

人工智能程序设计

python

```
import turtle
turtle.setup(650,350,200,200)
turtle.penup()
turtle.fd(-250)
turtle.pendown()
turtle.pensize(25)
turtle.color("purple")
for i in range(4):
    turtle.circle(40, 80)
    turtle.circle(-40, 80)
    turtle.circle(40, 80/2)
    turtle.circle(-40, 80/2)
    turtle.fd(40)
    turtle.circle(16, 180)
    turtle.fd(40 * 2/3)
```



人工智能程序设计

11.4 机器学习实践案例

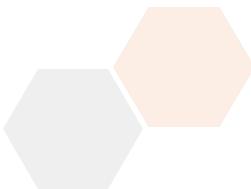
北京石油化工学院 人工智能研究院

刘 强

11.4.1 分类任务实践：泰坦尼克号生存预测

泰坦尼克号生存预测是机器学习入门的经典案例：

- **数据量适中**：约800条训练数据
- **特征丰富**：数值型（年龄、票价）和类别型（性别、船舱等级）
- **问题明确**：预测乘客是否生存，典型的二分类问题
- **现实意义**：具有历史背景，能激发学习兴趣



步骤1：数据准备

创建模拟数据集，包含乘客的基本信息和生存标签：

```
## 创建模拟数据集的核心逻辑
data = {
    'Age': np.random.normal(30, 12, n_samples),
    'Sex': np.random.choice(['male', 'female'], n_samples),
    'Pclass': np.random.choice([1, 2, 3], n_samples),
    'Fare': np.random.exponential(30, n_samples),
}

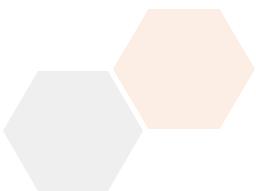
## 根据特征生成生存标签
for i in range(n_samples):
    prob = 0.3 # 基础生存概率
    if data['Sex'][i] == 'female': prob += 0.4 # 女性生存率更高
    if data['Pclass'][i] == 1: prob += 0.3 # 头等舱生存率更高
```

步骤2：探索性数据分析

分析不同特征与生存率的关系，发现数据中的规律：

```
## 分析不同特征与生存率的关系
sex_survival = df.groupby('Sex')['Survived'].mean()
class_survival = df.groupby('Pclass')['Survived'].mean()

## 可视化特征分布和相关性
plt.figure(figsize=(15, 12))
## 生存率分布、特征分布、相关性热力图等
```



步骤3：数据预处理

处理缺失值、编码分类变量、创建新特征：

```
## 处理缺失值
df['Age'].fillna(df['Age'].median(), inplace=True)

## 编码分类变量
le = LabelEncoder()
df['Sex'] = le.fit_transform(df['Sex'])

## 特征工程
df['FamilySize'] = df['SibSp'] + df['Parch'] + 1
df['IsAlone'] = (df['FamilySize'] == 1).astype(int)
```



