقي نظرة على توزيع جميع فئات الأخبار:

```
data["category"].value_counts()
```

```
sport        511
business     510
politics     417
tech         401
entertainment 386
Name: category, dtype: int64
```

نموذج تصنيف الأخبار

دعنا الآن نجهز البيانات لمهمة تدريب نموذج تصنيف الأخبار:

```
data = data[["title", "category"]]

x = np.array(data["title"])
y = np.array(data["category"])

cv = CountVectorizer()
X = cv.fit_transform(x)
```

```
X_train, X_test, y_train, y_test = train_test_split(X, y,
test_size=0.33, random_state=42)
```

سأستخدم الآن خوارزمية **Multinomial Naive Bayes** لتدريب نموذج تصنيف الأخبار:

```
model = MultinomialNB()
model.fit(X_train, y_train)
```

أخيراً، دعنا نختبر كيفية عمل هذا النموذج على أحد العناوين الرئيسية (**headlines**) في أخبار اليوم:

```
user = input("Enter a Text: ")
data = cv.transform([user]).toarray()
output = model.predict(data)
print(output)
```

```
Enter a Text: Latest Apple iPhone SE 3 concept renders show a compact smartphone in the style of the
iPhone 4
['tech']
```

هذه هي الطريقة التي يمكنك بها تدريب نموذج تصنيف الأخبار باستخدام التعلم الآلي باستخدام بايثون.

الملخص

هذه هي الطريقة التي يمكننا بها استخدام التعلم الآلي لتصنيف فئات الأخبار. يصنف كل موقع إخباري المقال الإخباري قبل نشره بحيث يمكن للزائرين في كل مرة يزورون موقع الويب الخاص بهم النقر بسهولة على نوع الأخبار التي تهمهم. أمل أن تكون قد أحببت هذه المقالة حول تصنيف الأخبار مع التعلم الآلي باستخدام بايثون.

29) التنبؤ بأسعار السيارة مع التعلم الآلي Car Price Prediction with Machine Learning

يعتمد سعر السيارة (Car Price) على الكثير من العوامل مثل السمعة الحسنة للعلامة التجارية للسيارة وميزات السيارة والقدرة الحصانية والمسافة المقطوعة التي تعطيها وغيرها الكثير. يعد التنبؤ بسعر السيارة أحد مجالات البحث الرئيسية في التعلم الآلي. لذلك إذا كنت تريد معرفة كيفية تدريب نموذج التنبؤ بسعر السيارة، فهذه المقالة مناسبة لك. في هذه المقالة، سوف آخذك في جولة حول كيفية تدريب نموذج التنبؤ بسعر السيارة باستخدام التعلم الآلي باستخدام بايثون.

التنبؤ بأسعار السيارة مع التعلم الآلي

أحد المجالات الرئيسية للبحث في التعلم الآلي هو التنبؤ بسعر السيارات. يعتمد على التمويل ومجال التسويق. إنه موضوع بحث رئيسي في التعلم الآلي لأن سعر السيارة يعتمد على العديد من العوامل. بعض العوامل التي تساهم كثيراً في سعر السيارة هي:

1. الماركة Brand.
2. النموذج Model.
3. القوة الحصانية Horsepower.
4. عدد الأميال Mileage.
5. ميزات السلامة Safety Features.
6. GPS وغيرها الكثير.

إذا تجاهل المرء العلامة التجارية للسيارة، فإن الشركة المصنعة للسيارة تحدد سعر السيارة بشكل أساسي بناءً على الميزات التي يمكن أن تقدمها للعميل. لاحقاً، قد ترفع العلامة التجارية السعر اعتماداً على حسن نيتها، ولكن أهم العوامل هي الميزات التي تمنحها السيارة لإضافة قيمة إلى حياتك. لذلك، في القسم أدناه، سوف أطلعك على مهمة تدريب نموذج التنبؤ بسعر السيارة باستخدام التعلم الآلي باستخدام لغة برمجة بايثون.

نموذج التنبؤ بسعر السيارة باستخدام لغة بايثون

تم تنزيل مجموعة البيانات التي أستخدمها هنا لتدريب نموذج التنبؤ بأسعار السيارة من Kaggle. يحتوي على بيانات حول جميع الميزات الرئيسية التي تساهم في سعر السيارة. فلنبدأ هذه المهمة عن طريق استيراد مكتبات بايثون ومجموعة البيانات الضرورية:

مجموعة البيانات

```
import numpy as np
import pandas as pd
```

```
import matplotlib.pyplot as plt
import seaborn as sns
from sklearn.model_selection import train_test_split
from sklearn.tree import DecisionTreeRegressor
```

```
data = pd.read_csv("CarPrice.csv")
data.head()
```

	car_ID	symboling	CarName	...	citympg	highwaympg	price
0	1	3	alfa-romero giulia	...	21	27	13495.0
1	2	3	alfa-romero stelvio	...	21	27	16500.0
2	3	1	alfa-romero Quadrifoglio	...	19	26	16500.0
3	4	2	audi 100 ls	...	24	30	13950.0
4	5	2	audi 100ls	...	18	22	17450.0

```
[5 rows x 26 columns]
```

يوجد 26 عمودًا في مجموعة البيانات هذه، لذلك من المهم جدًا التحقق مما إذا كانت مجموعة البيانات هذه تحتوي على قيم فارغة (null values) أم لا قبل المضي قدمًا:

```
data.isnull().sum()
```

```
car_ID          0
symboling       0
CarName         0
fueltype        0
aspiration      0
doornumber      0
carbody         0
drivewheel      0
enginelocation  0
wheelbase       0
carlength       0
carwidth        0
carheight       0
curbweight      0
enginetype      0
cylindernumber  0
engineize       0
fuelsystem      0
boreratio       0
stroke          0
compressionratio 0
horsepower      0
peakrpm         0
citympg         0
highwaympg      0
price           0
dtype: int64
```

لذلك لا تحتوي مجموعة البيانات هذه على أي قيم فارغة، فلنلقِ الآن نظرة على بعض الأفكار المهمة الأخرى للحصول على فكرة عن نوع البيانات التي نتعامل معها:

```
data.info()
```

```
RangeIndex: 205 entries, 0 to 204
Data columns (total 26 columns):
 #   Column              Non-Null Count  Dtype
---  -
 0   car_ID              205 non-null    int64
 1   symboling           205 non-null    int64
 2   CarName             205 non-null    object
 3   fueltype            205 non-null    object
 4   aspiration           205 non-null    object
 5   doornumber          205 non-null    object
 6   carbody             205 non-null    object
 7   drivewheel         205 non-null    object
 8   enginelocation      205 non-null    object
 9   wheelbase           205 non-null    float64
10   carlength           205 non-null    float64
11   carwidth            205 non-null    float64
12   carheight           205 non-null    float64
13   curbweight          205 non-null    int64
14   enginetype          205 non-null    object
15   cylindernumber      205 non-null    object
16   enginesize          205 non-null    int64
17   fuelsystem          205 non-null    object
18   boreratio           205 non-null    float64
19   stroke              205 non-null    float64
20   compressionratio    205 non-null    float64
21   horsepower          205 non-null    int64
22   peakrpm             205 non-null    int64
23   citympg             205 non-null    int64
24   highwaympg         205 non-null    int64
25   price               205 non-null    float64
dtypes: float64(8), int64(8), object(10)
memory usage: 41.8+ KB
```

```
print(data.describe())
```

	car_ID	symboling	wheelbase	...	citympg	highwaympg	price
count	205.000000	205.000000	205.000000	...	205.000000	205.000000	205.000000
mean	103.000000	0.834146	98.756585	...	25.219512	30.751220	13276.710571
std	59.322565	1.245307	6.021776	...	6.542142	6.886443	7988.852332
min	1.000000	-2.000000	86.600000	...	13.000000	16.000000	5118.000000
25%	52.000000	0.000000	94.500000	...	19.000000	25.000000	7788.000000
50%	103.000000	1.000000	97.000000	...	24.000000	30.000000	10295.000000
75%	154.000000	2.000000	102.400000	...	30.000000	34.000000	16503.000000
max	205.000000	3.000000	120.900000	...	49.000000	54.000000	45400.000000

```
[8 rows x 16 columns]
```

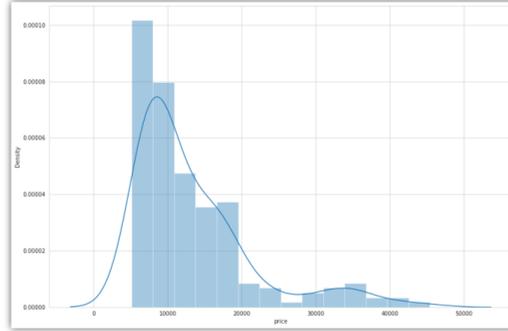
```
data.CarName.unique()
```

```
array(['alfa-romero giulia', 'alfa-romero stelvio',
      'alfa-romero Quadrifoglio', 'audi 100 ls', 'audi 100ls',
      'audi fox', 'audi 5000', 'audi 4000', 'audi 5000s (diesel)',
      'bmw 320i', 'bmw x1', 'bmw x3', 'bmw z4', 'bmw x4', 'bmw x5',
      'chevrolet impala', 'chevrolet monte carlo', 'chevrolet vega 2300',
```

```
'dodge rampage', 'dodge challenger se', 'dodge d200',
'dodge monaco (sw)', 'dodge colt hardtop', 'dodge colt (sw)',
'dodge coronet custom', 'dodge dart custom',
'dodge coronet custom (sw)', 'honda civic', 'honda civic cvcc',
'honda accord cvcc', 'honda accord lx', 'honda civic 1500 gl',
'honda accord', 'honda civic 1300', 'honda prelude',
'honda civic (auto)', 'isuzu MU-X', 'isuzu D-Max ',
'isuzu D-Max V-Cross', 'jaguar xj', 'jaguar xf', 'jaguar xk',
'mazda rx3', 'mazda glc deluxe', 'mazda rx2 coupe', 'mazda rx-4',
'mazda glc deluxe', 'mazda 626', 'mazda glc', 'mazda rx-7 gs',
'mazda glc 4', 'mazda glc custom l', 'mazda glc custom',
'buick electra 225 custom', 'buick century luxus (sw)',
'buick century', 'buick skyhawk', 'buick opel isuzu deluxe',
'buick skylark', 'buick century special',
'buick regal sport coupe (turbo)', 'mercury cougar',
'mitsubishi mirage', 'mitsubishi lancer', 'mitsubishi outlander',
'mitsubishi g4', 'mitsubishi mirage g4', 'mitsubishi montero',
'mitsubishi pajero', 'Nissan versa', 'nissan gt-r', 'nissan rogue',
'nissan latio', 'nissan titan', 'nissan leaf', 'nissan juke',
'nissan note', 'nissan clipper', 'nissan nv200', 'nissan dayz',
'nissan fuga', 'nissan otti', 'nissan teana', 'nissan kicks',
'peugeot 504', 'peugeot 304', 'peugeot 504 (sw)', 'peugeot 604sl',
'peugeot 505s turbo diesel', 'plymouth fury iii',
'plymouth cricket', 'plymouth satellite custom (sw)',
'plymouth fury gran sedan', 'plymouth valiant', 'plymouth duster',
'porsche macan', 'porsche panamera', 'porsche cayenne',
'porsche boxer', 'renault 12tl', 'renault 5 gtl', 'saab 99e',
'saab 99le', 'saab 99gle', 'subaru', 'subaru dl', 'subaru brz',
'subaru baja', 'subaru r1', 'subaru r2', 'subaru trezia',
'subaru tribeca', 'toyota corona mark ii', 'toyota corona',
'toyota corolla 1200', 'toyota corona hardtop',
'toyota celica gt liftback', 'toyota corolla tercel',
'toyota corona liftback', 'toyota starlet', 'toyota tercel',
'toyota cressida', 'toyota celica gt', 'toyota tercel',
'volkswagen rabbit', 'volkswagen 113l deluxe sedan',
'volkswagen model 111', 'volkswagen type 3', 'volkswagen 411 (sw)',
'volkswagen super beetle', 'volkswagen dasher', 'vw dasher',
'vw rabbit', 'volkswagen rabbit', 'volkswagen rabbit custom',
'volvo 145e (sw)', 'volvo 144ea', 'volvo 244d1', 'volvo 245',
'volvo 264gl', 'volvo diesel', 'volvo 246'], dtype=object)
```

من المفترض أن يكون عمود السعر في مجموعة البيانات هذه هو العمود الذي نحتاج إلى توقع قيمه. دعونا نرى توزيع قيم عمود السعر:

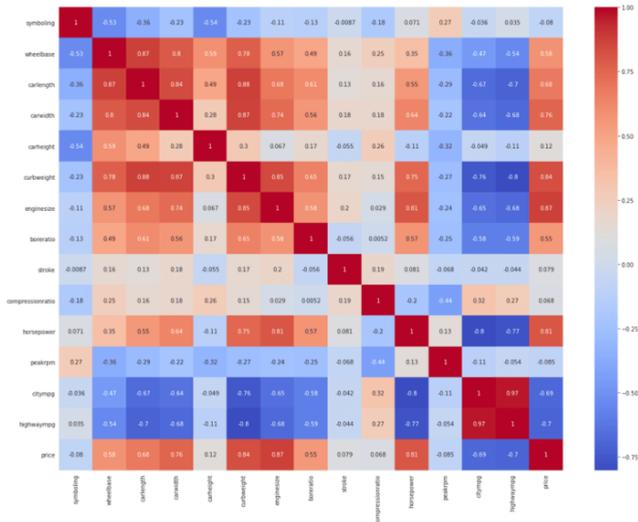
```
sns.set_style("whitegrid")
plt.figure(figsize=(15, 10))
sns.distplot(data.price)
plt.show()
```



دعنا الآن نلقي نظرة على الارتباط بين جميع ميزات مجموعة البيانات هذه:

	car_ID	symboling	...	highwaympg	price
car_ID	1.000000	-0.151621	...	0.011255	-0.109093
symboling	-0.151621	1.000000	...	0.034606	-0.079978
wheelbase	0.129729	-0.531954	...	-0.544082	0.577816
carlength	0.170636	-0.357612	...	-0.704662	0.682920
carwidth	0.052387	-0.232919	...	-0.677218	0.759325
carheight	0.255960	-0.541038	...	-0.107358	0.119336
curbweight	0.071962	-0.227691	...	-0.797465	0.835305
enginesize	-0.033930	-0.105790	...	-0.677470	0.874145
boreratio	0.260064	-0.130051	...	-0.587012	0.553173
stroke	-0.160824	-0.008735	...	-0.043931	0.079443
compressionratio	0.150276	-0.178515	...	0.265201	0.067984
horsepower	-0.015006	0.070873	...	-0.770544	0.808139
peakrpm	-0.203789	0.273606	...	-0.054275	-0.085267
citympg	0.015940	-0.035823	...	0.971337	-0.685751
highwaympg	0.011255	0.034606	...	1.000000	-0.697599
price	-0.109093	-0.079978	...	-0.697599	1.000000

[16 rows x 16 columns]



```
plt.figure(figsize=(20, 15))
correlations = data.corr()
```

```
sns.heatmap(correlations, cmap="coolwarm", annot=True)
plt.show()
```

تدريب نموذج التنبؤ بسعر السيارة

سأستخدم خوارزمية انحدار شجرة القرار **decision tree** لتدريب نموذج التنبؤ بسعر السيارة. لذلك دعونا نقسم البيانات إلى مجموعات تدريب واختبار ونستخدم خوارزمية انحدار شجرة القرار لتدريب النموذج:

```
predict = "price"
data = data[["symboling", "wheelbase", "carlength",
            "carwidth", "carheight", "curbweight",
            "enginesize", "bore", "stroke",
            "compressionratio", "horsepower", "peakrpm",
            "citympg", "highwaympg", "price"]]
x = np.array(data.drop([predict], 1))
y = np.array(data[predict])

from sklearn.model_selection import train_test_split
xtrain, xtest, ytrain, ytest = train_test_split(x, y, test_size=0.2)

from sklearn.tree import DecisionTreeRegressor
model = DecisionTreeRegressor()
model.fit(xtrain, ytrain)
predictions = model.predict(xtest)

from sklearn.metrics import mean_absolute_error
model.score(xtest, predictions)
```

1.0

يعطي النموذج دقة 100٪ في مجموعة الاختبار، وهو أمر ممتاز.

الملخص

هذه هي الطريقة التي يمكنك بها تدريب نموذج التعلم الآلي لمهمة التنبؤ بأسعار السيارات باستخدام لغة برمجة بايثون. إنه موضوع بحث رئيسي في التعلم الآلي لأن سعر السيارة يعتمد على العديد من العوامل. أتمنى أن تكون قد أحببت هذا المقال حول مهمة تدريب نموذج للتنبؤ بأسعار السيارات باستخدام التعلم الآلي.

30 اكتشاف البريد العشوائي باستخدام التعلم الآلي

Spam Detection with Machine Learning

يعد اكتشاف البريد غير المرغوب فيه (Spam Detection) في رسائل البريد الإلكتروني والرسائل أحد التطبيقات الرئيسية التي تحاول كل شركة تقنية كبيرة تحسينها لعملائها. يعد تطبيق المراسلة الرسمي من Gmail و Apple من Google مثالين رائعين لمثل هذه التطبيقات حيث يعمل اكتشاف الرسائل غير المرغوب فيها بشكل جيد لحماية المستخدمين من تنبيهات الرسائل غير المرغوب فيها. لذلك، إذا كنت تتطلع إلى إنشاء نظام للكشف عن الرسائل غير المرغوب فيها، فهذه المقالة مناسبة لك. في هذه المقالة، سوف أطلعك على مهمة اكتشاف البريد العشوائي باستخدام التعلم الآلي باستخدام بايثون.

