宝可梦数据分析

张思雨　龚圆

11.14

目录

1 引言

1.1 项目背景

1.1.1 选题背景

传奇宝可梦（Legendary Pokémon）作为宝可梦系列游戏中的稀有物种，具有极高的价值和吸引力。这些宝可梦通常具有特殊的能力和技能，而且在游戏中只能捕捉到一次。因此，预测一个宝可梦是否为传奇宝可梦成为了玩家们关注的重要问题。

1.1.2 研究背景

收集 1-8 代 1031 只精灵宝可梦的数据集，对宝可梦的各项数据特征，例如种族值、技能、进化条件进行深入研究，并构建一个预测模型。预测一个宝可梦是否为传奇宝可梦。

1.2 研究方法

1.2.1 方法

利用 excel 和 python 对数据进行预处理

利用基于 Python 平台的 Numpy、Pandas 以及机器学习算法库 scikit-learn 提供的 KNeighborsClassifier 分析模型进行数据预测

2 数据采集与处理

2.1 数据获取

2.1.1 数据来源

数据来源于阿里天池

2.1.2 数据集介绍

名称	中文解释

pokedex_number	宝可梦图鉴 ID
name	名称
generation	第几代
classfication	精灵类型
abilities	特殊能力
height_m	身高(米)
weight_kg	体重(千克)
type1	主属性
type2	副属性
base_total	基础总值
hp	声明值
attack	基础攻击属性
defense	基础防御属性
sp_attack	特殊攻击属性
sp_defense	特殊防御属性
speed	基础速度属性
capture_rate	捕捉几率
base_egg_steps	孵化阶段
base_happiness	活跃指数
against_?	18 项定向攻击的伤害指数
is_legendary	是否为传奇宝可梦(1 为是)

3 数据分析与可视化

3.1 种族属性雷达图

3.1.1 数据预处理

对血量、攻击力、防御力、特殊攻击、特殊防御、速度六个基础值做标准化处理，并单独取出传奇的龙系。

```python
from sklearn.preprocessing import MinMaxScaler
col = ['attack','defense','sp_attack','sp_defense','speed','hp']
data_scaled=df[col]
data_scaled=pd.concat([data_scaled,df['type1'],df['is_legendary']],axis=1,join='outer') # 外连接
# 分组统计
data_scaled1=data_scaled.groupby('type1').mean()
data_scaled1=data_scaled1.drop(['is_legendary'],axis=1)
# 构建传奇龙系属性
data_scaled2=data_scaled.groupby(['is_legendary','type1']).mean().reset_index()
dat=data_scaled2[(data_scaled2['is_legendary']==1)&(data_scaled2['type1']=='dragon')] # 取出传奇的龙系
dat=dat.drop(['is_legendary'],axis=1)
dat=dat.rename({20:'dragon_legend'}) # 重命名行索引
# 构建其它传奇属性
dat1=data_scaled.groupby(['is_legendary']).mean().reset_index()
dat1=dat1[dat1['is_legendary']==1]
dat1=dat1.drop(['is_legendary'],axis=1)
dat1=dat1.rename({1:'is_legendary'})
# 数据合并
data_scaled1=pd.concat([data_scaled1,dat,dat1],axis=0,join='outer')
data_scaled1=data_scaled1.drop(['type1'],axis=1)
ind = list(data_scaled1.index) # 获取行索引
# 标准化
model_scaler = MinMaxScaler()
data_scaled1 = model_scaler.fit_transform(data_scaled1)  # 标准化处理
data_scaled1= pd.DataFrame(data_scaled1,index=ind,columns=col)
data_scaled1
```