步骤4：模型训练与评估

准备数据并训练多个模型进行比较：

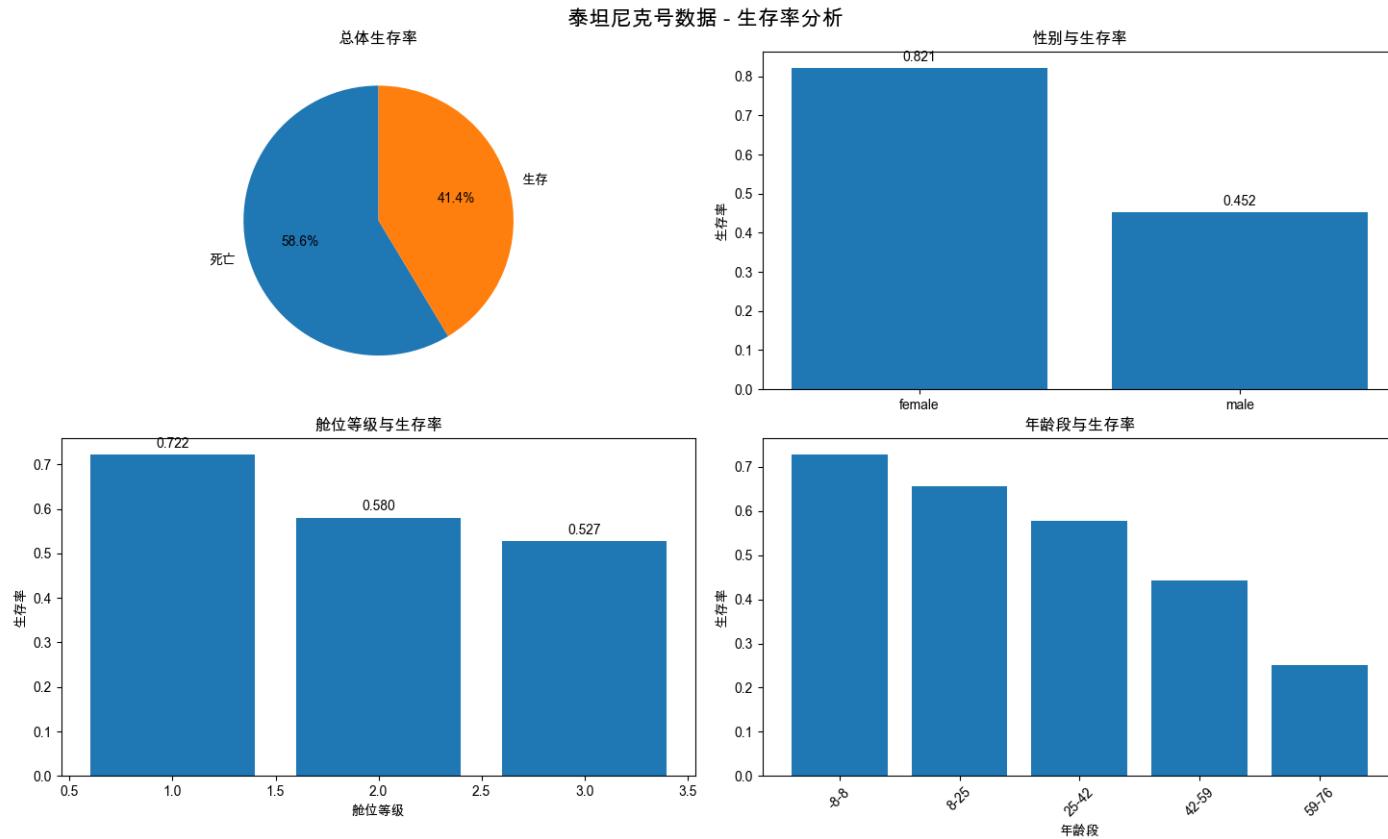
```
## 准备训练数据
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

## 训练多个模型
models = {
    '决策树': DecisionTreeClassifier(max_depth=5, random_state=42),
    '随机森林': RandomForestClassifier(n_estimators=100, random_state=42),
    '逻辑回归': LogisticRegression(random_state=42)
}

## 评估模型性能
for name, model in models.items():
    model.fit(X_train, y_train)
    y_pred = model.predict(X_test)
    accuracy = accuracy_score(y_test, y_pred)
    print("{} 准确率: {:.3f}".format(name, accuracy))
```

泰坦尼克号生存率分析

图 11.4.1 泰坦尼克号生存率分析



11.4.2 回归任务实践：房价预测

房价预测是回归任务的典型应用：

- 目标是根据房屋特征预测其价格
- 展示如何处理连续数值型的目标变量
- 学习评估回归模型的性能指标

数据集特征：房屋面积、卧室数量、浴室数量、房龄、地段等级、是否有车库、是否有花园



步骤1：数据准备

创建模拟房价数据集，根据特征生成合理的房价：

```
## 创建模拟房价数据集
data = {
    'Size': np.random.normal(150, 50, n_samples),      # 房屋面积
    'Bedrooms': np.random.poisson(3, n_samples),       # 卧室数量
    'Location': np.random.choice([1, 2, 3, 4, 5], n_samples),  # 地段等级
    'Age': np.random.exponential(10, n_samples),        # 房龄
}

## 根据特征生成房价
for i in range(n_samples):
    price = base_price + data['Size'][i] * 2000 # 面积影响
    price *= location_multiplier[data['Location'][i]] # 地段影响
```