اكتشاف البريد العشوائي

عندما ترسل تفاصيل حول بريدك الإلكتروني أو رقم الاتصال الخاص بك على أي منصة، أصبح من السهل على تلك المنصات تسويق منتجاتها عن طريق الإعلان عنها عن طريق إرسال رسائل بريد إلكتروني أو عن طريق إرسال رسائل مباشرة إلى رقم الاتصال الخاص بك. ينتج عن هذا الكثير من التنبيهات والإشعارات بشأن البريد العشوائي في صندوق الوارد الخاص بك. هذا هو المكان الذي تأتي فيه مهمة اكتشاف البريد العشوائي.

يعني Spam detection اكتشاف الرسائل غير المرغوب فيها أو رسائل البريد الإلكتروني من خلال فهم محتوى النص بحيث يمكنك فقط تلقي إشعارات حول الرسائل أو رسائل البريد الإلكتروني المهمة جداً بالنسبة لك. إذا تم العثور على رسائل غير مرغوب فيها، فسيتم نقلها تلقائياً إلى مجلد البريد العشوائي ولن يتم إخطارك بهذه التنبيهات. يساعد هذا في تحسين تجربة المستخدم، حيث يمكن للعديد من تنبيهات البريد العشوائي أن تزعج العديد من المستخدمين.

اكتشاف البريد العشوائي باستخدام بايثون

أمل أن تفهم الآن ما هو اكتشاف الرسائل غير المرغوب فيها، فلنرى الآن كيفية تدريب نموذج التعلم الآلي على اكتشاف تنبيهات الرسائل غير المرغوب فيها باستخدام بايثون. سأبدأ هذه المهمة عن طريق استيراد مكتبات بايثون الضرورية ومجموعة البيانات التي تحتاجها لهذه المهمة:

```
import pandas as pd
import numpy as np
from sklearn.feature_extraction.text import CountVectorizer
from sklearn.model_selection import train_test_split
from sklearn.naive_bayes import MultinomialNB
data = pd.read_csv("https://raw.githubusercontent.com/amankharwal/SMS-Spam-Detection/master/spam.csv", encoding='latin-1')
data.head()
```

	class	message	Unnamed: 2	Unnamed: 3	Unnamed: 4
0	ham	Go until jurong point, crazy.. Available only ...	NaN	NaN	NaN
1	ham	Ok lar... Joking wif u oni...	NaN	NaN	NaN
2	spam	Free entry in 2 a wkly comp to win FA Cup fina...	NaN	NaN	NaN
3	ham	U dun say so early hor... U c already then say...	NaN	NaN	NaN
4	ham	Nah I don't think he goes to usf, he lives aro...	NaN	NaN	NaN

من مجموعة البيانات هذه، الفئة `class` والرسالة `message` هما الميزتان الوحيدتان اللتان نحتاجهما لتدريب نموذج التعلم الآلي على اكتشاف الرسائل غير المرغوب فيها، لذلك دعونا نحدد هذين العمودين كمجموعة بيانات جديدة:

```
data = data[["class", "message"]]
```

دعنا الآن نقسم مجموعة البيانات هذه إلى مجموعات تدريب واختبار وتدريب النموذج على اكتشاف الرسائل غير المرغوب فيها:

```
x = np.array(data["message"])
y = np.array(data["class"])
cv = CountVectorizer()
X = cv.fit_transform(x) # Fit the Data
X_train, X_test, y_train, y_test = train_test_split(X, y,
test_size=0.33, random_state=42)

clf = MultinomialNB()
clf.fit(X_train,y_train)
```

دعنا الآن نختبر هذا النموذج من خلال أخذ إدخال المستخدم كرسالة لاكتشاف ما إذا كان بريداً عشوائياً أم لا:

```
sample = input('Enter a message:')
data = cv.transform([sample]).toarray()
print(clf.predict(data))
```

```
Enter a message:You won $40 cash price
['spam']
```

الملخص

هذه هي الطريقة التي يمكنك بها تدريب نموذج التعلم الآلي على مهمة اكتشاف ما إذا كانت رسالة بريد إلكتروني أو رسالة بريد عشوائي أم لا. يكتشف كاشف الرسائل غير المرغوب فيها رسائل البريد العشوائي أو رسائل البريد الإلكتروني من خلال فهم محتوى النص بحيث يمكنك فقط تلقي إشعارات حول الرسائل أو رسائل البريد الإلكتروني المهمة جداً بالنسبة لك. أمل أن تكون قد أحببت هذه المقالة حول مهمة الكشف عن تنبيهات البريد العشوائي باستخدام التعلم الآلي باستخدام بايثون.

31 التنبؤ بدرجات الطلاب باستخدام التعلم الآلي Student Grades Prediction with Machine Learning

في الدراسات العليا، يجد العديد من الطلاب صعوبة في تحقيق درجات جيدة لأنهم لا يحصلون على دعم كبير في دورات التعليم العالي مقارنة بالدعم الذي يتلقاه الطلاب في المدارس. يمكننا استخدام التعلم الآلي لمهمة التنبؤ بدرجات الطالب حتى يتمكن المدرسون من مساعدة الطلاب على الاستعداد للموضوعات التي تم توقع انخفاض درجات الطلاب فيها. في هذه المقالة، سوف أطلعك على مهمة التنبؤ بدرجات الطلاب باستخدام التعلم الآلي باستخدام بايثون.

التنبؤ بدرجات الطالب

الجامعات هي أماكن مرموقة للغاية للوصول إلى التعليم العالي. لكن مقدار الرسوم التي تفرضها الجامعات اليوم لا يساوي أبداً الدعم الذي تقدمه للطلاب. يحتاج بعض الطلاب إلى الكثير من الاهتمام من المعلمين لأنه إذا لم يتم إيلاء اهتمام خاص لأولئك الطلاب الذين لم يحصلوا على درجات جيدة، فقد يكون ذلك ضاراً بحالتهم العاطفية وحياتهم المهنية على المدى الطويل.

باستخدام خوارزميات التعلم الآلي، يمكننا التنبؤ بمدى جودة أداء الطلاب حتى نتمكن من مساعدة الطلاب الذين من المتوقع أن تكون درجاتهم منخفضة. يعتمد توقع درجات الطلاب على مشكلة الانحدار في التعلم الآلي. في القسم أدناه، سوف آخذك خلال مهمة التنبؤ بدرجات الطلاب باستخدام التعلم الآلي باستخدام بايثون.

التنبؤ بدرجات الطالب باستخدام لغة بايثون

أمل أن تكون قد فهمت الآن سبب حاجتنا للتنبؤ بدرجات الطالب. دعنا الآن نرى كيف يمكننا استخدام التعلم الآلي لمهمة التنبؤ بدرجات الطلاب باستخدام بايثون. سأبدأ هذه المهمة عن طريق استيراد مكتبات بايثون و**مجموعة البيانات** اللازمة:

```
import numpy as np
import pandas as pd
from sklearn.linear_model import LinearRegression
from sklearn.utils import shuffle
```

```
data = pd.read_csv("student-mat.csv")
data.head()
```

	school	sex	age	address	famsize	Pstatus	Medu	Fedu	Mjob	Fjob	reason	guardian
0	GP	F	18	U	GT3	A	4	4	at_home	teacher	course	mother
1	GP	F	17	U	GT3	T	1	1	at_home	other	course	father
2	GP	F	15	U	LE3	T	1	1	at_home	other	other	mother
3	GP	F	15	U	GT3	T	4	2	health	services	home	mother
4	GP	F	16	U	GT3	T	3	3	other	other	home	father

تستند مجموعة البيانات التي أستخدمها لمهمة التنبؤ بدرجات الطلاب إلى إنجازات طلاب المدارس البرتغالية. في مجموعة البيانات هذه، يمثل G1 درجات الفترة الأولى، ويمثل G2 درجات الفترة الثانية، ويمثل G3 الدرجات النهائية. الآن دعنا نجهز البيانات ودعنا نرى كيف يمكننا توقع الدرجات النهائية للطلاب:

```
data = data[["G1", "G2", "G3", "studytime", "failures", "absences"]]
predict = "G3"
x = np.array(data.drop([predict], 1))
y = np.array(data[predict])
```

```
from sklearn.model_selection import train_test_split
xtrain, xtest, ytrain, ytest = train_test_split(x, y, test_size=0.2)
```

في الكود أعلاه، قمنا أولاً بتحديد الأعمدة الضرورية التي نحتاجها لتدريب نموذج التعلم الآلي لمهمة التنبؤ بدرجات الطلاب. ثم أعلنت أن عمود G3 هو التسمية المستهدفة لدينا، ثم قسمنا مجموعة البيانات إلى اختبار بنسبة 20٪ وتدريب بنسبة 80٪. دعنا الآن نرى كيفية تدريب نموذج الانحدار الخطي [linear regression](#) لمهمة التنبؤ بدرجات الطلاب:

```
linear_regression = LinearRegression()
linear_regression.fit(xtrain, ytrain)
accuracy = linear_regression.score(xtest, ytest)
print(accuracy)
```

```
0.8432876775479776
```

أعطى نموذج الانحدار الخطي دقة حوالي 84٪ وهي ليست سيئة في هذه المهمة. الآن دعنا نلقي نظرة على التنبؤات التي قدمها نموذج التنبؤ بالدرجات للطلاب:

```
predictions = linear_regression.predict(xtest)
for i in range(len(predictions)):
    print(predictions[x], xtest[x], [ytest[x]])
```

```
[[16.16395534 14.23423176 14.08532841 5.28096434 14.23423176]
 [16.16395534 16.16395534 14.08532841 5.28096434 7.97291422]
 [14.52779998 11.92149651 14.08532841 9.13993948 4.71694746]
 ...
 [ 4.71694746 11.92149651 3.9451298 9.13993948 9.13993948]
 [12.56424351 4.92497623 3.9451298 5.28096434 5.28096434]
 [11.92149651 9.05247158 3.9451298 5.28096434 16.16395534] [[[15 16 2 0 2]
 [15 14 2 0 2]
 [15 14 3 0 6]
 [ 7 6 2 0 10]
 [15 14 2 0 2]]]....
```

الملخص

هذه هي الطريقة التي يمكنك بها تدريب نموذج الانحدار الخطي لمهمة تنبؤ درجات الطلاب باستخدام التعلم الآلي باستخدام بايثون. يمكنك القيام بالكثير باستخدام مجموعة البيانات هذه، ويمكنك العثور على المعلومات الكاملة حول مجموعة البيانات هذه من [هنا](#).

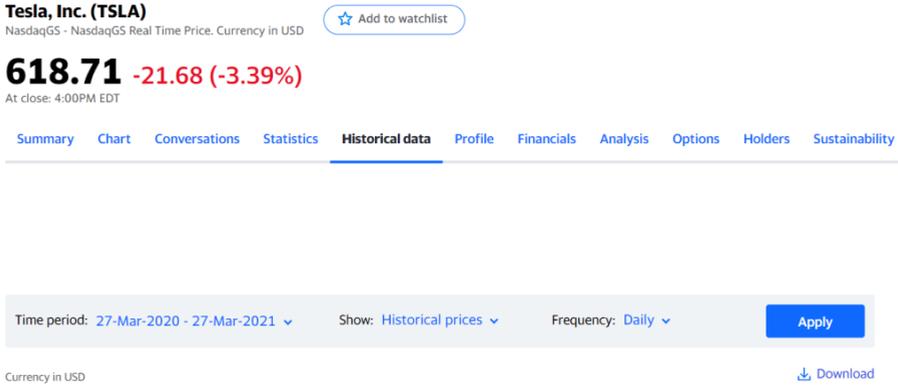
32) التنبؤ بسعر سهم Tesla مع التعلم الآلي Tesla Stock Price Prediction with Machine Learning

Tesla هي شركة أمريكية للسيارات تهدف إلى تسريع انتقال العالم نحو الطاقة المستدامة. قبل أيام قليلة من ارتفاع أسعار أسهم Tesla، جعل Elon Musk أغنى شخص في العالم. يُعد التنبؤ بأسعار الأسهم حالة استخدام رائعة للتعلم الآلي، لذلك في هذه المقالة، سوف آخذك خلال مهمة توقع أسعار أسهم Tesla مع التعلم الآلي باستخدام بايثون.

التنبؤ بسعر سهم Tesla مع التعلم الآلي

يعد التنبؤ بأسعار الأسهم حالة استخدام رائعة للتعلم الآلي لكل من تحليل السلاسل المالية والزمنية. كانت Tesla في عيون العالم لفترة طويلة الآن حيث تدعم حكومات العديد من البلدان في جميع أنحاء العالم رؤية Tesla. لذلك في هذه المقالة، سوف آخذك من خلال برنامج تعليمي حول كيفية استخدام نموذج Facebook Prophet لمهمة التنبؤ بسعر سهم Tesla.

تم تنزيل مجموعة البيانات التي سأستخدمها هنا من موقع yahoo finance. لتنزيل مجموعة البيانات هذه، ما عليك سوى زيارة موقع yahoo finance وابحث عن TSLA. ستري الداشبوردي كما هو موضح في الصورة أدناه:



هنا عليك النقر فوق الأسعار التاريخية ثم النقر فوق تنزيل. سيتم تنزيل مجموعة البيانات باسم "TSLA.csv".

التنبؤ بسعر سهم Tesla باستخدام لغة بايثون

أتمنى أن تكون قد قمت بتنزيل البيانات التاريخية لأسعار أسهم Tesla بسهولة باتباع الخطوات المذكورة في القسم أعلاه. دعنا الآن نرى كيفية توقع أسعار أسهم Tesla باستخدام التعلم الآلي باستخدام بايثون. سأبدأ هنا باستيراد مكتبات بايثون ومجموعة البيانات اللازمة:

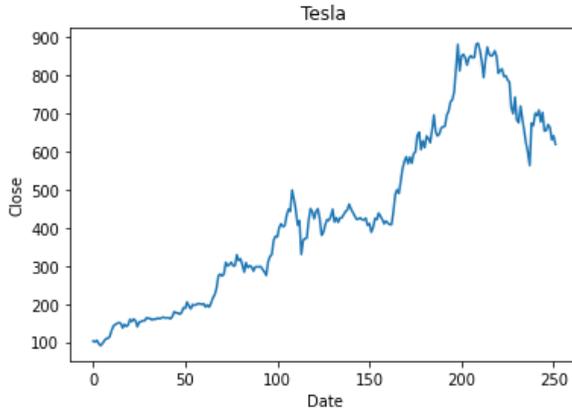
```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from fbprophet import Prophet

data = pd.read_csv("TSLA.csv")
data.head()
```

	Date	Open	High	Low	Close	Adj Close	Volume
0	2020-03-27	101.000000	105.160004	98.806000	102.872002	102.872002	71887000
1	2020-03-30	102.052002	103.330002	98.246002	100.426003	100.426003	59990500
2	2020-03-31	100.250000	108.592003	99.400002	104.800003	104.800003	88857500
3	2020-04-01	100.800003	102.790001	95.019997	96.311996	96.311996	66766000
4	2020-04-02	96.206001	98.851997	89.279999	90.893997	90.893997	99292000

قبل المضي قدماً، دعنا نتخيل عمود الإغلاق "Close" في مجموعة البيانات والذي يمثل أسعار الإغلاق لكل يوم:

```
close = data['Close']
ax = close.plot(title='Tesla')
ax.set_xlabel('Date')
ax.set_ylabel('Close')
plt.show()
```



نحتاج فقط إلى عمودين من مجموعة البيانات هذه (التاريخ والإغلاق)، لذا فلنقم بإنشاء إطار بيانات جديد بهذين العمودين فقط:

```
data["Date"] = pd.to_datetime(data["Date"],
infer_datetime_format=True)
data = data[["Date", "Close"]]
```

نظراً لأننا نستخدم نموذج Facebook prophet هنا للتنبؤ بأسعار أسهم Tesla، فنحن بحاجة إلى إعادة تسمية الأعمدة:

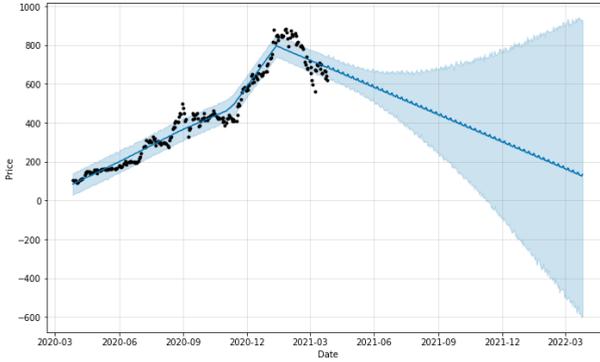
```
data = data.rename(columns={"Date" : "ds", "Close" : "y" })
```

لذلك قمنا بإعداد مجموعة البيانات لنموذج Facebook prophet، والآن دعونا نتنبأ بأسعار أسهم Tesla:

```
model = Prophet()
model.fit(data)
predict = model.make_future_dataframe( periods=365)
forecast = model.predict(predict)
forecast[["ds", "yhat", "yhat_lower", "yhat_upper"]].tail()
```

	ds	yhat	yhat_lower	yhat_upper
612	2022-03-22	131.630090	-585.268250	931.611531
613	2022-03-23	129.584278	-583.545636	935.285420
614	2022-03-24	127.202999	-593.418911	930.525966
615	2022-03-25	125.492270	-601.302243	924.233573
616	2022-03-26	134.596307	-595.884292	930.702026

```
graph = model.plot(forecast, xlabel="Date", ylabel="Price")
```



الملخص

يبدو أن أسعار أسهم Tesla ستنخفض في المستقبل القريب إذا لم يأتوا بفكرة جديدة تمثل رؤيتهم. قد يكون هذا ممكناً لأن الشركات الأخرى بدأت أيضاً في تصنيع السيارات الكهربائية بسعر منخفض جداً مقارنةً بـ Tesla. آمل أن تكون قد أحببت هذه المقالة حول مهمة التنبؤ بأسعار أسهم Tesla مع التعلم الآلي باستخدام بايثون.

