

SPRAWOZDANIE

SIEĆ KOHONENA – ALGORYTM WTA



Przedmiot: *Podstawy sztucznej inteligencji*

Autor: *Dávid Ali*

Kontakt: s26567@st.pans.nysa.pl

Data: 26. 01. 2024 r.

Spis treści

Spis treści	1
Cel	2
Realizacja.....	3
Spis plików.....	15

Cel

Celem niniejszego projektu jest implementacja algorytmu uczenia sieci neuronowej z wykorzystaniem Sieci Kohonena z algorytmem uczenia WTA (Winner-Takes-All). Projekt skupia się na dwóch różnych zestawach danych: własnych danych związanych z systemami ekspertowymi (SE1 i SE2) oraz znanymi danymi dotyczącymi irysów/klasy wina. Implementacja ma obejmować proces uczenia na obu zbiorach danych, a także ocenę poprawności generowanych grup/kategorii przez sieć na danych testowych.

Wykorzystane technologie

W projekcie wykorzystano język programowania C++ oraz środowisko Visual Studio Community Edition 2022 do implementacji algorytmu uczenia sieci neuronowej. Wybór tego środowiska umożliwia efektywne debugowanie, organizację kodu oraz zapewnia wygodne narzędzia do rozwijania projektu.

Zagadnienia wstępne

Sieć Kohonena

Sieć Kohonena to rodzaj sztucznej sieci neuronowej, której głównym zadaniem jest przekształcanie wejściowych danych wielowymiarowych do niższowymiarowej przestrzeni, co pozwala na uzyskanie struktury danych i ich grupowanie. Sieci tego typu są często wykorzystywane do analizy danych, redukcji wymiarów oraz klasyfikacji. Sieć Kohonena składa się z warstwy wejściowej i warstwy neuronów zwanej mapą Kohonena. Każdy neuron w mapie reprezentuje pewną grupę lub kategorię danych. Podczas procesu uczenia, neurony konkurują ze sobą o to, który z nich najlepiej odpowiada na aktualne dane wejściowe. Zwycięzca, czyli neuron z najbliższym wzorcem, zostaje dostosowany, co umożliwia adaptację sieci do struktury danych.

Algorytm WTA

Istnieje kilka algorytmów uczenia sieci Kohonena, a jednym z nich jest algorytm WTA (Winner-Takes-All). Algorytm ten polega na tym, że tylko jeden neuron staje się zwycięzcą i jest aktualizowany podczas każdej iteracji uczenia. Proces ten prowadzi do powstawania jednej dominującej grupy w wynikowej mapie. Podczas uczenia sieci, dla każdego wektora danych wejściowych, obliczane jest odległość pomiędzy wektorem a wagami każdego neuronu. Następnie neuron, którego wagi są najbliższe wektorowi wejściowemu, zostaje uznany za zwycięzcę. Wagi zwycięskiego neuronu (oraz w przypadku innych algorytmów uczenia [np. WTM] wag sąsiednich neuronów) są następnie aktualizowane w kierunku wektora wejściowego. Algorytm uczenia WTA ma za zadanie osiągnąć konwergencję, gdzie neurony mapy Kohonena reprezentują różne grupy danych. Proces ten powtarzany jest dla każdego wektora uczącego, aż do uzyskania zadowalającej jakości klasyfikacji.

W dalszej części sprawozdania zostaną przedstawione szczegóły implementacji algorytmu sieci Kohonena z wykorzystaniem algorytmu uczenia WTA w języku C++ z użyciem środowiska Visual Studio Community Edition 2022.