步骤2：特征工程

创建新的衍生特征，提升模型预测能力：

```
## 创建新特征
df['PricePerSqm'] = df['Price'] / df['Size'] # 每平米价格
df['TotalRooms'] = df['Bedrooms'] + df['Bathrooms'] # 总房间数
df['RoomRatio'] = df['Bathrooms'] / df['Bedrooms'] # 浴室卧室比

## 分类特征编码
df = pd.get_dummies(df, columns=['SizeCategory', 'AgeCategory'])
```



步骤3：模型训练与评估

训练多个回归模型并比较性能：

```
## 训练多个回归模型
regression_models = {
    '线性回归': LinearRegression(),
    '决策树回归': DecisionTreeRegressor(max_depth=10, random_state=42),
    '随机森林回归': RandomForestRegressor(n_estimators=100, random_state=42)
}

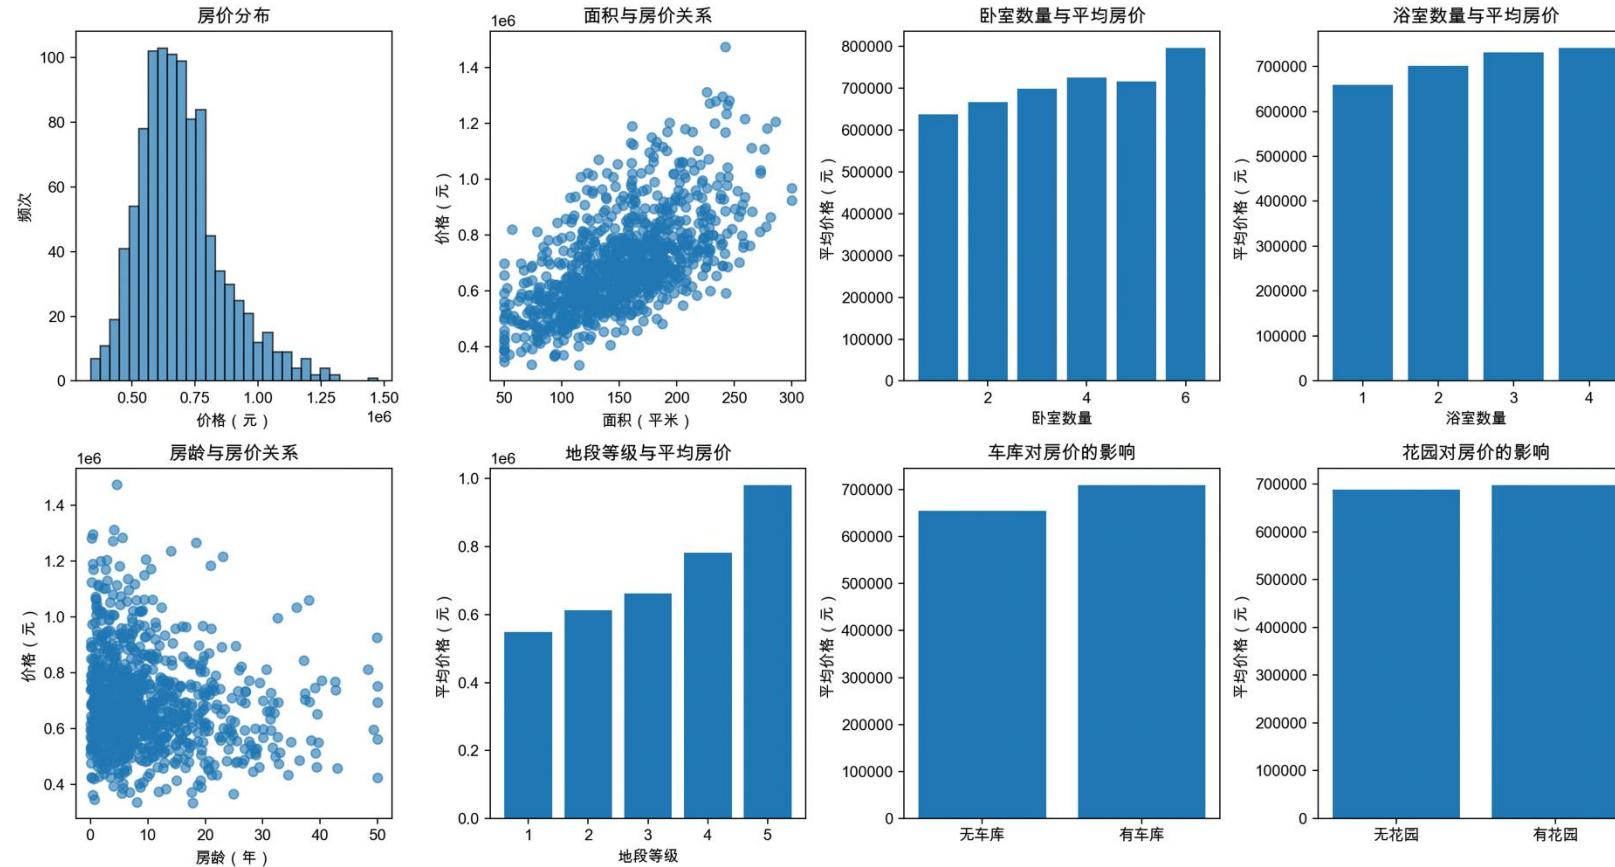
## 评估回归性能
for name, model in regression_models.items():
    model.fit(X_train, y_train)
    y_pred = model.predict(X_test)

    r2 = r2_score(y_test, y_pred)
    rmse = np.sqrt(mean_squared_error(y_test, y_pred))
    mae = mean_absolute_error(y_test, y_pred)

    print("{} - R²: {:.3f}, RMSE: {:.0f}, MAE: {:.0f}".format(name, r2, rmse, mae))
```