33 التنبؤ بمعدل النقر للظهور من خلال التعلم الآلي Click-Through Rate Prediction with Machine Learning

في أي وكالة إعلانية، من المهم جداً توقع المستخدمين الأكثر ربحية والذين من المرجح جداً أن يستجيبوا للإعلانات المستهدفة. في هذه المقالة، سوف أطلعك على كيفية تدريب نموذج لمهمة التنبؤ بمعدل النقر (click-through rate prediction) باستخدام التعلم الآلي باستخدام بايثون.

نموذج التنبؤ بمعدل النقر مع التعلم الآلي

من خلال توقع نسبة النقر إلى الظهور، تختار شركة إعلانات الزائرين المحتملين الذين من المرجح أن يستجيبوا للإعلانات، وتحلل سجل التصفح الخاص بهم وتعرض الإعلانات الأكثر صلة بناءً على اهتمام المستخدم.

هذه المهمة مهمة لكل وكالة إعلانية لأن القيمة التجارية للترويج على الإنترنت تعتمد فقط على كيفية استجابة المستخدم لها. تُعد استجابة المستخدم للإعلانات ذات قيمة كبيرة لكل شركة إعلانية لأنها تتيح للشركة تحديد الإعلانات الأكثر صلة بالمستخدمين.

في القسم أدناه، سوف آخذك إلى كيفية إنشاء نموذج لمهمة التنبؤ بمعدل النقر باستخدام التعلم الآلي باستخدام بايثون. هذه المهمة مهمة جداً لأولئك الذين يرغبون في العمل كعالم بيانات في أي شركة تتعامل مع إعلانات مثل Google و Facebook.

نموذج التنبؤ بمعدل النقر باستخدام بايثون

لنبدأ الآن في مهمة نموذج للتنبؤ بمعدل النقر إلى الظهور باستخدام التعلم الآلي عن طريق استيراد مجموعة البيانات:

```
import pandas as pd
data = pd.read_csv('advertising.csv')
print(data.head())
```

	Daily Time Spent on Site	Age	...	Timestamp	Clicked on Ad
0	68.95	35	...	2016-03-27 00:53:11	0
1	80.23	31	...	2016-04-04 01:39:02	0
2	69.47	26	...	2016-03-13 20:35:42	0
3	74.15	29	...	2016-01-10 02:31:19	0
4	68.37	35	...	2016-06-03 03:36:18	0

[5 rows x 10 columns]

دعنا الآن نلقي نظرة على البيانات لمعرفة ما إذا كان لدينا أي قيم فارغة في مجموعة البيانات:

```
print(data.isnull().sum())
```

```
Daily Time Spent on Site    0
Age                        0
Area Income                 0
Daily Internet Usage       0
Ad Topic Line              0
City                       0
Male                      0
Country                    0
Timestamp                  0
Clicked on Ad              0
dtype: int64
```

قبل المضي قدماً، دعنا نلقي نظرة على أسماء جميع الأعمدة في مجموعة البيانات:

```
print(data.columns)
```

```
Index(['Daily Time Spent on Site', 'Age', 'Area Income',
       'Daily Internet Usage', 'Ad Topic Line', 'City', 'Male', 'Country',
       'Timestamp', 'Clicked on Ad'],
      dtype='object')
```

دعنا الآن نحضر البيانات حتى نتمكن من التوافق بسهولة مع نموذج التعلم الآلي. سنقوم هنا بإسقاط بعض الأعمدة غير الضرورية:

```
x=data.iloc[0:7,:]
x=x.drop(['Ad Topic Line','City'],axis=1)
x
```

```
↳
```

	Daily Time Spent on Site	Age	Area Income	Daily Internet Usage	Male
0	68.95	35	61833.90	256.09	0
1	80.23	31	68441.85	193.77	1
2	69.47	26	59785.94	236.50	0
3	74.15	29	54806.18	245.89	1
4	68.37	35	73889.99	225.58	0
...
995	72.97	30	71384.57	208.58	1
996	51.30	45	67782.17	134.42	1
997	51.63	51	42415.72	120.37	1
998	55.55	19	41920.79	187.95	0
999	45.01	26	29875.80	178.35	0

1000 rows × 5 columns

```
y=data.iloc[:,9]
y
```

```

0    0
1    0
2    0
3    0
4    0
..
995  1
996  1
997  1
998  0
999  1
Name: Clicked on Ad, Length: 1000, dtype: int64

```

الآن سأقسم البيانات إلى مجموعات تدريب واختبار. سأستخدم هنا 70 في المائة من البيانات كتدريب و30 في المائة كاختبار:

```

from sklearn.model_selection import train_test_split
x_train,x_test,y_train,y_test=train_test_split(x,y,test_size=0
.3,random_state=4)
print(x_train.shape)
print(y_train.shape)
print(x_test.shape)
print(y_test.shape)

```

```

(700, 5)
(700,)
(300, 5)
(300,)

```

نموذج الانحدار اللوجستي:

سأستخدم الآن نموذج الانحدار اللوجستي (**logistic regression**) للتنبؤ بنسبة النقر إلى الظهور للمستخدمين:

```

from sklearn.linear_model import LogisticRegression
Lr=LogisticRegression(C=0.01,random_state=0)
Lr.fit(x_train,y_train)
y_pred=Lr.predict(x_test)
print(y_pred)

```

```

[0 0 0 1 1 0 0 1 0 1 1 1 0 0 0 1 1 0 1 0 1 1 1 0 1 1 1 0 0 1 0 0 0 1 1 1 1 0 1 1
0 1 0 0 1 0 1 0 1 0 1 0 0 0 0 1 1 1 0 1 0 1 0 0 0 1 1 1 1 1 0 1 0 0 0 0 1 1 0 0 0
0 1 1 1 1 0 1 0 1 0 0 0 0 1 0 1 0 0 1 0 0 1 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 1 1 0
1 0 0 1 1 1 0 0 1 0 1 1 1 0 1 1 1 0 0 1 1 0 0 0 0 0 0 1 0 0 1 0 1 1 1 0 0 0 1 0 0
1 0 0 1 0 0 1 0 0 1 0 0 0 0 1 1 1 1 1 1 0 1 1 0 0 1 0 1 0 0 0 1 1 1 0 0 0 1 0
0 1 0 1 0 1 1 1 1 0 1 1 1 0 0 0 1 0 0 0 0 0 0 0 1 0 0 0 0 0 1 1 1 1 1 1 1 1 0
0 1 0 0 0 1 1 0 0 0 0 1 0 1 0 0 1 1 1 0 0 0 1 1 0 1 1 0 1 1 0 1 1 1 1 1 1 1
1 0 1 0 1 0 0 1 0 0 0 1 1 1 1 0 1 0 1 0 1 0 0 0 0 0 0 1 0 0 1 0 1 1 1 1 0 0 1
1 0 0 0]

```

```

y_pred_proba=Lr.predict_proba(x_test)
print(y_pred_proba)
[9.56377730e-01 4.36222698e-02]
[4.57913871e-02 9.54208613e-01]
[9.90680226e-01 9.31977394e-03]
[4.52921708e-03 9.95470783e-01]
[9.53422807e-01 4.65771934e-02]
[4.93413634e-01 5.06586366e-01]
[9.27749026e-01 7.22509737e-02]
[9.88127401e-01 1.18725991e-02]
[8.38452014e-01 1.61547986e-01]
[8.36925286e-01 1.63074714e-01]
[9.80069836e-01 1.99301643e-02]
[9.65651589e-01 3.43484110e-02]
[6.84448458e-02 9.31555154e-01]
[9.87522934e-01 1.24770659e-02]
[9.17172887e-01 8.28271130e-02]
[2.43751163e-01 7.56248837e-01]
[9.37078134e-01 6.29218662e-02]
[2.82792965e-02 9.71720703e-01]
[2.72748965e-01 7.27251035e-01]
[3.00015981e-02 9.69998402e-01]
[9.85498737e-01 1.45012626e-02]
[9.82428592e-01 1.75714076e-02]
[3.70265237e-03 9.96297348e-01]
[7.99116022e-02 9.20088398e-01]
[9.09972207e-01 9.00277931e-02]
[9.44866412e-01 5.51335881e-02]
[9.84521236e-01 1.54787639e-02]]

```

الآن دعنا نلقي نظرة على دقة النموذج:

```

from sklearn.metrics import accuracy_score
print(accuracy_score(y_test,y_pred))

```

```
0.8733333333333333
```

لذلك لدينا دقة تبلغ حوالي 87 في المائة وهي ليست سيئة لهذا النوع من المشاكل. أخيراً، دعونا نلقي نظرة على نتيجة f1 score:

```

from sklearn.metrics import f1_score
print(f1_score(y_test,y_pred))

```

```
0.8652482269503545
```

أمل أن تكون قد أحببت هذه المقالة حول نموذج التنبؤ بنسبة النقر إلى الظهور مع التعلم الآلي باستخدام بايثون.

34 اكتشاف السخرية مع التعلم الآلي Sarcasm Detection with Machine Learning

كانت السخرية Sarcasm جزءًا من لغتنا لسنوات عديدة. هذا يعني أن تكون عكس ما تعنيه، عادةً بنبرة صوت مميزة بطريقة ممتعة. إذا كنت تعتقد أن أي شخص يمكنه فهم السخرية، فأنت مخطئ، لأن فهم السخرية يعتمد على مهاراتك اللغوية ومعرفتك بعقول الآخرين. لكن ماذا عن الكمبيوتر؟ هل من الممكن تدريب نموذج للتعلم الآلي يمكنه اكتشاف ما إذا كانت الجملة ساخرة أم لا؟ نعم إنه كذلك! لذلك إذا كنت تريد معرفة كيفية اكتشاف السخرية Sarcasm detection باستخدام التعلم الآلي، فهذه المقالة مناسبة لك. في هذه المقالة، سوف أطلعك على مهمة اكتشاف السخرية باستخدام التعلم الآلي باستخدام بايثون.

اكتشاف السخرية مع التعلم الآلي

السخرية تعني أن تكون مضحكا بأن تكون عكس ما تعنيه. لقد كانت جزءًا من كل لغة بشرية لسنوات. اليوم، يتم استخدامه أيضًا في عناوين الأخبار والعديد من منصات التواصل الاجتماعي الأخرى لجذب المزيد من الاهتمام. اكتشاف السخرية هو معالجة لغة طبيعية ومهمة تصنيف ثنائي. يمكننا تدريب نموذج التعلم الآلي لاكتشاف ما إذا كانت الجملة ساخرة أم لا باستخدام مجموعة بيانات من الجمل الساخرة وغير الساخرة التي وجدتها في Kaggle.

أتمنى أن تكون قد فهمت الآن ما هي السخرية. في القسم أدناه، سأوجهك خلال مهمة اكتشاف السخرية من خلال التعلم الآلي باستخدام لغة برمجة بايثون. يمكن تنزيل مجموعة البيانات التي أستخدمها لهذه المهمة من [هنا](#).

اكتشاف السخرية باستخدام بايثون

لنبدأ الآن بمهمة اكتشاف السخرية باستخدام التعلم الآلي باستخدام بايثون. سأبدأ هذه المهمة عن طريق استيراد مكتبات بايثون ومجموعة البيانات الضرورية:

```
import pandas as pd
import numpy as np
from sklearn.feature_extraction.text import CountVectorizer
from sklearn.model_selection import train_test_split
from sklearn.naive_bayes import BernoulliNB

data = pd.read_json("Sarcasm.json", lines=True)
print(data.head())
```

```

      article_link ... is_sarcastic
0 https://www.huffingtonpost.com/entry/versace-b... ...      0
1 https://www.huffingtonpost.com/entry/roseanne-... ...      0
2 https://local.theonion.com/mom-starting-to-fea... ...      1
3 https://politics.theonion.com/boehner-just-wan... ...      1
4 https://www.huffingtonpost.com/entry/jk-rowlin... ...      0

[5 rows x 3 columns]

```

يحتوي عمود "is_sarcastic" في مجموعة البيانات هذه على التسميات التي يتعين علينا توقعها لمهمة اكتشاف السخرية. يحتوي على قيم ثنائية مثل 1 و 0، حيث 1 تعني ساخرة sarcastic و 0 ليست ساخرة not sarcastic. من أجل التبسيط، سأحول قيم هذا العمود إلى "sarcastic" و "not sarcastic" بدلاً من 1 و 0:

```

data["is_sarcastic"] = data["is_sarcastic"].map({0: "Not Sarcasm", 1:
"Sarcasm"})
print(data.head())

```

```

      article_link ... is_sarcastic
0 https://www.huffingtonpost.com/entry/versace-b... ... Not Sarcasm
1 https://www.huffingtonpost.com/entry/roseanne-... ... Not Sarcasm
2 https://local.theonion.com/mom-starting-to-fea... ... Sarcasm
3 https://politics.theonion.com/boehner-just-wan... ... Sarcasm
4 https://www.huffingtonpost.com/entry/jk-rowlin... ... Not Sarcasm

[5 rows x 3 columns]

```

دعنا الآن نجهز البيانات لتدريب نموذج التعلم الآلي. تحتوي مجموعة البيانات هذه على ثلاثة أعمدة، نحتاج منها فقط إلى عمود "headline" كميزة والعمود "is_sarcastic" كتسمية. لذلك دعونا نحدد هذه الأعمدة ونقسم البيانات إلى مجموعة اختبار 20٪ ومجموعة تدريب 80٪:

```

data = data[["headline", "is_sarcastic"]]
x = np.array(data["headline"])
y = np.array(data["is_sarcastic"])

cv = CountVectorizer()
X = cv.fit_transform(x) # Fit the Data
X_train, X_test, y_train, y_test = train_test_split(X, y,
test_size=0.20, random_state=42)

```

سأستخدم الآن خوارزمية **Bernoulli Naive Bayes** لتدريب نموذج لمهمة اكتشاف السخرية:

```

model = BernoulliNB()
model.fit(X_train, y_train)
print(model.score(X_test, y_test))

```

```
0.8448146761512542
```

دعنا الآن نستخدم نصًا ساخرًا كمدخلات لاختبار ما إذا كان نموذج التعلم الآلي لدينا يكتشف السخرية أم لا:

```
user = input("Enter a Text: ")
data = cv.transform([user]).toarray()
output = model.predict(data)
print(output)
```

```
Enter a Text: Cows lose their jobs as milk prices drop
['Sarcasm']
```

الملخص

هذه هي الطريقة التي يمكنك بها استخدام التعلم الآلي لاكتشاف السخرية باستخدام لغة برمجة بايثون. كانت السخرية جزءاً من لغتنا لسنوات عديدة. هذا يعني أن تكون عكس ما تعنيه، عادةً بنبرة صوت مميزة بطريقة ممتعة. أتمنى أن تكون قد أحببت هذه المقالة حول مهمة اكتشاف السخرية باستخدام التعلم الآلي باستخدام بايثون.

35 التنبؤ بمتابعي وسائل التواصل الاجتماعي باستخدام Social Media Followers Prediction with Machine Learning

يوجد اليوم العديد من منصات الوسائط الاجتماعية حيث ستجد العديد من منشئي المحتوى في العديد من أنواع المجالات. بصفتك مستهلكاً لوسائل التواصل الاجتماعي، قد لا يكون عدد المتابعين لديك محل اهتمامك، ولكن بصفتك منشئ محتوى أو كرجل أعمال، فإن عدد المتابعين لديك مهم للوصول إلى المحتوى الخاص بك لمزيد من الجمهور. لذا، فإن مهمة التنبؤ بمتابعي وسائل التواصل الاجتماعي مهمة جداً لكل منشئ محتوى وكل عمل يعتمد على وسائل التواصل الاجتماعي. لذلك إذا كنت تريد معرفة كيفية التنبؤ بمتابعيك على وسائل التواصل الاجتماعي للشهر المقبل، فهذه المقالة مناسبة لك. في هذه المقالة، سوف أطلعك على مهمة التنبؤ بمتابعي وسائل التواصل الاجتماعي مع التعلم الآلي باستخدام بايثون.

التنبؤ بمتابعي وسائل التواصل الاجتماعي

للتنبؤ بالزيادة في عدد المتابعين الذين يمكن أن تتوقع رؤيتهم، فأنت بحاجة إلى مجموعة بيانات لمتابعيك على وسائل التواصل الاجتماعي والتي يمكن أن تعرض لك أنشطة الأشخاص في حسابك على وسائل التواصل الاجتماعي مثل:

1. كم عدد الأشخاص الذين تابعوك كل شهر.
2. عدد المشاهدات الناتجة عن عدد المتابعين.
3. كم من متابعيك يلغون متابعتك كل شهر.

لذلك من الصعب جداً العثور على مجموعة البيانات هذه بين أكثر منصات التواصل الاجتماعي شيوعاً مثل Facebook و Instagram لأن هذه المنصات لا توفر أي بيانات متعلقة بمتابعيك. لذلك بالنسبة لمهمة توقع متابعي وسائل التواصل الاجتماعي مع التعلم الآلي، قمت بجمع البيانات من حساب الوسائط الاجتماعية الخاص بي على Medium، وهو عبارة عن منصة وسائط اجتماعية لكتاب المحتوى والمدونين والباحثين. يمكنك استخدام نفس العملية في مجموعة البيانات الخاصة بك سواء حصلت عليها من Medium أو Instagram أو أي تطبيق وسائط اجتماعية آخر للتنبؤ بمتابعيك على وسائل التواصل الاجتماعي. للممارسة، يمكنك استخدام نفس مجموعة البيانات التي أستخدمها.