3.1.2 数据可视化

导入 Origin 作图、调整美观样式

各系宝可梦在血量、攻击力、防御力、特殊攻击、特殊防御、速度六个基础值方面的雷达图

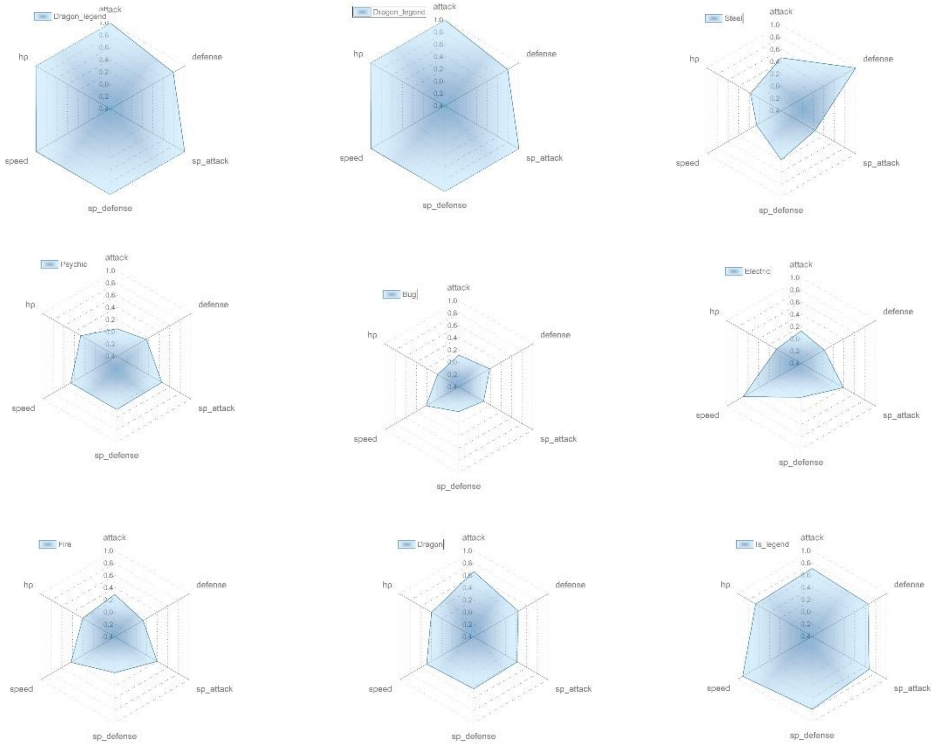

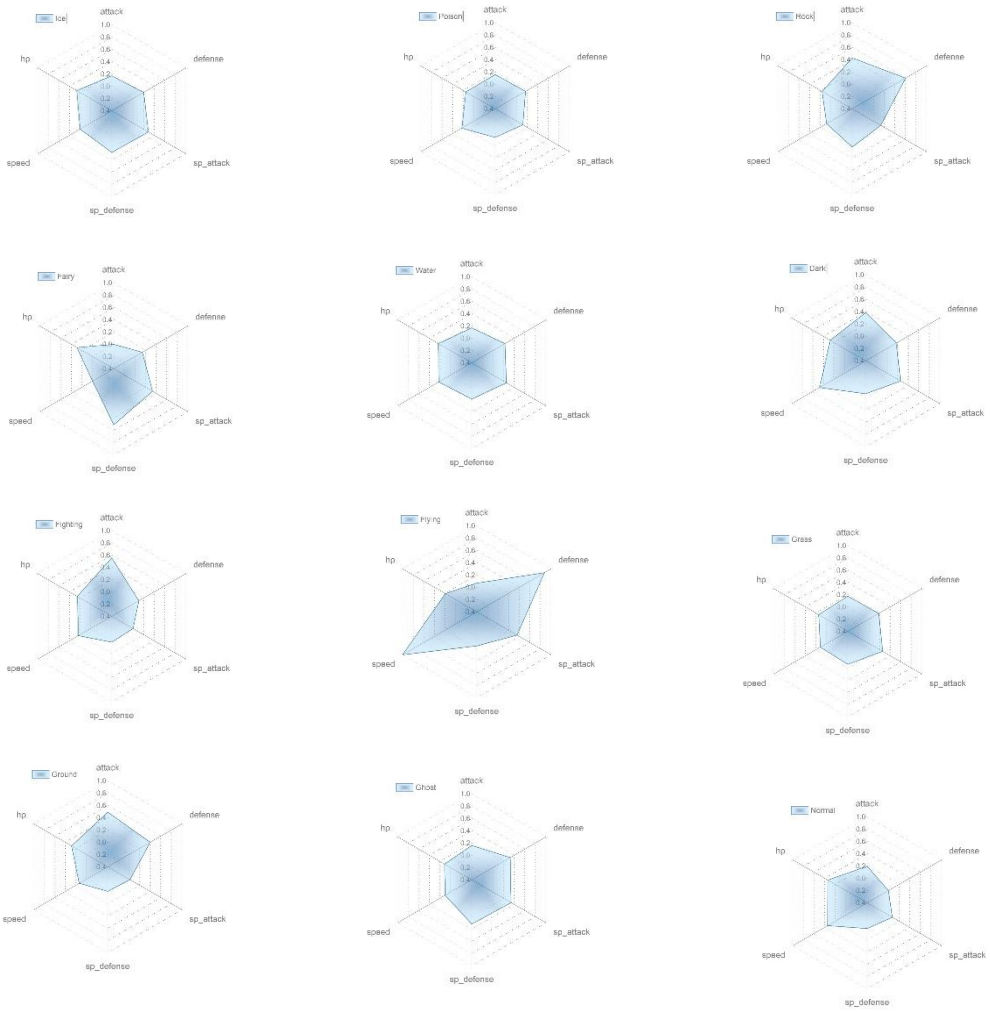

从图中看出各种族精灵的属性强弱势，并且龙系宝可梦具有全方位的碾压优势。

3.2 不同属性精灵数量排行

3.2.1 数据预处理

将 type 相同的数量进行求和排序。

```
def get_count(excel_path, column_name):
    # 读取工作簿
    df = pd.read_excel(excel_path)
    # 统计相同文本的数量
    counts = df[column_name].value_counts()
    return counts

# 测试代码
excel_path = 'pokemon.xlsx'
column_name = 'type'
print(get_count(excel_path, column_name))
```

3.2.2 数据可视化

各属性宝可梦数量的分布

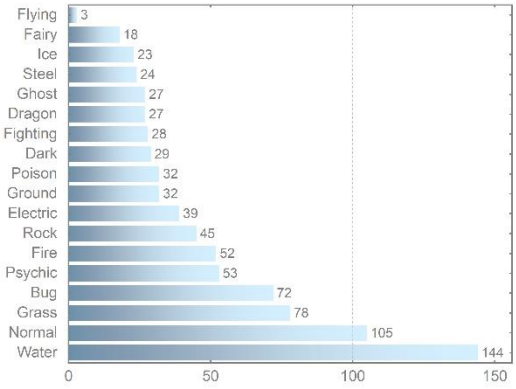

水系宝可梦数量最多，飞行系最少。

3.3 各代精灵数量排行

3.3.1 数据预处理

将 generation 相同的数量进行求和。

```
def get_count(excel_path, column_name):
    # 读取工作簿
    df = pd.read_excel(excel_path)
    # 统计相同文本的数量
    counts = df[column_name].value_counts()
    return counts

# 测试代码
excel_path = 'pokemon.xlsx'
column_name = 'generation'
print(get_count(excel_path, column_name))
```