房价回归分析

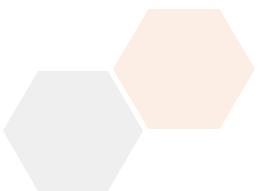
图 11.4.2 房价回归分析



11.4.3 Ask AI: Kaggle竞赛入门

Kaggle 是全球最大的数据科学竞赛平台:

- 接触真实的商业问题
- 学习最佳实践
- 在竞争中快速提升技能



推荐入门竞赛

泰坦尼克号生存预测

- 最适合初学者的竞赛
- 数据集小巧，问题清晰
- 学习分类任务的绝佳起点

房价预测竞赛

- 学习回归任务和特征工程技巧

手写数字识别

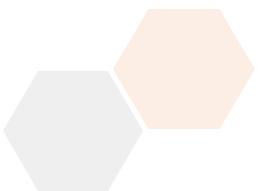
- 理解图像分类的基本方法



实践练习

练习 11.4.1：分类模型优化

1. 在泰坦尼克案例中尝试不同的特征工程方法
2. 比较决策树、随机森林、逻辑回归的性能
3. 分析模型的优缺点和适用场景



实践练习

练习 11.4.2：销量预测模型

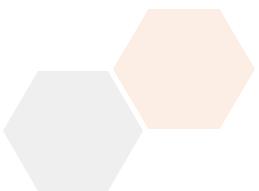
1. 构建商品销量预测数据集，包含特征：价格、促销力度、季节、广告投入、库存量等
2. 尝试不同的回归算法（线性回归、决策树回归、随机森林回归）
3. 使用交叉验证评估模型稳定性，分析哪些特征对销量影响最大



实践练习

练习 11.4.3: Kaggle实践

1. 注册 **Kaggle** 账号, 浏览泰坦尼克竞赛
2. 下载数据集, 完成基本的数据分析
3. 提交一次预测结果, 体验完整流程



本节小结

- **分类任务**: 泰坦尼克号生存预测, 预测离散类别
- **回归任务**: 房价预测, 预测连续数值
- **完整流程**: 数据准备→探索分析→预处理→模型训练→性能评估
- **Kaggle平台**: 提供真实项目实践机会