التنبؤ بمتابعي الوسائط الاجتماعية باستخدام بايثون

سأبدأ مهمة التنبؤ بمتابعي وسائل التواصل الاجتماعي باستخدام التعلم الآلي عن طريق استيراد مكتبات بايثون الضرورية و**مجموعة البيانات** التي جمعتها عن متابعيني من Medium:

```
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
import numpy as np

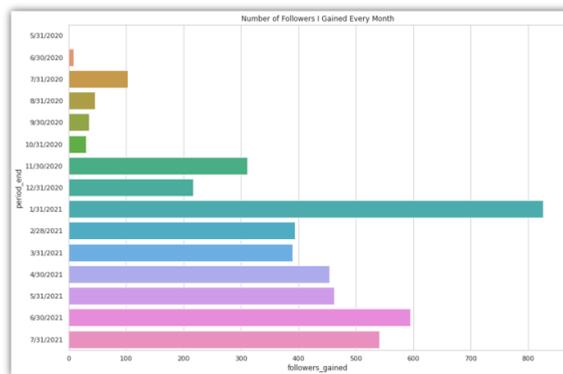
data = pd.read_csv("stats.csv")
data.drop(data.tail(1).index, inplace=True)
data.head()
```

```
   period_start period_end ... subscribers_total  views
0  5/1/2020  5/31/2020 ...           0  128.0
1  6/1/2020  6/30/2020 ...           0  16130.0
2  7/1/2020  7/31/2020 ...           0  14616.0
3  8/1/2020  8/31/2020 ...           0  4053.0
4  9/1/2020  9/30/2020 ...           0  5153.0

[5 rows x 11 columns]
```

في السطر السابع من الكود أعلاه، قمت بحذف الصف الأخير من مجموعة البيانات لأنه يحتوي على بيانات حول هذا الشهر. الآن سألقي نظرة على عدد المتابعين الذين اكتسبهم كل شهر على حسابي منذ أن انضمت إلى منصة التواصل الاجتماعي هذه:

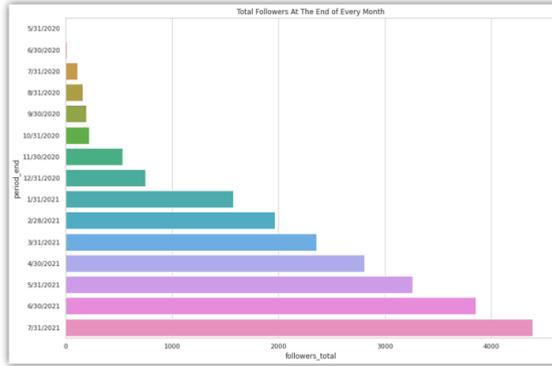
```
plt.figure(figsize=(15, 10))
sns.set_theme(style="whitegrid")
plt.title("Number of Followers I Gained Every Month")
sns.barplot(x="followers_gained", y="period_end", data=data)
plt.show()
```



الآن دعنا نلقي نظرة على العدد الإجمالي للمتابعين الذين ينتهي بي الأمر معهم كل شهر:

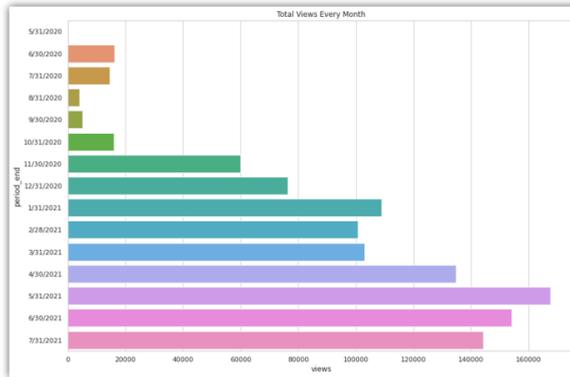
```
plt.figure(figsize=(15, 10))
sns.set_theme(style="whitegrid")
plt.title("Total Followers At The End of Every Month")
```

```
sns.barplot(x="followers_total", y="period_end", data=data)
plt.show()
```



دعنا الآن نلقي نظرة على إحدى أهم الميزات، وهي إجمالي عدد المشاهدات التي أحصل عليها كل شهر:

```
plt.figure(figsize=(15, 10))
sns.set_theme(style="whitegrid")
plt.title("Total Views Every Month")
sns.barplot(x="views", y="period_end", data=data)
plt.show()
```



سأستخدم الآن مكتبة **autots** في بايثون، والتي تعد واحدة من أفضل مكتبات علوم البيانات للتنبؤ بالسلسلة الزمنية (**time series forecasting**). إذا لم تكن قد استخدمت هذه المكتبة من قبل، فيمكنك تشبيتها بسهولة على نظامك باستخدام الأمر **pip**:

```
pip install autots
```

الآن إليك كيف يمكننا توقع الزيادة في عدد المتابعين الذين نتوقع رؤيتهم خلال الأشهر الأربعة المقبلة:

```
from autots import AutoTS
model = AutoTS(forecast_length=4, frequency='infer',
ensemble='simple')
```

```
model = model.fit(data, date_col='period_end',  
value_col='followers_gained', id_col=None)  
prediction = model.predict()  
forecast = prediction.forecast  
print (forecast)
```

	followers_gained
2021-08-31	693.465876
2021-09-30	617.750000
2021-10-31	650.000000
2021-11-30	634.750000

الملخص

إذن هذه هي الطريقة التي يمكنك بها توقع الزيادة في عدد متابعيك على أي منصة وسائط اجتماعية. بصفتك مستهلكاً لوسائل التواصل الاجتماعي، قد لا يكون عدد المتابعين لديك محل اهتمامك، ولكن بصفتك منشئ محتوى أو كرجل أعمال، فإن عدد المتابعين لديك مهم للوصول إلى المحتوى الخاص بك لمزيد من الجمهور. أأمل أن تكون قد أحببت هذه المقالة حول مهمة التنبؤ بمتابعي وسائل التواصل الاجتماعي مع التعلم الآلي باستخدام بايثون.

36 اكتشاف خطاب الكراهية باستخدام التعلم الآلي Hate Speech Detection with Machine Learning

يعتبر خطاب الكراهية (Hate speech) من القضايا الخطيرة التي نراها يومياً على منصات التواصل الاجتماعي مثل Facebook و Twitter. يمكن العثور على معظم المنشورات التي تحتوي على خطاب كراهية في حسابات الأشخاص ذوي الآراء السياسية. لذلك، إذا كنت تريد معرفة كيفية تدريب نموذج اكتشاف خطاب الكراهية باستخدام التعلم الآلي، فهذه المقالة مناسبة لك. في هذه المقالة، سأوجهك خلال مهمة اكتشاف خطاب الكراهية باستخدام التعلم الآلي باستخدام بايثون.

اكتشاف خطاب الكراهية باستخدام التعلم الآلي

لا يوجد تعريف قانوني لخطاب الكراهية لأنه لا يمكن بسهولة تصنيف آراء الأشخاص على أنها بغیضة أو مسيئة. ومع ذلك، تُعرّف الأمم المتحدة خطاب الكراهية بأنه أي نوع من الاتصالات اللفظية أو الكتابية أو السلوكية التي يمكن أن تهاجم أو تستخدم لغة تمييزية تجاه شخص أو مجموعة من الأشخاص بناءً على هويتهم على أساس الدين أو العرق أو الجنسية أو العرق أو اللون أو النسب. أو الجنس أو أي عامل هوية آخر.

أمل أن تكون قد فهمت الآن ما هو خطاب الكراهية. تحتاج منصات وسائل التواصل الاجتماعي إلى اكتشاف خطاب الكراهية ومنع انتشاره أو حظره في الوقت المناسب. لذلك في القسم أدناه، سأوجهك خلال مهمة اكتشاف الكلام الذي يحض على الكراهية باستخدام التعلم الآلي باستخدام لغة برمجة بايثون.

اكتشاف خطاب الكراهية باستخدام بايثون

يتم تنزيل مجموعة البيانات التي أستخدمها لمهمة اكتشاف خطاب الكراهية من Kaggle. تم جمع مجموعة البيانات هذه في الأصل من Twitter وتحتوي على الأعمدة التالية:

1. فهرس (index).
2. عدد (count).
3. خطاب الكراهية (hate_speech).
4. لغة بذيئة (offensive_language).
5. لا هذا ولا ذاك (neither).

6. فئة (class).

7. تغريدة (tweet).

فلنبدأ باستيراد جميع مكتبات بايثون ومجموعة البيانات اللازمة لهذه المهمة:

```
from nltk.util import pr
import pandas as pd
import numpy as np
from sklearn.feature_extraction.text import CountVectorizer
from sklearn.model_selection import train_test_split
from sklearn.tree import DecisionTreeClassifier
import re
import nltk
stemmer = nltk.SnowballStemmer("english")
from nltk.corpus import stopwords
import string
stopword=set(stopwords.words('english'))
data = pd.read_csv("twitter.csv")
print(data.head())
```

Unnamed: 0	count	hate_speech	offensive_language	neither	class	\
0	0	3	0	0	3	2
1	1	3	0	3	0	1
2	2	3	0	3	0	1
3	3	3	0	2	1	1
4	4	6	0	6	0	1

tweet

```
0 !!! RT @mayasolovely: As a woman you shouldn't...
1 !!!!! RT @mleew17: boy dats cold...tyga dwn ba...
2 !!!!!!! RT @UrKindOfBrand Dawg!!!! RT @80sbaby...
3 !!!!!!!! RT @C_G_Anderson: @viva_based she lo...
4 !!!!!!!!!!!!!!! RT @ShenikaRoberts: The shit you...
```

سأضيف عموداً جديداً إلى مجموعة البيانات هذه كعناوين تحتوي على القيم على النحو التالي:

1. خطاب الكراهية (Hate Speech).

2. لغة بذيئة (Offensive Language).

3. لا كره ومهينه (No Hate and Offensive).

```
data["labels"] = data["class"].map({0: "Hate Speech",
                                     1: "Offensive Language",
                                     2: "No Hate and
Offensive"})
print(data.head())
```

Unnamed: 0	count	hate_speech	offensive_language	neither	class	\
0	0	3	0	0	3	2
1	1	3	0	3	0	1
2	2	3	0	3	0	1
3	3	3	0	2	1	1
4	4	6	0	6	0	1

	tweet	labels
0	!!! RT @mayasolovely: As a woman you shouldn't...	No Hate and Offensive
1	!!!! RT @mleew17: boy dats cold...tyga dwn ba...	Offensive Language
2	!!!!!! RT @UrKindOfBrand Dawg!!!! RT @80sbaby...	Offensive Language
3	!!!!!!! RT @C_G_Anderson: @viva_based she lo...	Offensive Language
4	!!!!!!!!!!!! RT @ShenikaRoberts: The shit you...	Offensive Language

الآن سأختار فقط أعمدة التغريدات والتسميات لبقية مهمة تدريب نموذج اكتشاف خطاب الكراهية:

```
data = data[["tweet", "labels"]]
print(data.head())
```

	tweet	labels
0	!!! RT @mayasolovely: As a woman you shouldn't...	No Hate and Offensive
1	!!!! RT @mleew17: boy dats cold...tyga dwn ba...	Offensive Language
2	!!!!!! RT @UrKindOfBrand Dawg!!!! RT @80sbaby...	Offensive Language
3	!!!!!!! RT @C_G_Anderson: @viva_based she lo...	Offensive Language
4	!!!!!!!!!!!! RT @ShenikaRoberts: The shit you...	Offensive Language

الآن سوف أقوم بإنشاء دالة لتنظيف النصوص في عمود التغريدة (`tweet column`):

```
def clean(text):
    text = str(text).lower()
    text = re.sub('[\.\*\?\\]', '', text)
    text = re.sub('https?://\S+|www\.\S+', '', text)
    text = re.sub('<.*?>+', '', text)
    text = re.sub('[%s]' % re.escape(string.punctuation), '',
text)
    text = re.sub('\n', '', text)
    text = re.sub('\w*\d\w*', '', text)
    text = [word for word in text.split(' ') if word not in
stopword]
    text=" ".join(text)
    text = [stemmer.stem(word) for word in text.split(' ')]
    text=" ".join(text)
    return text
data["tweet"] = data["tweet"].apply(clean)
```

فلنقم الآن بتقسيم مجموعة البيانات إلى مجموعات تدريب واختبار وتدريب نموذج التعلم الآلي لمهمة اكتشاف الكلام الذي يحض على الكراهية:

```
x = np.array(data["tweet"])
y = np.array(data["labels"])

cv = CountVectorizer()
```

```
X = cv.fit_transform(x) # Fit the Data
X_train, X_test, y_train, y_test = train_test_split(X, y,
test_size=0.33, random_state=42)

clf = DecisionTreeClassifier()
clf.fit(X_train,y_train)
```

دعنا الآن نختبر نموذج التعلم الآلي هذا لمعرفة ما إذا كان يكتشف الكلام الذي يحض على الكراهية أم لا:

```
sample = "Let's unite and kill all the people who are
protesting against the government"
data = cv.transform([sample]).toarray()
print(clf.predict(data))
```

```
['Hate Speech']
```

الملخص

هذه هي الطريقة التي يمكنك بها تدريب نموذج التعلم الآلي على مهمة اكتشاف خطاب الكراهية باستخدام لغة برمجة بايثون. يعتبر خطاب الكراهية من القضايا الخطيرة التي نراها يومياً على منصات التواصل الاجتماعي مثل Facebook و Twitter. يمكن العثور على معظم المنشورات التي تحتوي على خطاب كراهية في حسابات الأشخاص ذوي الآراء السياسية. أتمنى أن تكون قد أحببت هذه المقالة حول مهمة اكتشاف خطاب الكراهية باستخدام التعلم الآلي باستخدام بايثون.

37) التنبؤ بسعر Dogecoin مع التعلم الآلي Dogecoin Price Prediction with Machine Learning

Dogecoin هو سبب الانخفاض الأخير في أسعار Bitcoin. سعر Dogecoin رخيص جداً حالياً مقارنة بعملة Bitcoin، لكن بعض الخبراء الماليين، بما في ذلك الرئيس التنفيذي لشركة Tesla Elon Musk، يزعمون أننا سنشهد ارتفاعاً في سعر Dogecoin قريباً. لذا، إذا كنت تريد معرفة كيفية التنبؤ بالأسعار المستقبلية لـ Dogecoin، فهذه المقالة مناسبة لك. في هذه المقالة، سوف أطلعك على مهمة توقع أسعار Dogecoin مع التعلم الآلي باستخدام بايثون.

التنبؤ بسعر Dogecoin

يعد التنبؤ بسعر العملة المشفرة مشكلة انحدار (regression) في التعلم الآلي. تعد Bitcoin واحدة من أكثر الأمثلة نجاحاً على العملات المشفرة، لكننا شهدنا مؤخراً انخفاضاً كبيراً في أسعار Bitcoin بسبب Dogecoin. على عكس Bitcoin، تعتبر عملة Dogecoin رخيصة جداً في الوقت الحالي، لكن الخبراء الماليين يتوقعون أننا قد نشهد زيادة كبيرة في أسعار Dogecoin.

هناك العديد من مناهج التعلم الآلي التي يمكننا استخدامها لمهمة التنبؤ بسعر Dogecoin. يمكنك تدريب نموذج التعلم الآلي أو يمكنك أيضاً استخدام نموذج قوي متاح بالفعل مثل نموذج Facebook Prophet. لكن في القسم أدناه، سأستخدم مكتبة autots في بايثون لمهمة التنبؤ بأسعار Dogecoin مع التعلم الآلي.

التنبؤ بسعر Dogecoin باستخدام بايثون

للتنبؤ بأسعار Dogecoin المستقبلية، تحتاج أولاً إلى الحصول على مجموعة بيانات لهذه المهمة. لذلك للحصول على مجموعة بيانات لمهمة التنبؤ بسعر Dogecoin، ما عليك سوى اتباع الخطوات المذكورة أدناه:

1. قم بزيارة Yahoo Finance.
2. ابحث عن "Dogecoin".
3. انقر فوق "البيانات التاريخية Historical Data".
4. انقر فوق "تنزيل Download".

بعد الانتهاء من الخطوات المذكورة أعلاه، ستجد مجموعة بيانات بالأسعار التاريخية لـ Dogecoin في مجلد التنزيلات الخاص بك. لنبدأ الآن بمهمة توقع أسعار Dogecoin عن طريق استيراد مكتبات بايثون ومجموعة البيانات اللازمة:

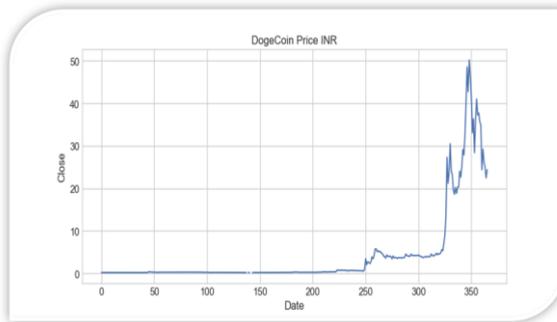
```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
from seaborn import regression
sns.set()
plt.style.use('seaborn-whitegrid')

data = pd.read_csv("Dogecoin.csv")
print(data.head())
```

	Date	Open	High	Low	Close	Adj Close	Volume
0	2020-05-24	0.193350	0.194625	0.186274	0.186783	0.186783	1.418502e+10
1	2020-05-25	0.186607	0.193194	0.185048	0.192753	0.192753	1.628989e+10
2	2020-05-26	0.192689	0.192902	0.186774	0.187698	0.187698	1.400234e+10
3	2020-05-27	0.187635	0.191591	0.187006	0.190508	0.190508	1.413078e+10
4	2020-05-28	0.190621	0.193574	0.188966	0.191035	0.191035	1.667015e+10

في مجموعة البيانات هذه، يحتوي عمود الإغلاق (**close**) على القيم التي نريد التنبؤ بقيمتها المستقبلية، لذلك دعونا نلقي نظرة فاحصة على القيم التاريخية لأسعار إغلاق Dogecoin:

```
data.dropna()
plt.figure(figsize=(10, 4))
plt.title("DogeCoin Price INR")
plt.xlabel("Date")
plt.ylabel("Close")
plt.plot(data["Close"])
plt.show()
```



سأستخدم الآن مكتبة **autots** في بايثون لتدريب نموذج التعلم الآلي للتنبؤ بالأسعار المستقبلية لـ Dogecoin. إذا لم تكن قد استخدمت هذه المكتبة من قبل، فيمكنك تثبيتها بسهولة في نظامك باستخدام الأمر **pip**:

```
pip install autots
```

الآن دعنا ندرّب نموذج التنبؤ بأسعار Dogecoin ونلقي نظرة على الأسعار المستقبلية لـ Dogecoin:

```
from autots import AutoTS
```

```

model = AutoTS(forecast_length=10, frequency='infer',
ensemble='simple', drop_data_older_than_periods=200)
model = model.fit(data, date_col='Date', value_col='Close',
id_col=None)

prediction = model.predict()
forecast = prediction.forecast
print("DogeCoin Price Prediction")
print(forecast)

```

```

DogeCoin Price Prediction
      Close
2021-05-25  23.625960
2021-05-26  24.655236
2021-05-27  24.642397
2021-05-28  25.270966
2021-05-29  26.182042
2021-05-30  26.204409
2021-05-31  27.254508
2021-06-01  28.709306
2021-06-02  29.425843
2021-06-03  29.497685

```

الملخص

هناك العديد من مناهج التعلم الآلي التي يمكننا استخدامها لمهمة التنبؤ بالأسعار المستقبلية لـ Dogecoin. في هذه المقالة، قدمت لك كيف يمكنك التنبؤ بالأسعار المستقبلية لـ Dogecoin باستخدام مكتبة autots في بايثون. آمل أن تكون قد أحببت هذه المقالة حول كيفية التنبؤ بالأسعار المستقبلية لـ Dogecoin باستخدام التعلم الآلي باستخدام بايثون.