3.3.2 数据可视化

导入 Origin 作图、调整美观样式

1~8 代宝可梦的数量

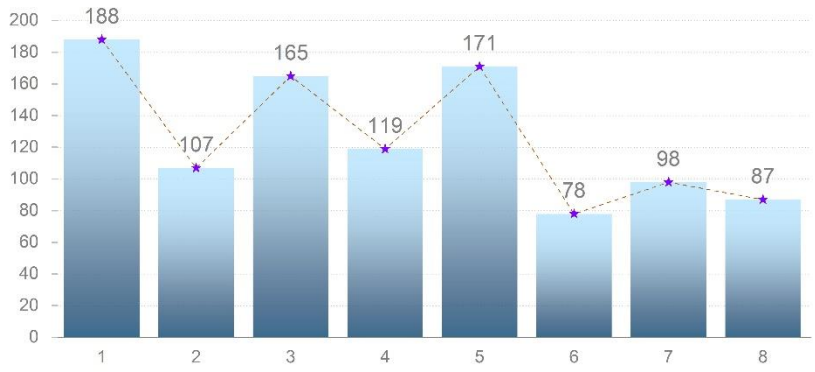

1~8 代宝可梦数量占比

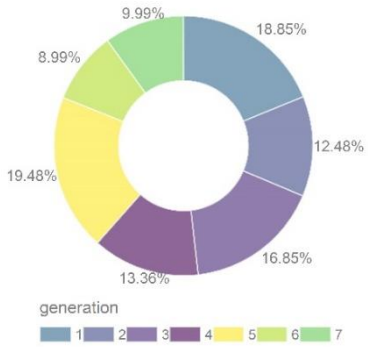

从图中看出，第一代精灵数量最多，6、7、8 代相对较少。

3.4 双系宝可梦数量

```
plt.subplots(figsize=(10, 10))
sns.heatmap(df[df['type2']!='None'].groupby(['type1', 'type2']).size().unstack(), linewidths=1, annot=True, cmap="B]
plt.xticks(rotation=35)
plt.show()
```

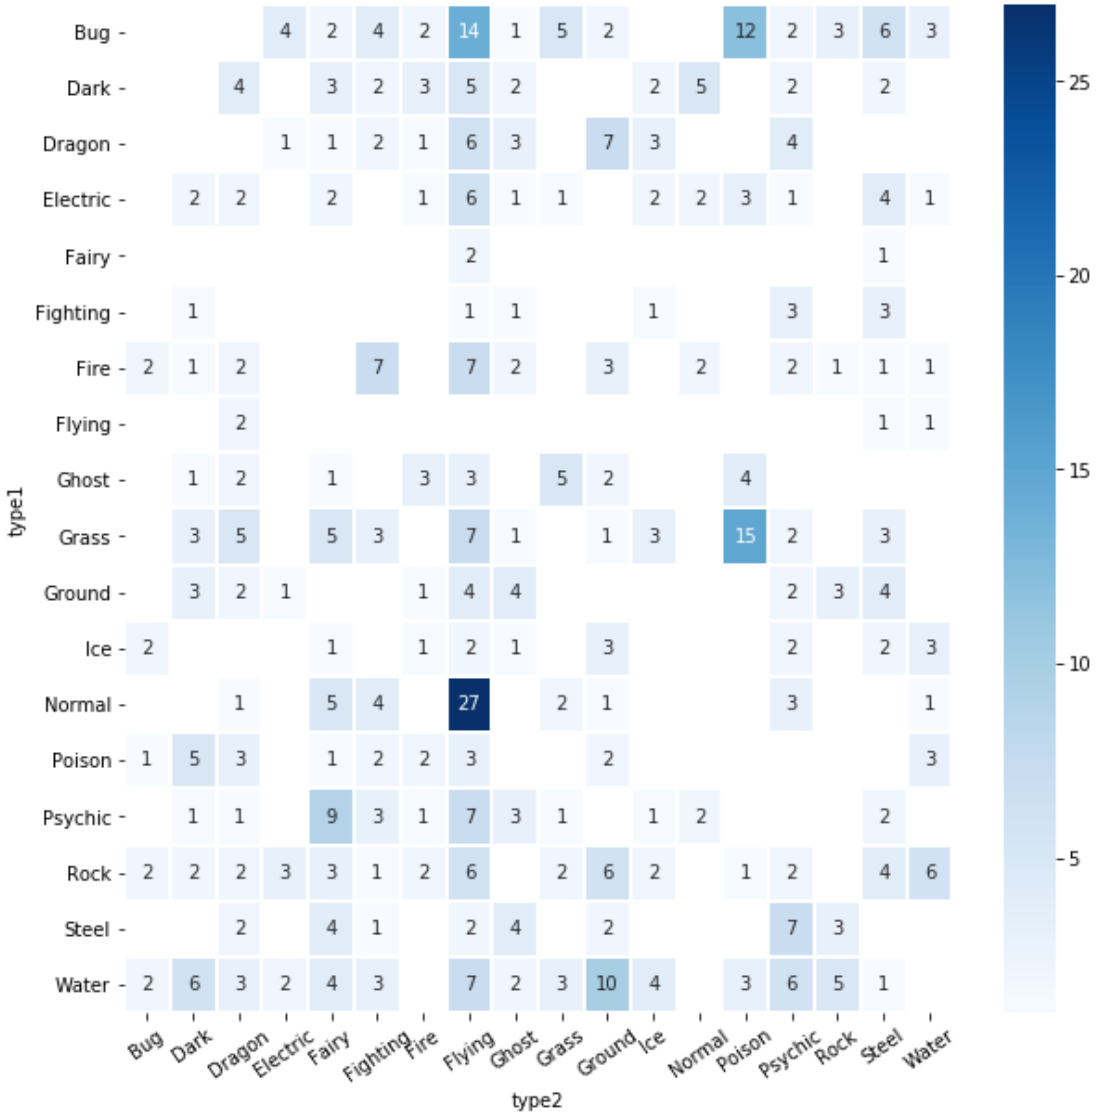

3.5 种族属性总值

3.5.1 数据预处理

针对 against_bug, against_dark, against_dragon, against_electric, against_fairy, against_fighting, against_fire, against_flying, against_ghost, against_grass, against_ground, against_ice, against_normal, against_poison, against_psychic, against_rock, against_steel, against_water,