Realizacja

```
#include <cmath>
#include <stdio>
#include <stdlib>
#include <ctime>
#include <cfloat>
#include <windows.h>
#pragma warning(disable : 4996)
#pragma warning(disable : 6031)
#pragma warning(disable : 4244)

// #define __VERBOSE
#define SALT_WHILE_TRAINING
#define SALT_WHILE_TRAINING_CHANCE 0.01
#define SALT_WHILE_TRAINING_MAX_CHANGE 0.005
// #define SALT_WHILE_TESTING
#define SALT_WHILE_TESTING_CHANCE 1
#define SALT_WHILE_TESTING_MAX_CHANGE 0.0001
// #define TRAIN_EVEN_THEN_TEST_ODD

#define USE_SIMPLIFIED_WTM_ALGORITHM_IN_FIRST_N_EPOCHS 3
void fprintVector(FILE* fp, double* v, size_t n) {
    fprintf(fp, "{");
    for (size_t i = 0; i < n; i++) fprintf(fp, "%4.0lf", v[i] * 100);
    fprintf(fp, " }");
}

void sprintVector(char* buffer, double* v, size_t n) {
    sprintf(buffer, "{");
    for (size_t i = 0; i < n; i++) sprintf(buffer + strlen(buffer), "%4.0lf",
v[i] * 100);
    sprintf(buffer + strlen(buffer), " }");
}

void fprintWeights(FILE* fp, double** weights, size_t h, size_t w, size_t
epoch) {
    fprintf(fp, "WEIGHTS AFTER %Id EPOCHS:\n", epoch);

    for (size_t y = 0; y < h; y++) {
        fprintf(fp, "Neuron %*Iu: ", -(((int)log10(h) + 1), y);
        fprintVector(fp, weights[y], w);
        fprintf(fp, "\n");
    }
}

#ifdef __VERBOSE
void fprintWeights2(FILE* fp, double** weights, size_t h, size_t w, size_t
trainIndex, double learningRate, size_t epochIndex) {
    fprintf(fp, "Epoch index: %5Id | Train index: %5Id | Learning rate: %lf
\n", epochIndex, trainIndex, learningRate);

    for (size_t y = 0; y < h; y++) {
        fprintf(fp, "Neuron %*Iu: ", -(((int)log10(h) + 1), y);
        fprintVector(fp, weights[y], w);
        fprintf(fp, "\n");
    }
}
```

```
#endif
void fprintfInfo(FILE* fp, unsigned int seed, char* inFileName, size_t
inputNum, size_t inputSize, size_t outputSize, size_t numEpochs, double
learningRate) {
    fprintf(fp, "    Random seed: 0x%08x\n", seed);
    fprintf(fp, "  Number of inputs: %Id\n", inputNum);
    fprintf(fp, "    Size of inputs: %Id\n", inputSize);
    fprintf(fp, "Number of neurons: %Id\n", outputSize);
    fprintf(fp, "  Number of epochs: %Id\n", numEpochs);
    fprintf(fp, "    Learning rate: %lf\n", learningRate);
}
void normalizeColumns(double** m, size_t h, size_t w) {
    for (size_t x = 0; x < w; x++) {
        double min = m[0][x];
        double max = m[0][x];
        for (size_t y = 1; y < h; y++) {
            if (min > m[y][x]) min = m[y][x];
            if (max < m[y][x]) max = m[y][x];
        }
        for (size_t y = 0; y < h; y++) {
            m[y][x] = (m[y][x] - min) / (max - min);
        }
    }
}
void normalizeRow(double* v, size_t w) {
    double sum = 0;
    for (size_t x = 0; x < w; x++) {
        sum += v[x] * v[x];
    }
    double sq = sqrt(sum);
    for (size_t x = 0; x < w; x++) {
        v[x] /= sq;
    }
}
void normalizeRows(double** m, size_t h, size_t w) {
    for (size_t y = 0; y < h; y++) {
        normalizeRow(m[y], w);
    }
}
double distance(double* v1, double* v2, size_t w) {
    double sum = 0;
    for (size_t x = 0; x < w; x++) {
        sum += pow(v1[x] - v2[x], 2);
    }
    return sqrt(sum);
}
inline size_t randomI(size_t upperExclusiveLimit) {
    return rand() % upperExclusiveLimit;
}
inline double randomD() {
    return (double)rand() / RAND_MAX;
}
inline double randomDaround0(double plusMinus) {
```

```
    return ((double)rand() / RAND_MAX - 0.5) * 2 * plusMinus;