38 تصنيف إعلانات وسائل التواصل الاجتماعي مع التعلم الآلي Social Media Ads Classification with Machine Learning

يتعلق تصنيف إعلانات الوسائط الاجتماعية (Social Media Ads Classification) بتحليل الإعلانات لتصنيف ما إذا كان جمهورك المستهدف سيشتري المنتج أم لا. إنها حالة استخدام رائعة لعلوم البيانات في التسويق. لذلك، إذا كنت ترغب في معرفة كيفية تحليل إعلانات الوسائط الاجتماعية لتصنيف جمهورك المستهدف، فهذه المقالة مناسبة لك. في هذه المقالة، سوف أطلعك على مهمة تصنيف إعلانات الوسائط الاجتماعية مع التعلم الآلي باستخدام بايثون.

تصنيف إعلانات وسائل التواصل الاجتماعي

يعني تصنيف إعلانات الوسائط الاجتماعية تحليل إعلانات الوسائط الاجتماعية الخاصة بك للعثور على العملاء الأكثر ربحية لمنتجك والذين من المرجح أن يشتروا المنتج. في بعض الأحيان، لا يكون المنتج الذي تقدمه مناسباً لجميع الأشخاص عندما يتعلق الأمر بالعمر والدخل. على سبيل المثال، قد يرغب الشخص الذي يتراوح عمره بين 20 و 25 عامًا في الإنفاق على أغلفة الهواتف الذكية أكثر من الشخص الذي يتراوح عمره بين 40 و 45 عامًا.

وبالمثل، يمكن للشخص ذي الدخل المرتفع أن ينفق على السلع الكمالية أكثر مما ينفقه الشخص ذو الدخل المنخفض. إذن هذه هي الطريقة التي يمكن بها لأي شركة تحديد ما إذا كان الشخص سيشتري منتجهم أم لا عن طريق تصنيف إعلانات وسائل التواصل الاجتماعي الخاصة بهم. في القسم أدناه، سوف أطلعك على تصنيف إعلانات الوسائط الاجتماعية باستخدام التعلم الآلي باستخدام بايثون.

تصنيف إعلانات وسائل التواصل الاجتماعي باستخدام بايثون

يتم تنزيل مجموعة البيانات التي أستخدمها لمهمة تصنيف إعلانات الوسائط الاجتماعية من Kaggle. يحتوي على بيانات حول الحملة الإعلانية لمنتج ما على وسائل التواصل الاجتماعي. يحتوي على ميزات مثل:

1. عمر الجمهور المستهدف.
2. الراتب التقديري للجمهور المستهدف.
3. وما إذا كان الجمهور المستهدف قد اشترى المنتج أم لا.

لذلك دعونا نستورد مجموعة البيانات ومكتبات بايثون الضرورية لبدء هذه المهمة:

```
import numpy
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
import numpy as np
from sklearn.model_selection import train_test_split
from sklearn.tree import DecisionTreeClassifier
from sklearn.metrics import classification_report

data =
pd.read_csv("https://raw.githubusercontent.com/amankharwal/Web
site-data/master/social.csv")
print(data.head())
```

	Age	EstimatedSalary	Purchased
0	19	19000	0
1	35	20000	0
2	26	43000	0
3	27	57000	0
4	19	76000	0

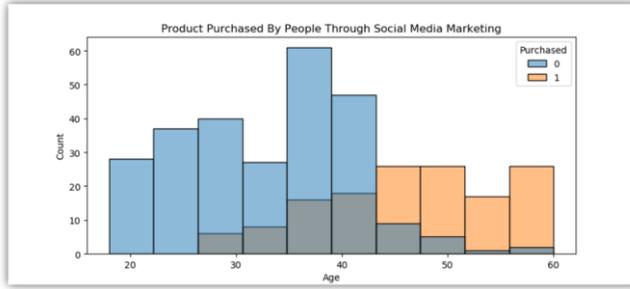
دعنا الآن نلقي نظرة على بعض الأفكار من البيانات لمعرفة ما إذا كنا بحاجة إلى إجراء أي تغييرات على مجموعة البيانات:

```
print(data.describe())
print(data.isnull().sum())
```

	Age	EstimatedSalary	Purchased
count	400.000000	400.000000	400.000000
mean	37.655000	69742.500000	0.357500
std	10.482877	34096.960282	0.479864
min	18.000000	15000.000000	0.000000
25%	29.750000	43000.000000	0.000000
50%	37.000000	70000.000000	0.000000
75%	46.000000	88000.000000	1.000000
max	60.000000	150000.000000	1.000000
Age	0		
EstimatedSalary	0		
Purchased	0		
dtype:	int64		

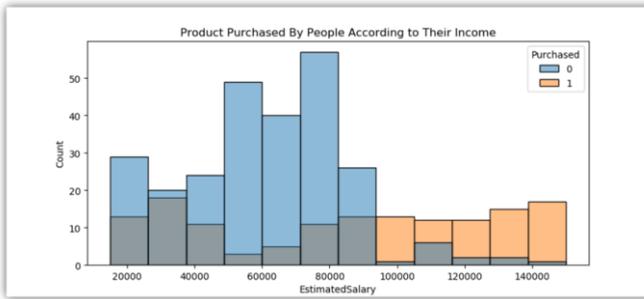
دعنا الآن نستكشف بعض الأنماط المهمة في مجموعة البيانات. أول ما أريد استكشافه هو أعمار الأشخاص الذين استجابوا لإعلانات وسائل التواصل الاجتماعي واشتروا المنتج:

```
plt.figure(figsize=(15, 10))
plt.title("Product Purchased By People Through Social Media
Marketing")
sns.histplot(x="Age", hue="Purchased", data=data)
plt.show()
```



يوضح الرسم أعلاه أن الأشخاص الذين تزيد أعمارهم عن 45 عامًا من بين الجمهور المستهدف يهتمون أكثر بشراء المنتج. دعنا الآن نلقي نظرة على فئة الدخل للأشخاص الذين استجابوا لإعلانات الشبكات الاجتماعية واشتروا المنتج:

```
plt.title("Product Purchased By People According to Their Income")
sns.histplot(x="EstimatedSalary", hue="Purchased", data=data)
plt.show()
```



يوضح الرسم أعلاه أن الأشخاص الذين يزيد دخلهم الشهري عن 90.000 من بين الجمهور المستهدف يهتمون أكثر بشراء المنتج.

تدريب نموذج تصنيف إعلانات وسائل التواصل الاجتماعي

دعنا الآن ندرّب نموذجًا لتصنيف إعلانات الوسائط الاجتماعية. أولاً، سأقوم بتعيين العمود "Purchased" في مجموعة البيانات كمتغير مستهدف والعمودين الآخرين كمميزات نحتاجها لتدريب نموذج:

```
x = np.array(data[["Age", "EstimatedSalary"]])
y = np.array(data[["Purchased"]])
```

لنقم الآن بتقسيم البيانات وتدريب نموذج تصنيف إعلانات الشبكات الاجتماعية باستخدام مصنف شجرة القرار (decision tree classifier):

```
xtrain, xtest, ytrain, ytest = train_test_split(x, y,
test_size=0.10,
```

```

random_state=42)
model = DecisionTreeClassifier()
model.fit(xtrain, ytrain)
predictions = model.predict(xtest)

```

أخيراً، دعنا نلقي نظرة على تقرير تصنيف (classification report) النموذج:

```
print(classification_report(ytest, predictions))
```

	precision	recall	f1-score	support
0	0.88	0.85	0.87	27
1	0.71	0.77	0.74	13
accuracy			0.82	40
macro avg	0.80	0.81	0.80	40
weighted avg	0.83	0.82	0.83	40

الملخص

إذن هذه هي الطريقة التي يمكنك بها تحليل إعلانات وسائل التواصل الاجتماعي وتصنيفها حول حملة التسويق لمنتج ما. يعني تصنيف إعلانات الوسائط الاجتماعية تحليل إعلانات وسائل التواصل الاجتماعي الخاصة بك للعثور على العملاء الأكثر ربحية لمنتجك والذين من المرجح أن يشتروا المنتج. أمل أن تكون قد أحببت هذه المقالة حول تصنيف إعلانات وسائل التواصل الاجتماعي باستخدام التعلم الآلي باستخدام بايثون.

39 اكتشاف الأخبار الكاذبة باستخدام التعلم الآلي Fake News Detection with Machine Learning

الأخبار الكاذبة (Fake news) هي واحدة من أكبر المشكلات التي تواجه وسائل التواصل الاجتماعي عبر الإنترنت وحتى بعض المواقع الإخبارية. في معظم الأوقات، نرى الكثير من الأخبار الكاذبة حول السياسة. لذا فإن استخدام التعلم الآلي لاكتشاف الأخبار الكاذبة يعد مهمة صعبة للغاية. إذا كنت تريد معرفة كيفية اكتشاف الأخبار الكاذبة باستخدام التعلم الآلي، فهذه المقالة مناسبة لك. في هذه المقالة، سوف أطلعك على مهمة كشف الأخبار الوهمية باستخدام التعلم الآلي باستخدام بايثون.

اكتشاف الأخبار الكاذبة

الأخبار الكاذبة هي واحدة من أكبر المشاكل لأنها تؤدي إلى الكثير من المعلومات الخاطئة في منطقة معينة. في معظم الأحيان، قد يؤدي نشر أخبار كاذبة حول المعتقدات السياسية والدينية لمجتمع ما إلى أعمال شغب وأعمال عنف كما رأيت في البلد الذي تعيش فيه. لذلك، لاكتشاف الأخبار الكاذبة، يمكننا العثور على علاقات بين عناوين الأخبار الكاذبة حتى نتتمكن من تدريب نموذج للتعلم الآلي يمكنه إخبارنا ما إذا كانت معلومة معينة كاذبة أم حقيقية بمجرد ملاحظة العنوان الرئيسي في الأخبار. لذلك في القسم أدناه، سأقدم لكم مشروع التعلم الآلي عن اكتشاف الأخبار الكاذبة باستخدام لغة برمجة بايثون.

اكتشاف الأخبار الكاذبة باستخدام بايثون

تحتوي مجموعة البيانات التي أستخدمها هنا لمهمة الكشف عن الأخبار الكاذبة على بيانات حول عنوان الأخبار ومحتوى الأخبار وعمود يُعرف باسم التسمية (label) يوضح ما إذا كانت الأخبار كاذبة أم حقيقية. لذلك يمكننا استخدام مجموعة البيانات هذه للعثور على العلاقات بين عناوين الأخبار الكاذبة والحقيقية لفهم نوع العناوين الرئيسية في معظم الأخبار الكاذبة. لذلك دعونا نستورد مكتبات بايثون الضرورية ومجموعة البيانات التي نحتاجها لهذه المهمة:

```
import pandas as pd
import numpy as np
from sklearn.feature_extraction.text import CountVectorizer
from sklearn.model_selection import train_test_split
from sklearn.naive_bayes import MultinomialNB

data = pd.read_csv("news.csv")
print(data.head())
```

```

Unnamed: 0 ... label
0      8476 ... FAKE
1     10294 ... FAKE
2      3608 ... REAL
3     10142 ... FAKE
4       875 ... REAL

```

مجموعة البيانات هذه كبيرة جداً ولحسن الحظ لا تزال لا تحتوي على قيم مفقودة، لذا دون إضاعة أي وقت، دعنا نستخدم عمود العنوان (**title column**) كميزة نحتاجها لتدريب نموذج التعلم الآلي وعمود التسمية (**label column**) على أنهما القيم التي نريد توقعها:

```

x = np.array(data["title"])
y = np.array(data["label"])

```

```

cv = CountVectorizer()
x = cv.fit_transform(x)

```

دعنا الآن نفصل مجموعة البيانات إلى مجموعات تدريب واختبار، وبعد ذلك سأستخدم خوارزمية **Multinomial Naive Bayes** لتدريب نموذج اكتشاف الأخبار الكاذبة:

```

xtrain, xtest, ytrain, ytest = train_test_split(x, y,
test_size=0.2, random_state=42)
model = MultinomialNB()
model.fit(xtrain, ytrain)
print(model.score(xtest, ytest))

```

```
0.8074191002367798
```

الآن دعونا نختبر هذا النموذج. لاختبار نموذجنا المدرب، سأقوم أولاً بتدوين عنوان أي خبر موجود في أخبار google لمعرفة ما إذا كان نموذجنا يتوقع أن الأخبار حقيقية أم لا:

```

news_headline = "CA Exams 2021: Supreme Court asks ICAI to
extend opt-out option for July exams, final order tomorrow"
data = cv.transform([news_headline]).toarray()
print(model.predict(data))

```

```
['REAL']
```

سأقوم الآن بكتابة عنوان أخبار كاذف عشوائي لمعرفة ما إذا كان النموذج يتنبأ بأن الأخبار كاذبة أم لا:

```

news_headline = "Cow dung can cure Corona Virus"
data = cv.transform([news_headline]).toarray()
print(model.predict(data))

```

```
['FAKE']
```

الملخص

هذه هي الطريقة التي يمكننا بها تدريب نموذج التعلم الآلي لمهمة اكتشاف الكاذبة باستخدام لغة برمجة بايثون. الأخبار الكاذبة هي واحدة من أكبر المشاكل لأنها تؤدي إلى الكثير من المعلومات الخاطئة في منطقة معينة. أتمنى أن تكون قد أحببت هذه المقالة حول مهمة اكتشاف الأخبار الكاذبة باستخدام التعلم الآلي باستخدام بايثون.

40 التنبؤ بالمبيعات باستخدام التعلم الآلي Sales Prediction with Machine Learning

يعد التنبؤ بالمبيعات (Forecasting sales) مشكلة صعبة لكل نوع من أنواع الأعمال، ولكنه يساعد في تحديد المكان الذي يجب أن تنفق فيه الشركة أكثر على الإعلان وأين يجب أن تقلل الإنفاق. في هذه المقالة، سوف أطلعك على مهمة التنبؤ بالمبيعات باستخدام التعلم الآلي باستخدام بايثون.

ما هو التنبؤ بالمبيعات؟

يعني التنبؤ بالمبيعات التنبؤ بكمية المنتج التي سيشتريها الأشخاص بناءً على عوامل مثل المبلغ الذي تنفقه للإعلان عن منتجك، أو شريحة الأشخاص الذين تعلن عنهم، أو النظام الأساسي الذي تعلن عنه حول منتجك.

عادةً ما تعتمد مبيعات المنتج بشكل أساسي على المبلغ الذي تنفقه على الإعلان عنه، فكلما زاد عدد الأشخاص الذين يصل منتجك، زادت المبيعات طالما أن جودة منتجك جيدة. الآن في القسم أدناه، سوف آخذك خلال مشروع التعلم الآلي حول التنبؤ بالمبيعات باستخدام بايثون.