即含有“against”的数据进行加总。首先读文件，并将结果存储在 df 变量中。然后使用 groupby 函数对指定的属性列和数值列进行分组，并使用 sum 函数对每个分组的数值列进行求和。最后打印出每个属性的总和。

```
def sum_by_attribute(excel_path, attribute_column, value_column):
    # 读取 Excel 文件
    df = pd.read_excel(excel_path)

    # 对指定属性列和数值列进行加总求和
    total_sum = df.groupby(attribute_column)[value_column].sum()

    # 打印结果
    print(total_sum)

excel_path = 'pokemon.xlsx'
attribute_column = 'type'
value_column = 'against-'
sum_by_attribute(excel_path, attribute_column, value_column)
```

3.5.2 数据可视化

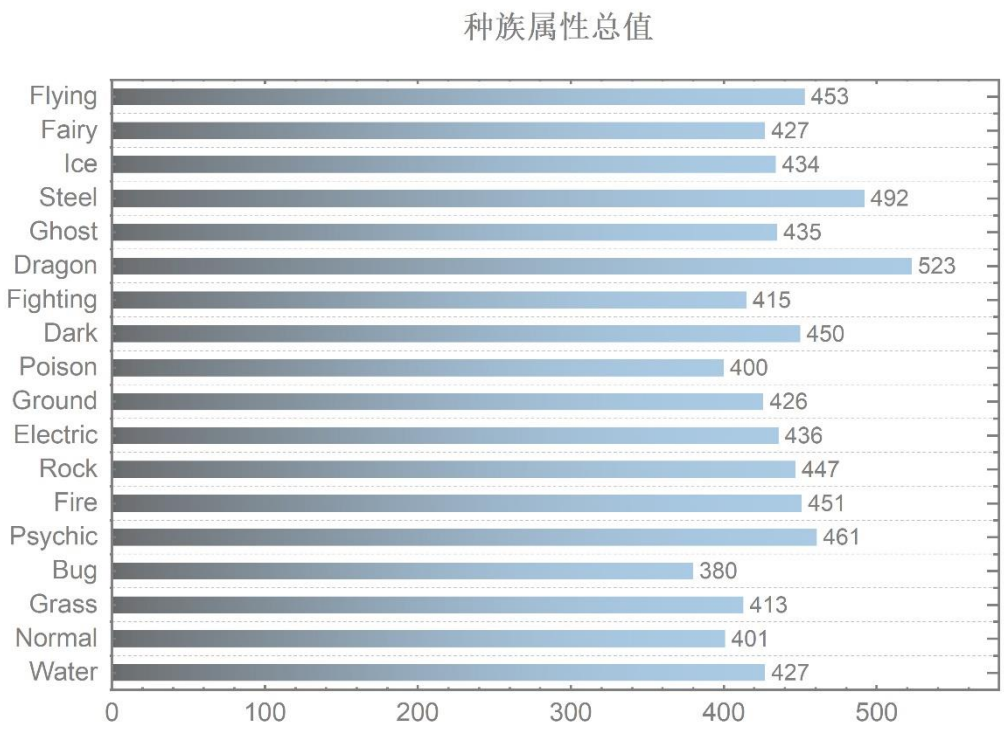

龙系的属性总值最高，超过了 500，虫系最低，低于 400，与上面雷达图展示一致。虫系历来就是被玩家认为是最弱的属性，抗性也较弱，很多属性对虫系都有抵抗效果，能力较高的虫系宝可梦，数量也相对较少。但虫系的宝可梦培育的难度比较小，可以很快的进化到最终形态，能够在游戏的前期发挥重要的作用。

3.6 各精灵抗性属性

处理 against 属性值

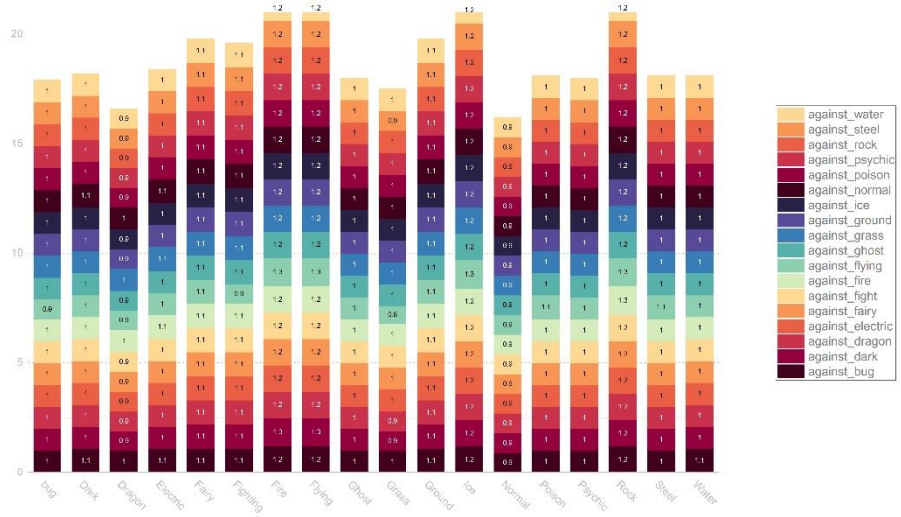

抗性方面:钢系抗性总值是最好的，除了地面、格斗、火属性伤害值相对较高，其余都比较低。岩石系及冰系抗性是最弱的，岩石系对格斗、草系、地面、钢系、水系抗性较低，冰系对火系、格斗、岩石、钢系抗性较低，龙系处于中间阶段。

3.7 不同种族能力平均值排行

3.7.1 数据预处理

一个精灵对应一个或多个 ability，数据集中 abilities 列将该精灵的 ability 由顿号分隔列举，因此需对 ability 数进行额外计算掌握能力数量平均值。

