



モデル作成・検証 Cheat Sheet

代表的なアルゴリズム




k-NN

学習データをプロットしておき、新しいデータに対し、そこから距離が近い順に任意のK個を取得し、多数決でデータが属するクラスを推定するクラス判別のアルゴリズムです。



Naive Bayes

ベイズの定理をもとにデータが与えられたときの全ての推定の確率を計算し、最も確率の高いものを推定結果として出力します。



Decision Tree

ツリーによって分類を行う手法です。可読性が高く、外れ値にも強い手法ですが、過学習を起こしやすいため、パラメータ調整や枝の刈り込みが必要となります。




Random Forest

アンサンブル学習をベースに、多数の異なる決定木 (Decision Tree)を集めて分析を行う手法です。決定木で起きやすい過学習を避けることができます。




SVM

クラスを分類する境界線を引き、データ判別を行う手法です。少ないデータで結果を出すことができます。カーネルトリックにより、非線形データにも対応できます。



Logistic Regression

回帰手法を応用して二項分類を行うロジスティック回帰のオペレータです。
2値カテゴリ(Binomial)がlabelとして設定されている必要があります。



Linear Regression

線形回帰を行うオペレータです。
数値項目が目的変数(Label)として設定されている必要があります。



Generalized Linear Model

従来の線形回帰を拡張した一般化線形モデルを使用するオペレータです。
正規分布ではないデータに対しても有効に利用できます。


モデル適用



Apply Model


unlポートに接続されたラベル無しデータに対し、Modポートに接続されているモデルを適用するオペレータです。

検証




Performance

精度検証に用いるオペレータです。
汎用できるものから、回帰や分類に特化したものもありますので、用途に合わせて使い分けをしてください。



Validation

分割検証(Split Validation)に使用するオペレータです。
入力されたデータセットを指定した割合で学習データとテストデータに分割し、1回のみ検証を実施します。
内部プロセスの左側で学習モデルの作成、右側で検証を行います。




Cross Validation


交差検証を行う際に使用します。データセットを指定したk個に分割し、一つをテストデータ、残りを学習データとして検証を行い、組み合わせを変えてk回反復します。
モデルに過剰適合が起きていないかの確認に用います。

サンプル

■ Cross Validation使用の一例



■ Forward Selection使用の一例



精度向上



Forward Selection

説明変数が多いとき、説明変数の組み合わせを変えながら、最も高い正答率となる組み合わせを探すときに使用するオペレータです。



Optimize Parameters (Grid)

オペレータのハイパーパラメータの最適化をします。
選択された範囲内から最適なパラメータの組み合わせをグリッドサーチによって探索します。