التنبؤ بالمبيعات باستخدام بايثون

أمل أن تفهم الآن ما هو التنبؤ بالمبيعات. عادةً ما يحتاج النشاط التجاري القائم على المنتج والخدمات دائماً إلى عالم البيانات الخاص به للتنبؤ بمبيعاته المستقبلية مع كل خطوة يتخذها للتلاعب بتكلفة الإعلان عن منتجهم. فلنبدأ مهمة التنبؤ بالمبيعات باستخدام التعلم الآلي باستخدام بايثون. سأبدأ هذه المهمة عن طريق استيراد مكتبات بايثون ومجموعة البيانات الضرورية:

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
from sklearn.model_selection import train_test_split
from sklearn.linear_model import LinearRegression

data =
pd.read_csv("https://raw.githubusercontent.com/amankharwal/Web
site-data/master/advertising.csv")
print(data.head())
```

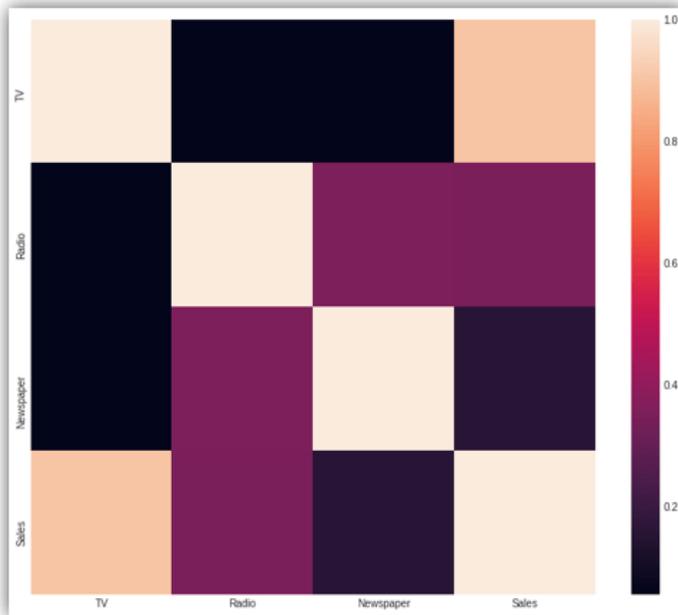
	TV	Radio	Newspaper	Sales
0	230.1	37.8	69.2	22.1
1	44.5	39.3	45.1	10.4
2	17.2	45.9	69.3	12.0
3	151.5	41.3	58.5	16.5
4	180.8	10.8	58.4	17.9

```
print(data.isnull().sum())
```

```
TV          0
Radio       0
Newspaper   0
Sales       0
dtype: int64
```

لذلك لا تحتوي مجموعة البيانات هذه على أي قيم فارغة. دعنا الآن نلقي نظرة على الارتباط بين الميزات قبل أن نبدأ في تدريب نموذج التعلم الآلي للتنبؤ بالمبيعات المستقبلية:

```
plt.style.use('seaborn-whitegrid')
plt.figure(figsize=(12, 10))
sns.heatmap(data.corr())
plt.show()
```



دعنا الآن نجهز البيانات لتلائم نموذج التعلم الآلي ثم سأستخدم خوارزمية الانحدار الخطي ([linear regression](#)) لتدريب نموذج التنبؤ بالمبيعات باستخدام بايثون:

```
x = np.array(data.drop(["Sales"], 1))
y = np.array(data["Sales"])
xtrain, xtest, ytrain, ytest = train_test_split(x, y,
test_size=0.2, random_state=42)
model = LinearRegression()
model.fit(xtrain, ytrain)
ypred = model.predict(xtest)

data = pd.DataFrame(data={"Predicted Sales": ypred.flatten()})
print(data)
```

Predicted Sales	
0	17.034772
1	20.409740
2	23.723989
3	9.272785
4	21.682719
5	12.569402
6	21.081195
7	8.690350
8	17.237013
9	16.666575
10	8.923965
11	8.481734
12	18.207512
13	8.067507
14	12.645510
15	14.931628
16	8.128146
17	17.898766
18	11.008806
19	20.478328
20	20.806318
21	12.598833
22	10.905183
23	22.388548
24	9.417961
25	7.925067
26	20.839085
27	13.815209
28	10.770809
29	7.926825
30	15.959474
31	10.634909
32	20.802920
33	10.434342
34	21.578475
35	21.183645
36	12.128218
37	22.809533
38	12.609928
39	6.464413

الملخص

هذه هي الطريقة التي يمكننا بها التنبؤ بالمبيعات المستقبلية لمنتج ما باستخدام التعلم الآلي. يعد التنبؤ بالمبيعات مشكلة صعبة لكل نوع من أنواع الأعمال ولكن استخدام التعلم الآلي يجعل الأمر يبدو سهلاً. آمل أن تكون قد أحببت هذه المقالة حول مهمة التنبؤ بالمبيعات باستخدام التعلم الآلي باستخدام بايثون.

41) تصنيف أسعار الأجهزة المحمولة مع التعلم الآلي Mobile Price Classification with Machine Learning

سعر المنتج هو أهم سمة لتسويق هذا المنتج. أحد تلك المنتجات التي يكون السعر فيها مهماً كثيراً هو الهاتف الذكي لأنه يأتي مع الكثير من الميزات بحيث تفكر الشركة كثيراً في كيفية تسعير هذا الهاتف المحمول الذي يمكن أن يبرر الميزات ويغطي أيضاً تكاليف التسويق والتصنيع للهاتف المحمول. في هذه المقالة، سوف أطلعك على مهمة تصنيف أسعار الأجهزة المحمولة باستخدام التعلم الآلي باستخدام بايثون.

تصنيف أسعار الأجهزة المحمولة مع التعلم الآلي

الهواتف المحمولة هي الأجهزة الإلكترونية الأكثر مبيعاً حيث يواصل الأشخاص تحديث هواتفهم المحمولة كلما وجدوا ميزات جديدة في جهاز جديد. يتم بيع الآلاف من الهواتف المحمولة يومياً، وفي مثل هذه الحالة يكون من الصعب جداً على الشخص الذي يخطط لإنشاء أعمال الهواتف المحمول الخاصة به أن يقرر السعر الذي يجب أن يكون عليه الهاتف المحمول. في القسم أدناه، سأقدم لك مشروع التعلم الآلي على نموذج تصنيف أسعار الأجهزة المحمولة حيث سأقوم بتدريب نموذج لتصنيف النطاق السعري للهواتف المحمولة باستخدام بايثون. تعتمد هذه المهمة على حل دراسة الحالة المذكورة أدناه.

"يريد السيد أمان أن يبدأ شركة الهواتف المحمولة الخاصة به ويريد أن يخوض معركة شاقة مع العلامات التجارية الكبرى للهواتف الذكية مثل *Apple* و *Samsung*. لكنه لا يعرف كيفية تقدير سعر الهاتف المحمول الذي يمكن أن يغطي كلاً من تكاليف التسويق والتصنيع. لذا في هذه المهمة، لا يتعين عليك توقع الأسعار الفعلية للهواتف المحمولة ولكن عليك توقع النطاق السعري للهواتف المحمولة."

تصنيف أسعار الأجهزة المحمولة باستخدام لغة بايثون

لذلك، نظراً لأن مهمتنا هي تصنيف النطاق السعري للهواتف المحمولة وليس التنبؤ بالأسعار الفعلية، لذلك سأقوم هنا بتدريب نموذج تصنيف لتصنيف النطاق السعري للهواتف المحمولة على النحو التالي:

- 0 (تكلفة منخفضة).
- 1 (تكلفة متوسطة).
- 2 (تكلفة عالية).

- 4 (تكلفة عالية جدا).

سأبدأ مهمة تصنيف أسعار الأجهزة المحمولة باستخدام التعلم الآلي عن طريق استيراد مكتبات بايثون ومجموعة البيانات اللازمة:

مجموعة البيانات

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler
from sklearn.linear_model import LogisticRegression
from sklearn.metrics import accuracy_score
sns.set()

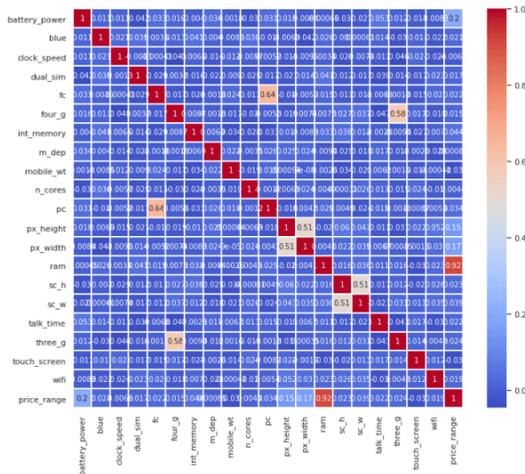
data = pd.read_csv("mobile_prices.csv")
print(data.head())
```

	battery_power	blue	clock_speed	...	touch_screen	wifi	price_range
0	842	0	2.2	...	0	1	1
1	1021	1	0.5	...	1	0	2
2	563	1	0.5	...	1	0	2
3	615	1	2.5	...	0	0	2
4	1821	1	1.2	...	1	0	1

[5 rows x 21 columns]

لذا، تحتوي مجموعة البيانات على 21 عمودًا ولحسن الحظ لا تحتوي مجموعة البيانات هذه على قيم مفقودة، لذا يمكننا البدء فقط من خلال تدريب النموذج، ولكن قبل ذلك، دعنا نلقي نظرة على الارتباط بين الميزات في مجموعة البيانات:

```
plt.figure(figsize=(12, 10))
sns.heatmap(data.corr(), annot=True, cmap="coolwarm",
            linecolor='white', linewidths=1)
```



تحضير البيانات

لا تحتوي مجموعة البيانات هذه على ميزات فئوية، لذلك يمكننا فقط استخدام هذه البيانات دون أي تحويل لأن جميع ميزات مجموعة البيانات رقمية. ولكن لتدريب نموذج، من المهم جدًا توحيد البيانات أو تطبيعها وتقسيمها إلى مجموعات تدريب واختبار.

لذلك دعونا نوحّد مجموعة البيانات ونقسم البيانات إلى 80٪ تدريب و20٪ اختبار:

```
x = data.iloc[:, :-1].values
y = data.iloc[:, -1].values
x = StandardScaler().fit_transform(x)
x_train, x_test, y_train, y_test = train_test_split(x, y,
test_size=0.20, random_state=0)
```

نموذج تصنيف سعر الهاتف المحمول

دعنا الآن ندرّب نموذج تصنيف أسعار الجوّال باستخدام بايثون. نظرًا لأن هذه مشكلة تصنيف، فسوف نستخدم خوارزمية الانحدار اللوجستي **Logistic Regression** المقدمة من Scikit-Learn:

```
from sklearn.linear_model import LogisticRegression
lreg = LogisticRegression()
lreg.fit(x_train, y_train)
y_pred = lreg.predict(x_test)
```

الآن دعنا نلقي نظرة على دقة النموذج:

```
accuracy = accuracy_score(y_test, y_pred) * 100
print("Accuracy of the Logistic Regression Model: ", accuracy)
```

```
Accuracy of the Logistic Regression Model: 95.5
```

لذا فإن النموذج يعطي دقة تبلغ حوالي 95.5٪ وهو أمر رائع. دعنا الآن نلقي نظرة على التنبؤات التي قدمها النموذج:

```
[3 0 2 2 3 0 0 3 3 1 1 3 0 2 3 0 3 2 2 1 0 0 3 1 2 2 3 1 3 1 1 0 2 0 2 3 0
 0 3 3 3 1 3 3 1 3 0 1 3 1 1 3 0 3 0 2 2 2 0 3 3 1 3 2 1 2 3 2 2 2 3 2 1 0
 1 3 2 2 1 2 3 3 3 0 0 0 2 1 2 3 1 2 2 1 0 3 3 3 0 3 1 1 3 1 3 2 2 3 2 3 3
 0 0 1 3 3 0 0 1 0 0 3 2 2 1 2 1 1 0 2 1 3 3 3 3 3 2 0 1 1 2 1 3 0 3 0 0
 2 0 1 1 1 1 3 0 0 3 1 3 2 1 3 1 2 3 3 2 1 0 3 1 2 3 3 0 2 2 3 1 2 1 0 1 2
 2 2 0 3 3 1 1 0 2 3 0 1 2 2 0 3 3 3 1 2 3 3 3 0 0 0 2 3 3 0 0 1 3 2 3 3 3
 0 0 2 3 3 1 0 2 0 0 0 3 2 1 2 2 1 1 0 2 3 3 0 0 1 3 3 1 3 0 3 1 1 0 2 3 3
 2 0 0 1 2 3 2 2 3 2 1 0 3 3 2 1 3 2 2 2 1 0 2 2 1 0 0 2 2 2 3 0 1 3 0 2 2
 3 0 2 0 1 1 3 0 0 2 3 1 2 0 2 0 3 0 3 3 2 3 1 2 2 1 1 1 0 1 0 3 1 0 3 0 0
 1 3 0 3 1 1 0 1 3 0 2 1 1 2 1 1 0 2 0 0 3 1 2 3 2 2 0 3 2 2 1 3 2 3 3 0
 2 0 3 0 1 1 2 3 1 3 1 2 0 1 2 3 0 0 1 3 0 3 0 2 2 1 1 0 2 0]
```

يوضح الناتج أعلاه النطاق السعري المصنف بواسطة النموذج. دعونا نلقي نظرة على عدد الهواتف المحمولة المصنفة لكل نطاق سعري:

```
(unique, counts) = np.unique(y_pred, return_counts=True)
price_range = np.asarray((unique, counts)).T
print(price_range)
```

أتمنى أن تكون قد أحببت هذه المقالة حول تصنيف أسعار الأجهزة المحمولة باستخدام التعلم الآلي.

43 التنبؤ بسعر صرف العملات مع التعلم الآلي Currency Exchange Rate Prediction with Machine Learning

صرف العملات (Currency exchange) هو واحد من أكبر الأسواق المالية. حالياً، دولار واحد من دولارات الولايات المتحدة يعادل 73.02 روبية هندية. تؤثر العديد من العوامل على أسعار الصرف مثل العوامل الاقتصادية والسياسية وحتى النفسية. يعد التنبؤ بسعر صرف العملات (Currency Exchange Rate Prediction) مشكلة صعبة، لذا في هذه المقالة، سوف أطلعك على مهمة التنبؤ بسعر صرف العملات باستخدام التعلم الآلي باستخدام بايثون.

التنبؤ بسعر صرف العملات

التنبؤ بأسعار صرف العملات هو مشكلة انحدار (regression) في التعلم الآلي. هناك تغيرات في أسعار الصرف كل يوم تؤثر على دخل الفرد أو الشركة ويمكن أن تؤثر حتى على اقتصاد بلد ما. وبالتالي، فإن التنبؤ بأسعار صرف العملات يمكن أن يساعد الفرد وكذلك البلد في نواح كثيرة.

هناك العديد من خوارزميات التعلم الآلي التي يمكننا استخدامها للتنبؤ بأسعار صرف العملات في المستقبل. يمكنك أيضاً استخدام الشبكات العصبية الاصطناعية (artificial neural networks) لهذه المهمة. في القسم أدناه، سوف أخذك خلال مهمة التنبؤ بسعر صرف العملات مع التعلم الآلي باستخدام بايثون.

التنبؤ بسعر صرف العملات باستخدام بايثون

للتنبؤ بسعر صرف العملات من خلال التعلم الآلي، نحتاج أولاً إلى الحصول على البيانات الأكثر ملاءمة لهذه المهمة. للحصول على مجموعة بيانات لهذه المهمة، ما عليك سوى اتباع الخطوات المذكورة أدناه:

1. قم بزيارة Yahoo Finance .

2. ابحث عن "USD / INR (INR = x)".

3. انقر فوق "البيانات التاريخية Historical Data".

4. انقر فوق "تنزيل Download".

باتباع الخطوات المذكورة أعلاه، ستتمكن من تنزيل البيانات التاريخية لأسعار صرف العملات بالروبية الهندية. بعد النقر فوق تنزيل، ستلقى ملف CSV في مجلد التنزيلات الخاص بك.

دعنا الآن نستورد مكتبات بايثون الضرورية التي نحتاجها لهذه المهمة ونقرأ مجموعة البيانات:

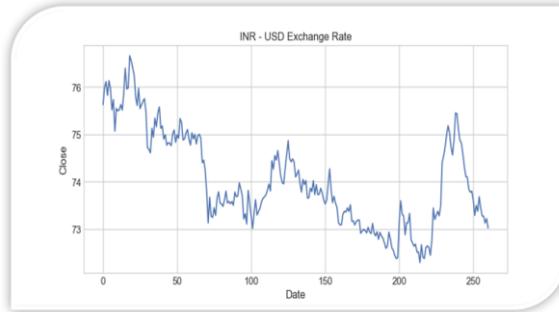
```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
from seaborn import regression
sns.set()
plt.style.use('seaborn-whitegrid')

data = pd.read_csv("INR.csv")
print(data.head())
```

	Date	Open	High	Low	Close	Adj Close	Volume
0	2020-05-22	75.625000	76.209503	75.610001	75.625000	75.625000	0
1	2020-05-25	75.985001	76.129501	75.757500	75.985001	75.985001	0
2	2020-05-26	75.873596	76.110001	75.404999	76.110001	76.110001	0
3	2020-05-27	75.489502	76.000000	75.381302	75.820000	75.820000	0
4	2020-05-28	75.885696	76.129997	75.634499	76.129997	76.129997	0

في مجموعة البيانات هذه، القيم الموجودة في عمود الاغلاق "Close" هي القيم المستهدفة التي نحتاج إلى توقعها. لذلك دعونا نلقي نظرة فاحصة على هذه القيم:

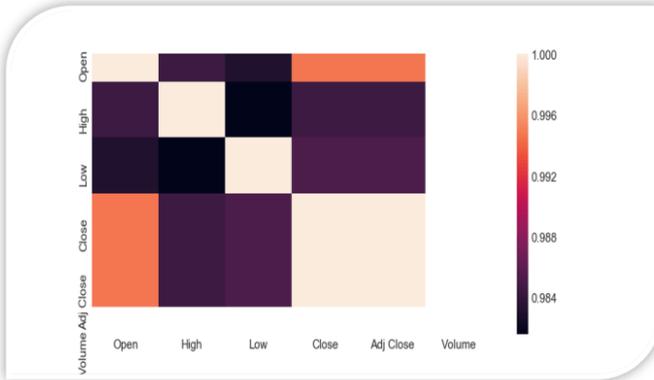
```
plt.figure(figsize=(10, 4))
plt.title("INR - USD Exchange Rate")
plt.xlabel("Date")
plt.ylabel("Close")
plt.plot(data["Close"])
plt.show()
```



دعنا الآن نلقي نظرة على الارتباط بين الميزات قبل تدريب نموذج التنبؤ بسعر صرف العملات:

```
print(data.corr())
sns.heatmap(data.corr())
plt.show()
```

	Open	High	Low	Close	Adj Close	Volume
Open	1.000000	0.984518	0.983143	0.994720	0.994720	NaN
High	0.984518	1.000000	0.981582	0.984599	0.984599	NaN
Low	0.983143	0.981582	1.000000	0.985281	0.985281	NaN
Close	0.994720	0.984599	0.985281	1.000000	1.000000	NaN
Adj Close	0.994720	0.984599	0.985281	1.000000	1.000000	NaN
Volume	NaN	NaN	NaN	NaN	NaN	NaN



الآن الخطوة التالية هي إعداد مجموعة البيانات عن طريق تخزين الميزات الأكثر صلة في المتغير x وتخزين العمود الهدف في المتغير y :

```
x = data[["Open", "High", "Low"]]
y = data["Close"]
x = x.to_numpy()
y = y.to_numpy()
y = y.reshape(-1, 1)
```

الآن، دعنا نقسم مجموعة البيانات ونقوم بتدريب نموذج توقع تبادل العملات باستخدام نموذج انحدار شجرة القرار (**Decision Tree Regression**) باستخدام لغة بايثون:

```
from sklearn.model_selection import train_test_split
xtrain, xtest, ytrain, ytest = train_test_split(x, y,
test_size=0.2, random_state=42)
```

```
from sklearn.tree import DecisionTreeRegressor
model = DecisionTreeRegressor()
model.fit(xtrain, ytrain)
ypred = model.predict(xtest)
```

دعنا الآن نلقي نظرة على القيم المتوقعة لأسعار صرف العملات بالروبية الهندية للأيام الخمسة القادمة:

```
data = pd.DataFrame(data={"Predicted Rate": ypred.flatten()})
print(data.head())
```

	Predicted Rate
0	74.820000
1	74.019997
2	73.089203
3	73.374802
4	73.133400

الملخص

التنبؤ بأسعار صرف العملات هو مشكلة الانحدار في التعلم الآلي. في هذه المقالة، استخدمت خوارزمية انحدار شجرة القرار للتنبؤ بأسعار صرف العملات. يمكنك استخدام خوارزميات الانحدار الأخرى وحتى الشبكات العصبية الاصطناعية لهذه المهمة. أمل أن تكون قد أحببت هذه المقالة حول التنبؤ بسعر صرف العملات باستخدام التعلم الآلي باستخدام بايثون.