定义一个名为 get_average 的函数，它接收四个参数，分别为 excel_path，sheet_name，name_column，content_column，分别表示 excel 文件路径，sheet 页名称，名称列，内容列。在函数内部，首先读取传入文件的 sheet 页的数据，并赋值给变量 df，然后使用 groupby 方法对 df 的 name_column 列进行分组，并使用 apply 方法对分组后的数据使用 split 方法将内容列以逗号分隔的内容分开并计算数量，最后求出平均值并将结果赋值给变量 average，最后返回 average。

```
def get_average(excel_path, sheet_name, name_column, content_column):
    # 读取工作簿
    df = pd.read_excel(excel_path, sheet_name)
    # 统计相同名称的数量并求平均值
    average = df.groupby(name_column)[content_column].apply(lambda x: x.str.split('、'). len()).mean()
    return average

excel_path = 'pokemon.xlsx'
sheet_name = 'ability'
name_column = 'type'
content_column = 'abilities'
print(get_average(excel_path, sheet_name, name_column, content_column))
```

3.7.2 数据可视化

各种族拥有的能力数量平均值

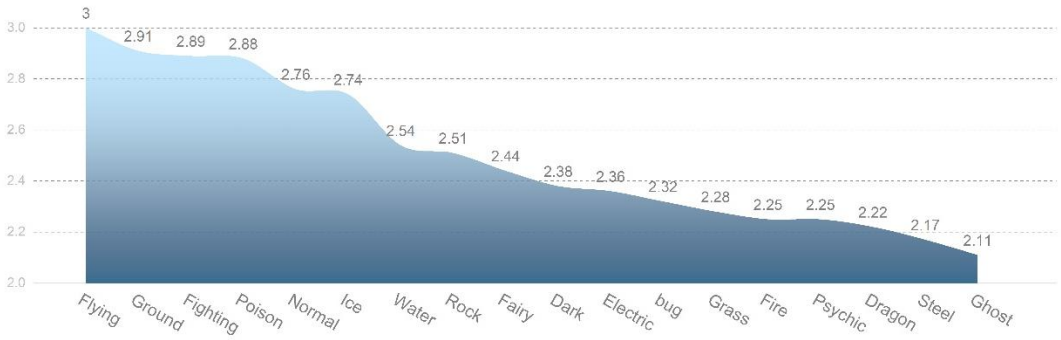

各种族平均拥有能力数都在 2 个以上，飞行系拥有平均能力数达到 3。

3.8 战斗分析

```
interested = ['hp','attack','defense','sp_attack','sp_defense','speed']
sns.pairplot(df[interested])
plt.show()
```

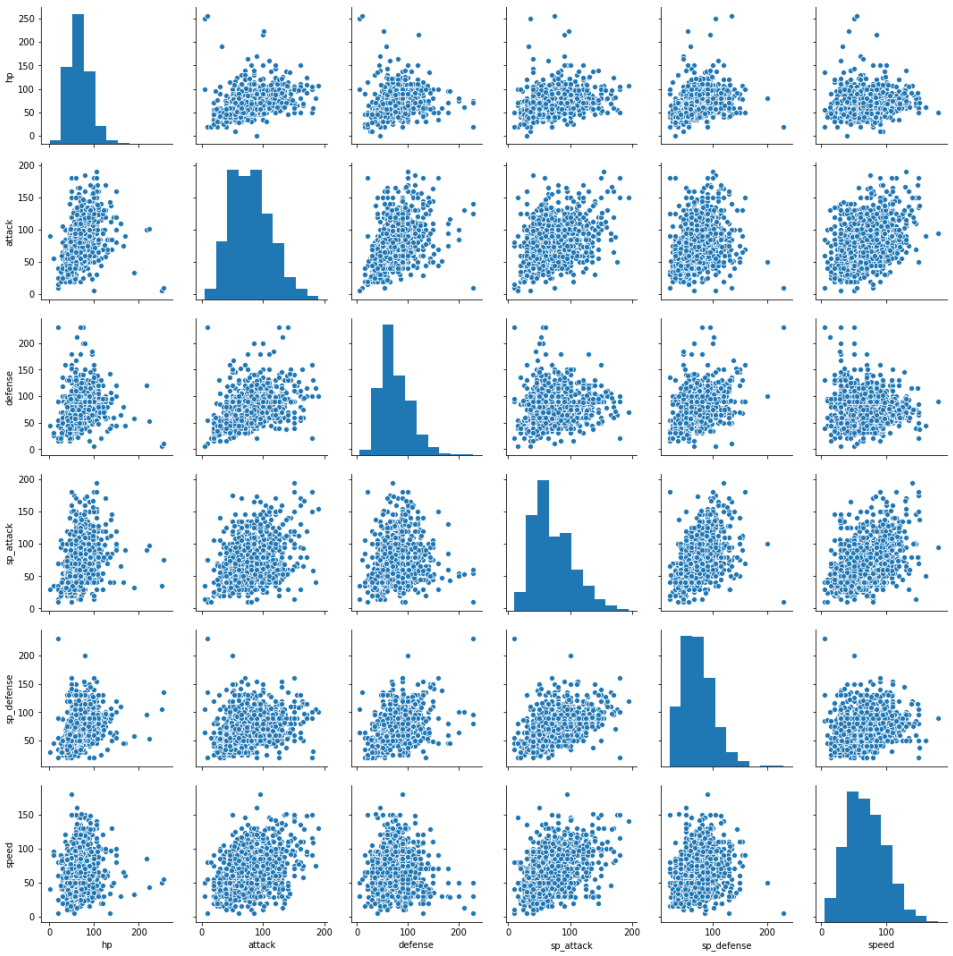

3.9 传奇宝可梦和普通宝可梦捕获率对比

3.9.1 数据预处理

将传奇宝可梦和普通宝可梦分开分别求捕获率平均值。

```python
def get_average(excel_path, sheet_name, name_column, number_column):
    # 读取工作簿
    df = pd.read_excel(excel_path, sheet_name)
    # 统计相同名称的数量并求平均值
    average = df.groupby(name_column)[number_column].mean()
    return average

excel_path = 'demo.xlsx'
sheet_name = '捕获率对比'
name_column = 'generation'
number_column = 'capture_rate'
print(get_average(excel_path, sheet_name, name_column, number_column))
```

