

Maschinelles Lernen 1

Wintersemester 2010/2011

Abteilung Maschinelles Lernen
 Institut für Softwaretechnik und
 theoretische Informatik
 Fakultät IV, Technische Universität Berlin
 Prof. Dr. Klaus-Robert Müller
 Email: klaus-robert.mueller@tu-berlin.de

Blatt 8

Abgabe bis Mittwoch, den 5. Januar 2011 um 12:00

Die Lösungen bitte per Email an **konrad+lehre@mlsec.org** senden
 und im **Postfach** von Dr. Konrad Rieck abgeben.

Bias-Varianz-Dilemma

In der Vorlesung wurde die Bias-Varianz-Zerlegung vorgestellt. Wir betrachten ein Lernproblem mit Verteilung $(X, Y) \sim p(x, y)$. Es sei

$$f(x) = E(Y|X=x),$$

d.h. der Erwartungswert von Y am Punkt x . Dies ist die optimale Vorhersage bezüglich des quadratischen Abstandsmaßes $l(y, y') = (y - y')^2$.

Wir halten einen Punkt x fest und betrachten die Vorhersage eines Lernalgorithmus g unter einem zufällig gewählten Trainingsdatensatz D .

$$E_D(g_D(x) - f(x))^2 = \underbrace{[E_D(g_D(x) - f(x))]^2}_{\text{Bias}^2} + \underbrace{E_D [g_D(x) - E_D(g_D(x))]^2}_{\text{Varianz}}$$

Auf diesem Aufgabenblatt soll der Bias und die Varianz experimentell gemessen werden.

Hierbei werden die Erwartungswerte geschätzt, in dem wiederholt einen Datensatz generiert, und die Vorhersagen an einer Anzahl von Stützstellen notiert und daraus Bias und Varianz berechnet, d.h.

$$\hat{b}(x) = \frac{1}{m} \sum_{i=1}^m (g_{D_i}(x) - f(x)).$$

$$\hat{v}(x) = \frac{1}{m-1} \sum_{i=1}^m \left(g_{D_i}(x) - \frac{1}{m} \sum_{j=1}^m g_{D_j}(x) \right)^2.$$

Da es sich um einen künstlich generierten Datensatz handelt, ist $f(x)$ bekannt.

Implementiere die folgenden Funktionen (jeweils 10 Punkte):

- **variance_per_point** Berechnet die Varianz $\hat{v}(x)$ für eine Reihe von Punkten x_1, \dots, x_n gelernt auf Datensätzen D_1, \dots, D_m .
- **squared_bias_per_point** Berechnet den quadrierten Bias $\hat{b}(x)^2$ für eine Reihe von Punkten x_1, \dots, x_n gelernt auf Datensätzen D_1, \dots, D_m .
- **squared_error_per_point** Berechnet den quadratischen Fehler

$$\hat{e}(x) = \frac{1}{m} \sum_{i=1}^m (g_{D_i}(x) - f(x))^2$$

für eine Reihe von Punkten x_1, \dots, x_n gelernt auf Datensätzen D_1, \dots, D_m .

Übergeben wird jeweils eine Matrix Y , die die Vorhersagen für alle Punkte und Datensätze enthält.

```
function sheet08
```

```
% The parameters:  

M = 1000; % number of evaluation points  

X = linspace(-4, 4, M)'; % the evaluation points  

ITERS = 100; % number of resamples
```

```

WIDTHS = logspace(-3, 1, 9); % the kernel widths
N = 100; % number of data points

% set up some empty vectors to collect the information
BIAS2 = zeros(length(WIDTHS), 1);
VARIANCE = zeros(length(WIDTHS), 1);
ERR = zeros(length(WIDTHS), 1);

% plot individual means and variances for 9
% different widths
figure(1)
for WI = 1:length(WIDTHS)
    W = WIDTHS(WI)

    % collect predictions for ITERS many resamples
    % predictions for one resample are stored in the columns of Y
    Y = zeros(M, ITERS);
    for I = 1:ITERS
        [DX, DY] = generate_data(N);
        Y(:, I) = kernel_regression(W, DX, DY, X);
    end

    % compute mean and variance
    ME = mean(Y, 2);
    VA = variance_per_point(Y);

    % plot the result
    subplot(3, 3, WI)
    plot(DX, DY, '.', ... % the last data set
        X, f(X), 'b-', ... % the true function
        X, ME, 'r-', ... % the mean of the predictions
        X, ME + 2*sqrt(VA), 'r--', ... % +- 2*sqrt(variance)
        X, ME - 2*sqrt(VA), 'r--', ...
        X, Y(:, end), 'g-'); % the last learned function

    % compute mean squared bias, variance, and error
    BIAS2(WI) = mean(squared_bias_per_point(Y, f(X)));
    VARIANCE(WI) = mean(VA);
    ERR(WI) = mean(squared_error_per_point(Y, f(X)));
    title(sprintf('width = %f\n bias^2 = %f, var = %f', ...
        W, BIAS2(WI), VARIANCE(WI)));
    drawnow
end

% plot squared bias, variance, and error
figure(2)
semilogx(WIDTHS, BIAS2, WIDTHS, VARIANCE, WIDTHS, ERR)
legend('bias^2', 'variance', 'error')

% Generate data
function [X, Y] = generate_data(N)
X = sort(rand(N, 1) * 8 - 4);
Y = f(X) + 0.5 * randn(N, 1);

% the true function (sinc function + linear offset)
function Y = f(X)
Y = sin(4*X)./(4*X) + X/2;

% Compute kernel regression estimates
function YE = kernel_regression(W, X, Y, XE)
K = rbfkern(W, X, XE);

```

```

YE = Y'*K ./ sum(K);

% Compute a Gaussian kernel
function K = rbfkern(W, X1, X2)
D = pdist(X1, X2);
K = exp(-D / W);

% Compute all pairwise distances
function D = pdist(X, Y)
D = size(X, 2);
N = size(X, 1);
M = size(Y, 1);

XX = sum(X.*X, 2);
YY = sum(Y.*Y, 2);
D = repmat(XX, 1, M) + repmat(YY', N, 1) - 2*X*Y';

%%%%%%%%%%%%%%%
% Your solutions below

% 1. Compute the variance per point
%
% Arguments:
%   Y: matrix where the columns are the predictions for a single
%       version of the data set
function V = variance_per_point(Y)
% ...

% 2. Compute the squared bias per point
%
% Arguments:
%   Y: see 1
%   F: a column vector of the true function
function B2 = squared_bias_per_point(Y, F)
% ...

% 3. Compute the squared error per point.
%
% Arguments:
%   Y: see 1
%   F: see 2
function E = squared_error_per_point(Y, F)
% ...

```

Für Fragen zum Übungsblatte bitte in der Google Group <http://groups.google.com/group/ml-tu> registrieren und die Frage an die Mailingliste stellen.