44) التنبؤ بالربح مع التعلم الآلي Profit Prediction with Machine Learning

يجب أن تحدد الشركة دائماً هدفاً يمكن تحقيقه، وإلا فلن يتمكن الموظفون من العمل بأفضل إمكانياتهم إذا وجدوا أن الهدف الذي حددته الشركة غير قابل للتحقيق. مهمة التنبؤ بالربح (**profit prediction**) لفترة معينة هي نفسها تحديد الأهداف. إذا كنت تعرف مقدار الربح الذي يمكنك تحقيقه من مقدار البحث والتطوير والتسويق الذي تقوم به، فيمكن أن تحقق الشركة أكثر من الربح المتوقع بشرط أن تكون القيمة المتوقعة قابلة للتحقيق. لذلك في هذه المقالة، سوف آخذك خلال مهمة التنبؤ بالربح مع التعلم الآلي باستخدام بايثون.

التنبؤ بالربح مع التعلم الآلي

يعتمد الربح الذي تحققه الشركة لفترة معينة على عدة عوامل مثل مقدار الوقت والمال الذي تنفقه الشركة على البحث والتطوير والتسويق وغير ذلك الكثير. لذا من أجل التنبؤ بأرباح الشركة لفترة معينة، نحتاج إلى تدريب نموذج التعلم الآلي باستخدام مجموعة بيانات تحتوي على بيانات تاريخية حول الأرباح التي حققتها الشركة.

مهمة التنبؤ بالربح هي عملية مهمة لكل عمل لتحديد هدف قابل للتحقيق. على سبيل المثال، إذا أنفق النشاط التجاري 500 دولار أمريكي على التسويق، فلا يمكنه توقع ربح قدره 20000 دولار أمريكي. وبالمثل، هناك العديد من العوامل الأخرى التي يعتمد عليها ربح العمل. لذلك يجب على الشركة تحديد هدف يمكن تحقيقه. في القسم أدناه، سوف أطلعك على مهمة التنبؤ بالربح من خلال التعلم الآلي باستخدام بايثون.

التنبؤ بالربح باستخدام بايثون

تتضمن مجموعة البيانات التي أستخدمها لمهمة التنبؤ بالربح بيانات حول إنفاق البحث والتطوير، وتكلفة الإدارة، والإنفاق على التسويق، وحالة التشغيل، والأرباح التاريخية الناتجة عن 50 شركة ناشئة. فلنبدأ بمهمة توقع الربح عن طريق استيراد مكتبات بايثون ومجموعة البيانات الضرورية:

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
data = pd.read_csv("Startups.csv")
print(data.head())
```

	R&D Spend	Administration	Marketing Spend	State	Profit
0	165349.20	136897.80	471784.10	New York	192261.83
1	162597.70	151377.59	443898.53	California	191792.06
2	153441.51	101145.55	407934.54	Florida	191050.39
3	144372.41	118671.85	383199.62	New York	182901.99
4	142107.34	91391.77	366168.42	Florida	166187.94

لا تحتوي هذه البيانات على أي قيم مفقودة، لذا دون إضاعة أي وقت، فلنبدأ بإلقاء نظرة على ملخص الإحصائيات لهذه البيانات:

```
print(data.describe())
```

	R&D Spend	Administration	Marketing Spend	Profit
count	50.000000	50.000000	50.000000	50.000000
mean	73721.615600	121344.639600	211025.097800	112012.639200
std	45902.256482	28017.802755	122290.310726	40306.180338
min	0.000000	51283.140000	0.000000	14681.400000
25%	39936.370000	103730.875000	129300.132500	90138.902500
50%	73051.080000	122699.795000	212716.240000	107978.190000
75%	101602.800000	144842.180000	299469.085000	139765.977500
max	165349.200000	182645.560000	471784.100000	192261.830000

الآن دعنا ننقي نظرة على الارتباط (**correlation**) بين الميزات:

```
sns.heatmap(data.corr(), annot=True)
plt.show()
```



نظرًا لأن هذه المهمة تعتمد على مشكلة الانحدار (**regression**)، فسوف أستخدم خوارزمية الانحدار الخطي (**Linear regression**) لتدريب نموذج التنبؤ بالربح. لذلك دعونا نجهز البيانات حتى تتمكن من ملاءمتها مع النموذج:

```
x = data[["R&D Spend", "Administration", "Marketing Spend"]]
y = data["Profit"]
x = x.to_numpy()
```

```

y = y.to_numpy()
y = y.reshape(-1, 1)

from sklearn.model_selection import train_test_split
xtrain, xtest, ytrain, ytest = train_test_split(x, y,
test_size=0.2, random_state=42)

```

الآن دعنا ندرّب نموذج الانحدار الخطي على هذه البيانات ونلقي نظرة على القيم المتوقعة:

```

from sklearn.linear_model import LinearRegression
model = LinearRegression()
model.fit(xtrain, ytrain)
ypred = model.predict(xtest)
data = pd.DataFrame(data={"Predicted Profit":
ypred.flatten()})
print(data.head())

```

	Predicted Profit
0	126703.027165
1	84894.750816
2	98893.418160
3	46501.708150
4	129128.397344

الملخص

إذن هذه هي الطريقة التي يمكننا بها التنبؤ بأرباح الشركة لفترة معينة باستخدام خوارزميات التعلم الآلي. يمكن أن تساعد مثل هذه المهام الشركة على تحديد هدف يمكن تحقيقه. أمل أن تكون قد أحببت هذه المقالة حول مهمة التنبؤ بالربح مع التعلم الآلي باستخدام بايثون.

45 تحليل جودة المياه باستخدام التعلم الآلي Water Quality Analysis using Machine Learning

يُعد الحصول على مياه الشرب المأمونة أحد الاحتياجات الأساسية لجميع البشر. من وجهة نظر قانونية، يعتبر الحصول على مياه الشرب أحد حقوق الإنسان الأساسية. تؤثر العديد من العوامل على جودة المياه (Water Quality)، كما أنها أحد مجالات البحث الرئيسية في التعلم الآلي. لذلك إذا كنت تريد معرفة كيفية إجراء تحليل جودة المياه (water quality analysis) باستخدام التعلم الآلي، فهذه المقالة مناسبة لك. في هذه المقالة، سوف أطلعك على تحليل جودة المياه باستخدام التعلم الآلي باستخدام بايثون.

تحليل جودة المياه

يُعد تحليل جودة المياه أحد المجالات الرئيسية للبحث في التعلم الآلي. يُعرف أيضاً باسم تحليل قابلية المياه للشرب (water potability analysis) لأن مهمتنا هنا هي فهم جميع العوامل التي تؤثر على قابلية المياه للشرب وتدريب نموذج التعلم الآلي الذي يمكنه تصنيف ما إذا كانت عينة مياه معينة آمنة أو غير صالحة للاستهلاك.

بالنسبة لمهمة تحليل جودة المياه، سأستخدم مجموعة بيانات Kaggle التي تحتوي على بيانات حول جميع العوامل الرئيسية التي تؤثر على قابلية المياه للشرب. جميع العوامل التي تؤثر على جودة المياه مهمة للغاية، لذلك نحتاج إلى استكشاف كل ميزة من ميزات مجموعة البيانات هذه بإيجاز قبل تدريب نموذج التعلم الآلي للتنبؤ بما إذا كانت عينة المياه آمنة أو غير مناسبة للاستهلاك. يمكنك تنزيل مجموعة البيانات التي أستخدمها لمهمة تحليل جودة المياه من [هنا](#).

تحليل جودة المياه باستخدام لغة بايثون

سأبدأ مهمة تحليل جودة المياه عن طريق استيراد مكتبات بايثون ومجموعة البيانات الضرورية:

```
import matplotlib.pyplot as plt
import pandas as pd
import seaborn as sns
import numpy as np

data = pd.read_csv("water_potability.csv")
data.head()
```

	ph	Hardness	Solids	Chloramines	Sulfate	Conductivity	Organic_carbon	Trihalomethanes	Turbidity	Potability
0	NaN	204.890455	20791.318981	7.300212	368.516441	564.308654	10.379783	86.990970	2.963135	0
1	3.716080	129.422921	18630.057858	6.635246	NaN	592.885359	15.180013	56.329076	4.500656	0
2	8.099124	224.236259	19909.541732	9.275884	NaN	418.606213	16.868637	66.420093	3.055934	0
3	8.316766	214.373394	22018.417441	8.059332	356.886136	363.266516	18.436524	100.341674	4.628771	0
4	9.092223	181.101509	17978.986339	6.548600	310.135738	398.410813	11.558279	31.997993	4.075075	0

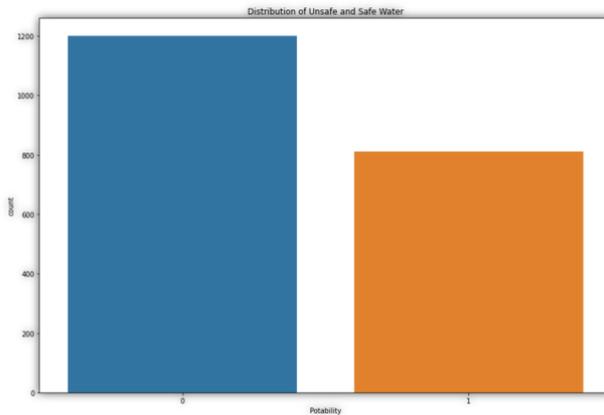
يمكنني رؤية القيم الخالية في المعاينة الأولى لمجموعة البيانات هذه نفسها، لذلك قبل المضي قدماً، دعنا نزيل جميع الصفوف التي تحتوي على قيم فارغة:

```
data = data.dropna()
data.isnull().sum()
```

```
ph          0
Hardness    0
Solids      0
Chloramines 0
Sulfate     0
Conductivity 0
Organic_carbon 0
Trihalomethanes 0
Turbidity   0
Potability  0
dtype: int64
```

عمود القابلية للشرب (**Potability column**) لمجموعة البيانات هذه هو العمود الذي نحتاج إلى توقعه لأنه يحتوي على القيمتين 0 و 1 التي تشير إلى ما إذا كانت المياه صالحة للشرب (1) أو غير صالحة (0) للشرب. لذلك دعونا نرى توزيع 0 و 1 في عمود "**Potability**":

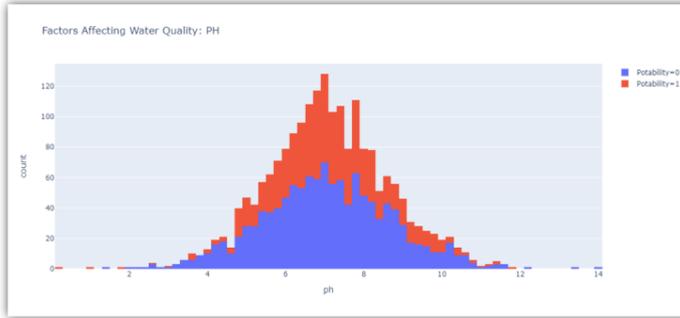
```
plt.figure(figsize=(15, 10))
sns.countplot(data.Potability)
plt.title("Distribution of Unsafe and Safe Water")
plt.show()
```



لذلك هذا شيء يجب أن تلاحظه أن مجموعة البيانات هذه غير متوازنة (**not balanced**) لأن عينات الأصفر أكثر من 1 ثانية.

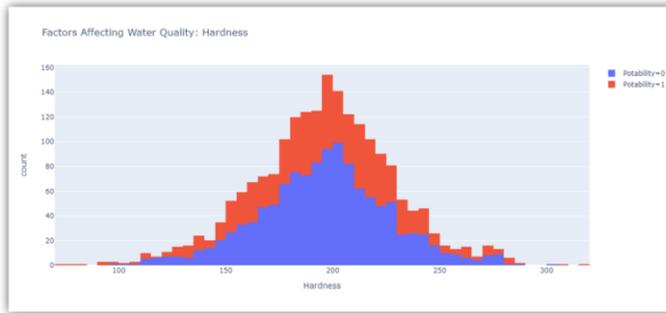
كما ذكرنا أعلاه، لا توجد عوامل لا يمكننا تجاهلها والتي تؤثر على جودة المياه، لذلك دعونا نستكشف جميع الأعمدة واحدة تلو الأخرى. لنبدأ بالقاء نظرة على عمود الاس الهيدروجيني (**ph column**):

```
import plotly.express as px
data = data
figure = px.histogram(data, x = "ph",
                      color = "Potability",
                      title= "Factors Affecting Water Quality:
PH")
figure.show()
```



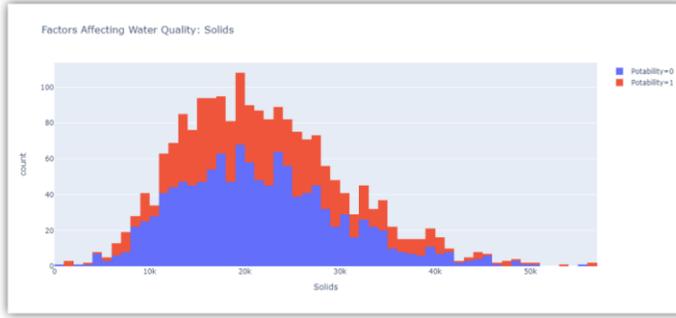
يمثل عمود الأس الهيدروجيني قيمة الأس الهيدروجيني للماء وهو عامل مهم في تقييم التوازن الحمضي القاعدي للماء. يجب أن تكون قيمة الرقم الهيدروجيني لمياه الشرب بين 6.5 و8.5. دعونا الآن نلقي نظرة على العامل الثاني الذي يؤثر على جودة المياه في مجموعة البيانات:

```
figure = px.histogram(data, x = "Hardness",
                      color = "Potability",
                      title= "Factors Affecting Water Quality:
Hardness")
figure.show()
```



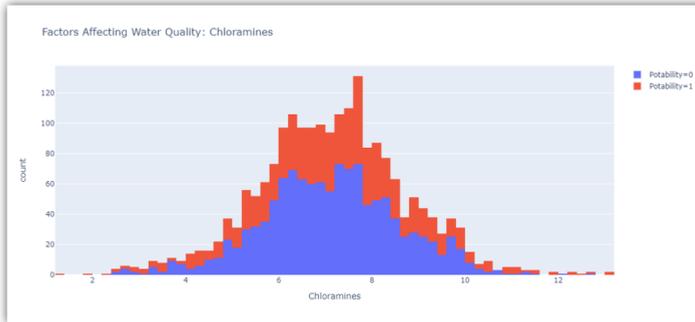
يوضح الشكل أعلاه توزيع عسرة **hardness** الماء في مجموعة البيانات. تعتمد عسرة الماء عادة على مصدره، لكن الماء الذي تصل قوته إلى 120-200 ملليغرام صالح للشرب. دعنا الآن نلقي نظرة على العامل التالي الذي يؤثر على جودة المياه:

```
figure = px.histogram(data, x = "Solids",
                      color = "Potability",
                      title= "Factors Affecting Water Quality:
Solids")
figure.show()
```



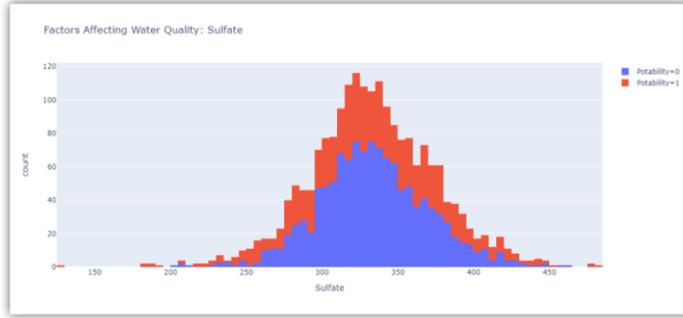
يمثل الشكل أعلاه توزيع إجمالي المواد الصلبة الذائبة في الماء في مجموعة البيانات. تسمى جميع المعادن العضوية وغير العضوية الموجودة في الماء بالمواد الصلبة الذائبة. الماء الذي يحتوي على عدد كبير جداً من المواد الصلبة الذائبة شديد التمدن. دعنا الآن نلقي نظرة على العامل التالي الذي يؤثر على جودة المياه:

```
figure = px.histogram(data, x = "Chloramines",
                      color = "Potability",
                      title= "Factors Affecting Water Quality:
Chloramines")
figure.show()
```



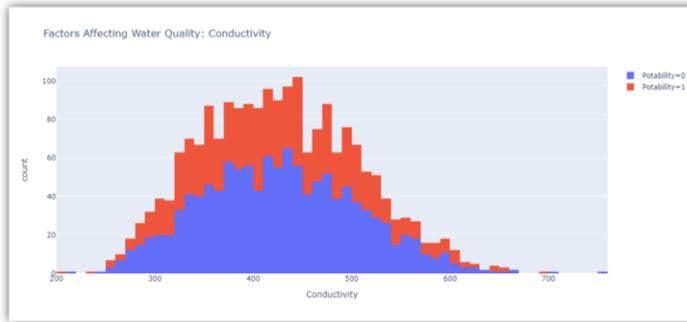
يمثل الشكل أعلاه توزيع الكلورامين (chloramine) في الماء في مجموعة البيانات. الكلورامين والكلور من المطهرات المستخدمة في أنظمة المياه العامة. دعنا الآن نلقي نظرة على العامل التالي الذي يؤثر على جودة المياه:

```
figure = px.histogram(data, x = "Sulfate",
                      color = "Potability",
                      title= "Factors Affecting Water Quality:
Sulfate")
figure.show()
```



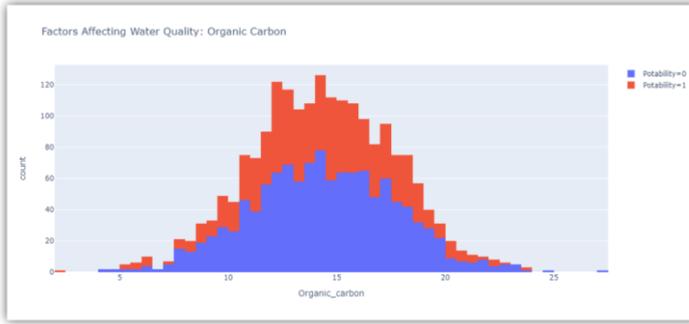
يوضح الشكل أعلاه توزيع الكبريتات (sulfate) في الماء في مجموعة البيانات. إنها مواد موجودة بشكل طبيعي في المعادن والتربة والصخور. الماء الذي يحتوي على أقل من 500 ملليغرام من الكبريتات آمن للشرب. الآن دعونا نرى العامل التالي:

```
figure = px.histogram(data, x = "Conductivity",
                      color = "Potability",
                      title= "Factors Affecting Water Quality:
Conductivity")
figure.show()
```



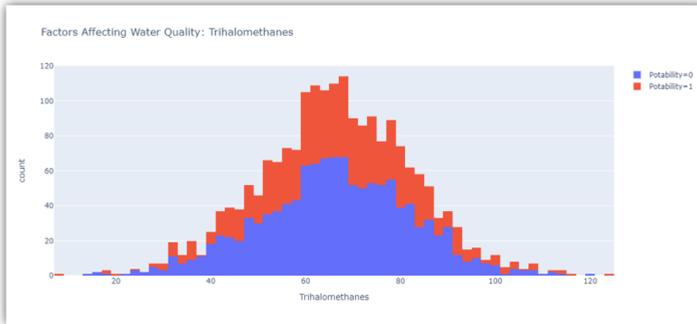
يمثل الشكل أعلاه توزيع موصلية المياه (water conductivity) في مجموعة البيانات. الماء موصل جيد للكهرباء، لكن أنقى أشكال الماء ليس موصلًا جيدًا للكهرباء. المياه ذات التوصيل الكهربائي أقل من 500 صالحة للشرب. الآن دعونا نرى العامل التالي:

```
figure = px.histogram(data, x = "Organic_carbon",
                      color = "Potability",
                      title= "Factors Affecting Water Quality:
Organic Carbon")
figure.show()
```



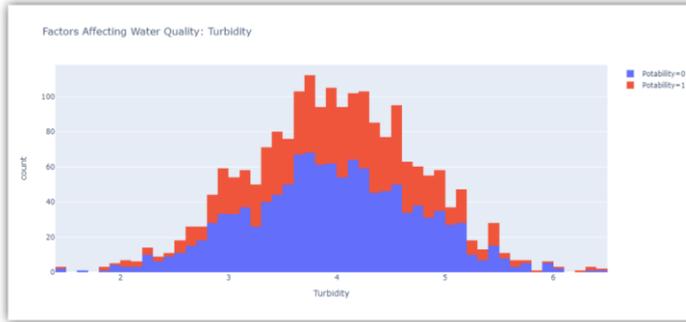
يمثل الشكل أعلاه توزيع الكربون العضوي (organic carbon) في الماء في مجموعة البيانات. يأتي الكربون العضوي من انهيار المواد العضوية الطبيعية والمصادر الاصطناعية. تعتبر المياه التي تحتوي على أقل من 25 ملليجرام من الكربون العضوي آمنة للشرب. دعنا الآن نلقي نظرة على العامل التالي الذي يؤثر على جودة مياه الشرب:

```
figure = px.histogram(data, x = "Trihalomethanes",
                      color = "Potability",
                      title= "Factors Affecting Water Quality:
Trihalomethanes")
figure.show()
```



يمثل الشكل أعلاه توزيع ثلاثي الميثان (trihalomethanes) أو (THM) في الماء في مجموعة البيانات. THMs هي مواد كيميائية موجودة في المياه المعالجة بالكلور. تعتبر المياه التي تحتوي على أقل من 80 ملليجرام من THMs آمنة للشرب. دعنا الآن نلقي نظرة على العامل التالي في مجموعة البيانات الذي يؤثر على جودة مياه الشرب:

```
figure = px.histogram(data, x = "Turbidity",
                      color = "Potability",
                      title= "Factors Affecting Water Quality:
Turbidity")
figure.show()
```



يمثل الشكل أعلاه توزيع العكارة (turbidity) في الماء. تعتمد عكارة الماء على عدد المواد الصلبة الموجودة في المعلق. تعتبر المياه ذات العكارة أقل من 5 ملليغرام صالحة للشرب.

نموذج التنبؤ بجودة المياه باستخدام لغة بايثون

في القسم أعلاه، استكشفنا جميع الميزات التي تؤثر على جودة المياه. الآن، الخطوة التالية هي تدريب نموذج التعلم الآلي لمهمة تحليل جودة المياه باستخدام بايثون. لهذه المهمة، سأستخدم مكتبة **PyCaret** في بايثون. إذا لم تكن قد استخدمت هذه المكتبة من قبل، فيمكنك تثبيتها بسهولة على نظامك باستخدام الأمر `pip`:

```
pip install pycaret
```

قبل تدريب نموذج التعلم الآلي، دعنا نلقي نظرة على الارتباط (**correlation**) بين جميع الميزات فيما يتعلق بعمود القابلية للشرب (**Potability column**) في مجموعة البيانات:

```
correlation = data.corr()
correlation["ph"].sort_values(ascending=False)
```

```
ph                1.000000
Hardness          0.108948
Organic_carbon    0.028375
Trihalomethanes   0.018278
Potability        0.014530
Conductivity      0.014128
Sulfate           0.010524
Chloramines       -0.024768
Turbidity         -0.035849
Solids            -0.087615
Name: ph, dtype: float64
```

الآن فيما يلي كيف يمكنك معرفة أي خوارزمية تعلم الآلة هي الأفضل لمجموعة البيانات هذه باستخدام مكتبة **PyCaret** في بايثون:

```
from pycaret.classification import*
clf = setup(data, target = "Potability", silent = True,
session_id = 786)
compare_models()
```

Model	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC	TT (Sec)	
rf	Random Forest Classifier	0.6830	0.7005	0.4197	0.6744	0.5133	0.2976	0.3182	0.724
qda	Quadratic Discriminant Analysis	0.6823	0.7192	0.3985	0.6883	0.5013	0.2917	0.3174	0.022
et	Extra Trees Classifier	0.6816	0.6941	0.3861	0.6858	0.4916	0.2863	0.3123	0.557
lightgbm	Light Gradient Boosting Machine	0.6652	0.6916	0.4762	0.6078	0.5324	0.2781	0.2840	0.172
gbc	Gradient Boosting Classifier	0.6602	0.6738	0.3718	0.6306	0.4667	0.2419	0.2603	0.339
nb	Naive Bayes	0.6184	0.6078	0.2478	0.5545	0.3412	0.1261	0.1462	0.019
dt	Decision Tree Classifier	0.6034	0.5895	0.5186	0.5049	0.5097	0.1775	0.1784	0.027
lr	Logistic Regression	0.5984	0.5199	0.0071	0.1900	0.0134	0.0028	0.0127	0.355
ridge	Ridge Classifier	0.5984	0.0000	0.0089	0.1583	0.0168	0.0035	0.0056	0.021
lda	Linear Discriminant Analysis	0.5977	0.4903	0.0089	0.1500	0.0167	0.0021	0.0024	0.022
ada	Ada Boost Classifier	0.5956	0.5671	0.2919	0.4896	0.3644	0.0972	0.1034	0.173
knn	K Neighbors Classifier	0.5743	0.5423	0.3644	0.4642	0.4070	0.0826	0.0846	0.121
svm	SVM - Linear Kernel	0.5194	0.0000	0.3982	0.1604	0.2287	-0.0014	-0.0104	0.027

وفقاً للنتيجة أعلاه، فإن خوارزمية الغابة العشوائية (random forrest(rf)) هي الأفضل لتدريب نموذج التعلم الآلي لمهمة تحليل جودة المياه. لذلك دعونا ندرّب النموذج ونفحص تنبؤاته:

```
model = create_model("rf")
predict = predict_model(model, data=data)
predict.head()
```

	ph	Hardness	Solids	Chloramines	Sulfate	Conductivity	Organic_carbon	Trihalomethanes	Turbidity	Potability	Label	Score
3	8.316766	214.373304	22018.417441	8.059332	356.896136	363.266516	18.436524	100.341674	4.628771	0	0	0.87
4	9.092223	181.101509	17978.986339	6.546600	310.135738	398.410813	11.558279	31.997993	4.075075	0	0	0.91
5	5.584087	188.313324	28748.687739	7.544869	326.678363	280.467916	8.399735	54.917862	2.559708	0	0	0.83
6	10.223862	248.071735	28749.716544	7.513408	393.683306	283.651634	13.789695	84.603556	2.672989	0	0	0.89
7	8.635849	203.381523	13672.091764	4.563009	303.309771	474.607645	12.363817	62.798309	4.401425	0	0	0.94

النتائج المذكورة أعلاه تبدو مرضية. أمل أن تكون قد أحببت مشروع التعلم الآلي هذا حول تحليل جودة المياه باستخدام بايثون.

الملخص

هذه هي الطريقة التي يمكنك بها تحليل جودة المياه وتدريب نموذج التعلم الآلي لتصنيف المياه الآمنة وغير الآمنة للشرب. يُعد الحصول على مياه الشرب المأمونة أحد الاحتياجات الأساسية لجميع البشر. من وجهة نظر قانونية، يعتبر الحصول على مياه الشرب أحد حقوق الإنسان الأساسية. تؤثر العديد من العوامل على جودة المياه، كما أنها أحد مجالات البحث الرئيسية في التعلم الآلي.

46 التنبؤ بمبيعات ألعاب الفيديو باستخدام التعلم الآلي Video Game Sales Prediction with Machine Learning

تحليل مبيعات ألعاب الفيديو (Video game sales analysis) هو بيان مشكلة شائع على Kaggle. يمكنك العمل على هذه المشكلة لتحليل مبيعات أكثر من 16500 لعبة أو يمكنك أيضاً تدريب نموذج التعلم الآلي للتنبؤ بمبيعات ألعاب الفيديو. لذلك إذا كنت تريد معرفة كيفية تدريب نموذج تنبؤ بمبيعات ألعاب الفيديو، فهذه المقالة مناسبة لك. في هذه المقالة، سأوجهك خلال مهمة تعلم الآلة حول تدريب نموذج توقع مبيعات لعبة فيديو باستخدام بايثون.

نموذج التنبؤ بمبيعات ألعاب الفيديو باستخدام بايثون

تحليل بيانات المبيعات لأكثر من 16500 لعبة هو بيان مشكلة شائع جداً على Kaggle. يمكنك إما حل هذه المشكلة للعثور على العديد من الأنماط (patterns) والعلاقات (relationships) بين العوامل التي تؤثر على مبيعات ألعاب الفيديو، أو يمكنك استخدام مجموعة البيانات هذه للتنبؤ بمبيعات ألعاب الفيديو في المستقبل. لذلك في القسم أدناه، سأوجهك خلال كيفية تدريب نموذج التعلم الآلي للتنبؤ بمبيعات ألعاب الفيديو باستخدام بايثون.

تحتوي مجموعة البيانات التي استخدمها لهذه المهمة على قائمة بألعاب الفيديو ومبيعاتها. لنبدأ هذه المهمة عن طريق استيراد مكتبات بايثون ومجموعة البيانات الضرورية:

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns

data = pd.read_csv("vgsales.csv")
print(data.head())
```

Rank	Name	Platform	Year	...	EU_Sales	JP_Sales	Other_Sales	Global_Sales	
0	1	Wii Sports	Wii	2006.0	...	29.02	3.77	8.46	82.74
1	2	Super Mario Bros.	NES	1985.0	...	3.58	6.81	0.77	40.24
2	3	Mario Kart Wii	Wii	2008.0	...	12.88	3.79	3.31	35.82
3	4	Wii Sports Resort	Wii	2009.0	...	11.01	3.28	2.96	33.00
4	5	Pokemon Red/Pokemon Blue	GB	1996.0	...	8.89	10.22	1.00	31.37

دعنا الآن نرى ما إذا كانت مجموعة البيانات هذه تحتوي على قيم خالية:

```
print(data.isnull().sum())
```

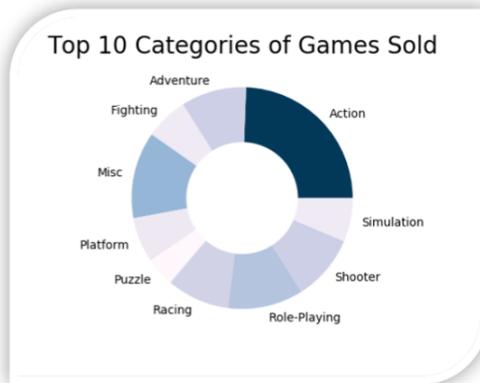
```
Rank      0
Name      0
Platform  0
Year      271
Genre     0
Publisher  58
NA_Sales  0
EU_Sales  0
JP_Sales  0
Other_Sales 0
Global_Sales 0
dtype: int64
```

سأقوم الآن بإنشاء مجموعة بيانات جديدة تزيل القيم الخالية:

```
data = data.dropna()
```

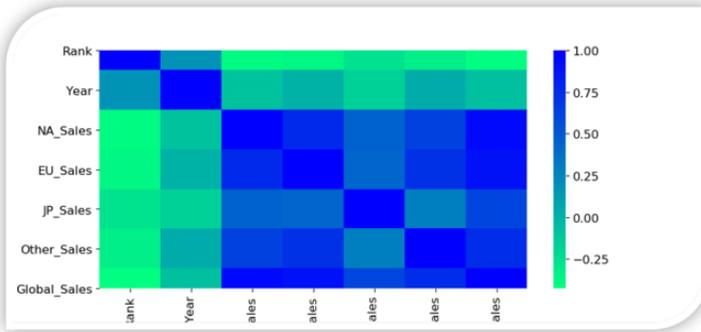
قبل تدريب النموذج، دعنا نلقي نظرة على أفضل 10 فئات من الألعاب مبيعاً:

```
import matplotlib as mpl
game = data.groupby("Genre")["Global_Sales"].count().head(10)
custom_colors = mpl.colors.Normalize(vmin=min(game),
vmax=max(game))
colours = [mpl.cm.PuBu(custom_colors(i)) for i in game]
plt.figure(figsize=(7,7))
plt.pie(game, labels=game.index, colors=colours)
central_circle = plt.Circle((0, 0), 0.5, color='white')
fig = plt.gcf()
fig.gca().add_artist(central_circle)
plt.rc('font', size=12)
plt.title("Top 10 Categories of Games Sold", fontsize=20)
plt.show()
```



دعنا الآن نلقي نظرة على الارتباط (**correlation**) بين ميزات مجموعة البيانات هذه:

```
print(data.corr())
sns.heatmap(data.corr(), cmap="winter_r")
plt.show()
```



نموذج التنبؤ بمبيعات ألعاب الفيديو التدريبية

دعنا الآن نرى كيفية تدريب نموذج التعلم الآلي للتنبؤ بمبيعات ألعاب الفيديو باستخدام بايثون. سأقوم بإعداد البيانات عن طريق تخزين الميزات التي نحتاجها لتدريب هذا النموذج في المتغير x وتخزين العمود الهدف في المتغير y :

```
x = data[["Rank", "NA_Sales", "EU_Sales", "JP_Sales",
"Other_Sales"]]
y = data["Global_Sales"]
```

الآن دعنا نقسم البيانات ونستخدم خوارزمية الانحدار الخطي ([linear regression](#)) لتدريب هذا النموذج:

```
from sklearn.model_selection import train_test_split
xtrain, xtest, ytrain, ytest = train_test_split(x, y,
test_size=0.2, random_state=42)

from sklearn.linear_model import LinearRegression
model = LinearRegression()
model.fit(xtrain, ytrain)
predictions = model.predict(xtest)
```

الملخص

هذه هي الطريقة التي يمكننا بها تدريب نموذج التعلم الآلي للتنبؤ بمبيعات ألعاب الفيديو. هذا بيان مشهور لمشكلة Kaggle يمكنك استخدامه لتحسين مهاراتك في العمل مع البيانات والتدريب على نموذج التعلم الآلي. أأمل أن تكون قد أحببت هذه المقالة حول كيفية تدريب نموذج التنبؤ بمبيعات ألعاب الفيديو باستخدام بايثون.

المصادر

1. 125 Data Science Projects You Can Try with Python, Aman Kharwal, <https://python.plainenglish.io/85-data-science-projects-c03c8750599e>.
2. 40+ Data Analysis Projects with Python, Aman Kharwal, <https://amankharwal.medium.com/data-analysis-projects-with-python-a262a6f9e68c>.

Data Science & Machine Learning

45 Data Science Projects with ML Solved and Explained with Python

By: Dr. Alaa Taima