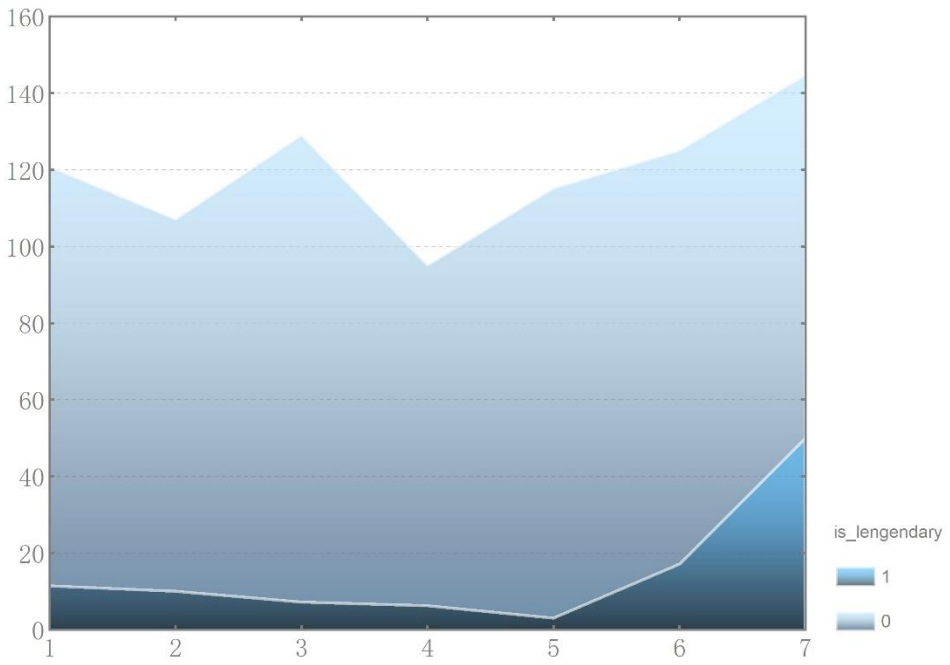

3.9.2 数据可视化

捕获率方面龙系捕获率最低，传奇系远低于普通系，直到第七代，传奇系捕获率才有一个明显上升。由于龙系及传奇系本身就很强大，而越强大的宝可梦就越稀少，捕获难度自然就高。

3.10 各代精灵为传奇数量

3.10.1 数据预处理

```
group_generation = df.groupby('generation')          # 按generation分组
group_generation = group_generation[['is_legendary']].sum()
```

3.10.2 数据可视化

分别制作柱状图和 3D 饼图，

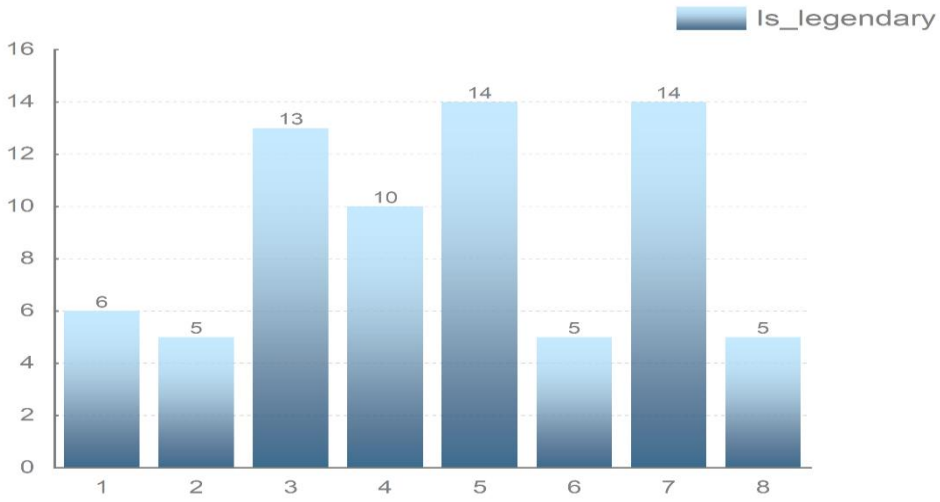

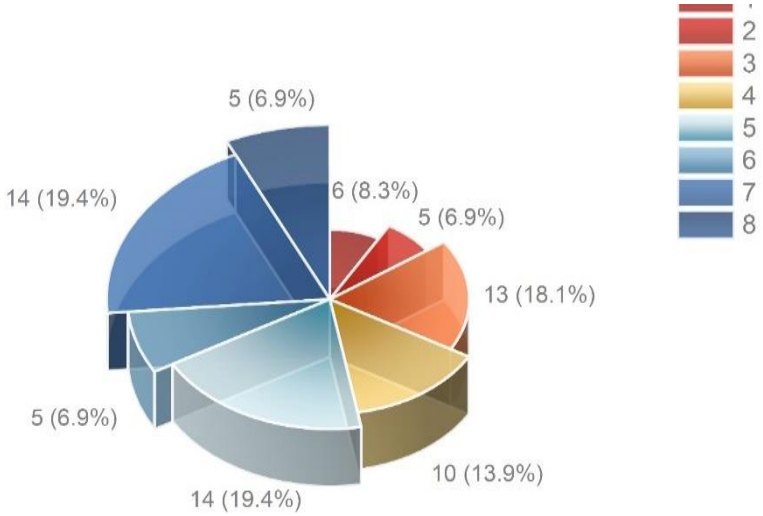

可见第一代精灵虽然多，但是为传奇的数量相对较少。

4 数据预测

4.1.数据预处理

4.1.1 数据清洗

观察发现 type1 数据为字符串，分别替换为数值 1~19

```
# 数据清洗
df['type1'].replace(['Bug', 'Dark', 'Dragon', 'Electric', 'Fairy', 'Fighting', 'Fire',
                     'Flying', 'Ghost', 'Grass', 'Ground', 'Ice', 'Normal', 'Poison',
                     'Psychic', 'Rock', 'Steel', 'Water'],
                    list(range(1, 19)), inplace=True)
```

4.1.2 数据选取

由于 type2 数据缺失过多，classfication 与 abilities 为多重复合特征，在预测时去除这三个特征，并去除预测目标“is_legendary”列

```
25  # 划分数据集
26  target = 'is_legendary'
27  X = df.iloc[:, 2:].drop(columns=['type2','classfication','abilities',target])
```

4.1.3 标准化

由于不同特征的数据数量级相差较大，因此进行了标准化处理

```
15  #标准化处理
16  X = (X - np.mean(X)) / np.std(X)
```

4.2 模型预测

4.2.1 模型选取

使用 rbf_svm、linear_svm、KNN 三种不同的预测模型精灵宝可梦是否为传奇精灵，并查看预测的正确率

```
31  # 使用不同的预测模型精灵宝可梦是否为传奇精灵，并查看预测的正确率
32  machine_name = np.array(['rbf_svm', 'linear_svm', 'KNN'])
33  machine_x = np.array([1, 2, 3])
34  machine_score = np.array([])
35
```

4.2.2 预测正确率

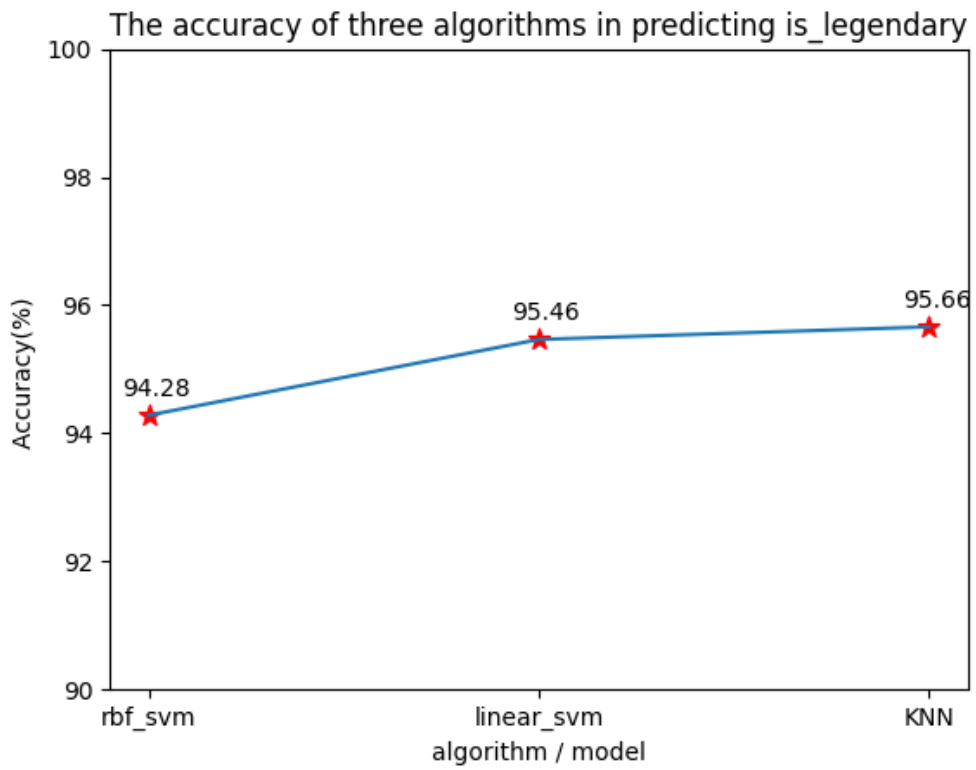

观察发现 KNN 算法的正确率最高，于是对 KNN 算法进行调参，观察正确率的变化

4.3IKNN 调参

4.3.1 研究不同的 test_size 对预测结果的影响

```
#改变test_size的取值，观察对正确率的影响
knn = KNeighborsClassifier()
y_list = np.array([])                                          # 存储正确率
test_list = np.array([0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9]) # 不同的test_size
for i in range(9):
    X_train, X_test, y_train, y_test = train_test_split(X, Y, test_size=test_list[i], random_state=18)  # 划分数据集
    knn.fit(X_train, y_train.values.ravel())                   # 训练
    y_KNCpred = knn.predict(X_test)                            # 计算正确率
    y_list = np.append(y_list, [metrics.accuracy_score(y_KNCpred, y_test) * 100])
for i, v in enumerate(y_list):                                 # 添加点值
    plt.text(test_list[i]*100-0.8, v+0.1, '%.2f' % v)
plt.plot(test_list * 100, y_list, 'b-o')                       # 绘制折线图
plt.title('Forecast of ' + target + ' when changing test_size')
plt.xlabel('test_size ( % )')
plt.ylabel('Accuracy ( % )')
plt.ylim(90, 100)
plt.show()
```

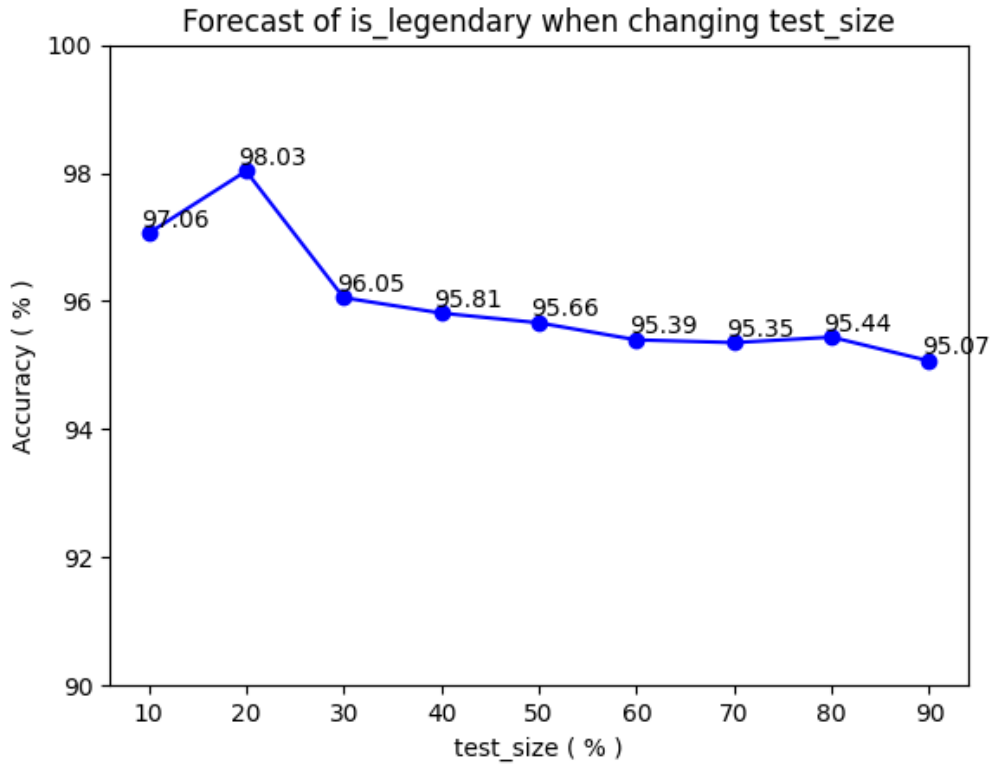

发现当 test_size 取 0.2 时，预测的准确率最高

4.4 探究预测过程中，各个特征的重要性

4.4.1 随机森林模型评估特征重要性

```
# 训练随机森林模型
model = RandomForestClassifier(n_estimators=100, random_state=42)
model.fit(X_train, y_train)

# 输出特征重要性
importance = model.feature_importances_
indices = np.argsort(importance)[::-1]

#绘制散点图显示每个特征的重要性
importance_df = pd.DataFrame({'Feature': X.columns, 'Importance': model.feature_importances_})
print(importance_df)
plt.scatter(X.columns, importance,s= list(map(lambda x: x * 1000, importance))  )
plt.xlabel('Feature')
plt.ylabel('Importance')
plt.xticks(rotation=90, fontsize=10)
plt.title('the importance of each feature on RandomForestClassifier')
plt.show()
```

各特征在预测算法中重要性如图

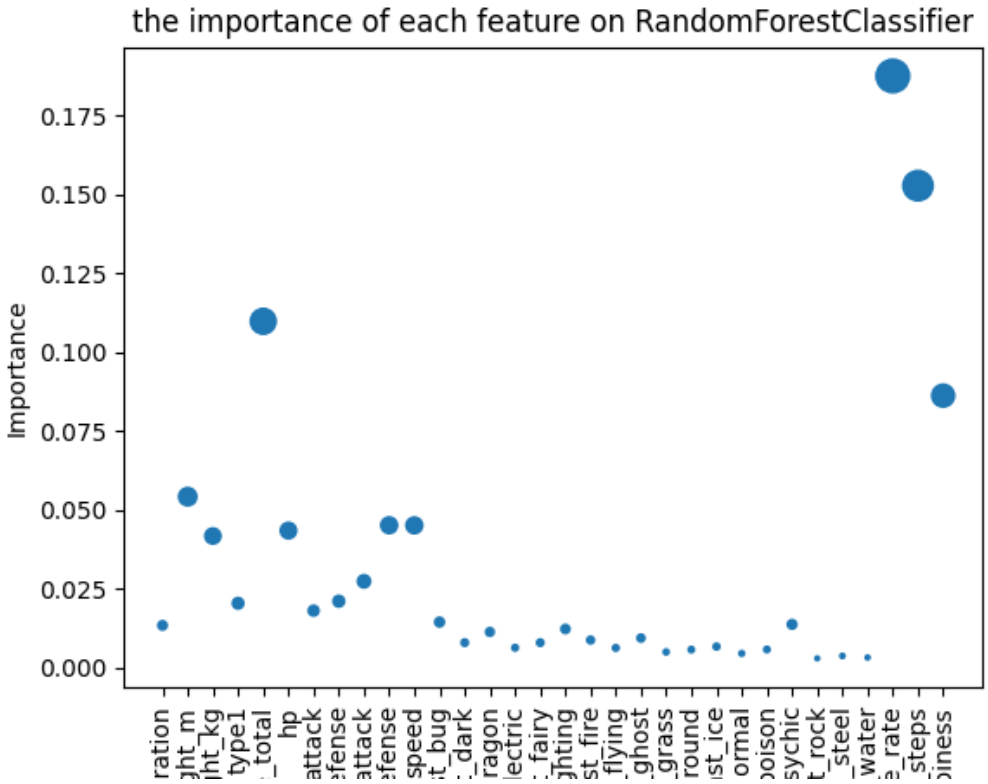

由图可以得出在预测宝可梦是否为传奇宝可梦的过程中，较为重要的几个特征及其对应的重要性分别为

capture_rate 0.187650
base_egg_steps 0.152833
base_total 0.109798
base_happiness 0.086215

5.总结

5.1 总结

5.1.1 数据可视化部分

本次项目对各种族宝可梦的血量、攻击力、防御力、特殊攻击、特殊防御、速度六个基础值，每代宝可梦的数量，每代传奇宝可梦的数量，以及宝可梦的战斗能力进行了简要分析。

5.1.2 预测部分

采用了三种预测模型，通过宝可梦的各项特征对是否为传奇宝可梦进行预测。默认

test_size 为 0.5 时，KNN 模型的准确率最高。对 KNN 进行参数调整，当 test_size 取 0.2 时准确率最高。并且对预测过程中各特征的重要性进行分析，其中较为重要的几个特征依次为 capture_rate、base_egg_steps、base_total、base_happiness。