}

void initWeights(double*** weights, size_t h, size_t w) {
    *weights = (double**)malloc(h * sizeof(double*));
    if (*weights == nullptr) exit(1);
    for (size_t y = 0; y < h; y++) {
        (*weights)[y] = (double*)malloc(w * sizeof(double));
        if ((*weights)[y] == nullptr) exit(1);
        for (size_t x = 0; x < w; x++) {
            (*weights)[y][x] = randomD();
        }
    }
    normalizeRows(*weights, h, w);
}

void initWeights2(double*** weights, double** inputs, size_t inputNum,
size_t inputSize, size_t outputSize) {
    *weights = (double**)malloc(outputSize * sizeof(double*));
    if (*weights == nullptr) exit(1);
    for (size_t y = 0; y < outputSize; y++) {
        (*weights)[y] = (double*)malloc(inputSize * sizeof(double));
        if ((*weights)[y] == nullptr) exit(1);
        for (size_t x = 0; x < inputSize; x++) {
            (*weights)[y][x] = inputs[randomI(inputNum)][x];
        }
    }
    normalizeRows(*weights, outputSize, inputSize);
}

void freeDoubleMatrix(double** m, size_t h) {
    for (size_t y = 0; y < h; y++) {
        free(m[y]);
    }
    free(m);
}

void freeCharMatrix(char** m, size_t h) {
    for (size_t y = 0; y < h; y++) {
        free(m[y]);
    }
    free(m);
}

size_t findWinner(double** weights, double* in, size_t h, size_t w) {
    size_t winnerIndex = 0;
    double minDistance = DBL_MAX;
    for (size_t y = 0; y < h; y++) {
        double dist = distance(weights[y], in, w);
        if (dist < minDistance) {
            minDistance = dist;
            winnerIndex = y;
        }
    }
    return winnerIndex;
}
```

```
void moveTowardsB(double* A, double* B, double rate, size_t w, size_t
winnerIndex = 0) {
    for (size_t x = 0; x < w; x++) {
        A[x] += rate * (B[x] - A[x]);
    }
}

void salt(double* in, double** copyWithSalt, size_t size, double chance =
0, double maxChange = 0) {
    (*copyWithSalt) = (double*)malloc(size * sizeof(double));
    if ((*copyWithSalt) == nullptr) exit(0);
    memcpy((*copyWithSalt), in, size * sizeof(double));
    for (size_t i = 0; i < size; i++) {
        if (randomD() >= chance) continue;
        (*copyWithSalt)[i] += randomDaround0(maxChange);
        if ((*copyWithSalt)[i] < 0) (*copyWithSalt)[i] = 0;
        if ((*copyWithSalt)[i] > 1) (*copyWithSalt)[i] = 1;
    }
}

void train(double** weights, double* in, double rate, size_t h, size_t w,
int useSimplifiedWTMAlgorytm = 0) {
#ifdef SALT_WHILE_TRAINING
    double* inp;
    salt(in, &inp, w, SALT_WHILE_TRAINING_CHANCE,
SALT_WHILE_TRAINING_MAX_CHANGE);
    size_t winnerIndex = findWinner(weights, inp, h, w);
    moveTowardsB(weights[winnerIndex], inp, rate, w);
    free(inp);
#else
    size_t winnerIndex = findWinner(weights, in, h, w);
    moveTowardsB(weights[winnerIndex], in, rate, w);
#endif
    normalizeRow(weights[winnerIndex], w);
    if (useSimplifiedWTMAlgorytm) {
        double* lowerNeighbor = weights[(winnerIndex + h - 1) % h];
        double* lowerlowerNeighbor = weights[(winnerIndex + h - 2) % h];
        double* upperNeighbor = weights[(winnerIndex + 1) % h];
        double* upperupperNeighbor = weights[(winnerIndex + 2) % h];

        moveTowardsB(lowerNeighbor, weights[winnerIndex], rate / 2, w);
        normalizeRow(lowerNeighbor, w);
        moveTowardsB(upperNeighbor, weights[winnerIndex], rate / 2, w);
        normalizeRow(upperNeighbor, w);
        moveTowardsB(lowerlowerNeighbor, lowerNeighbor, rate / 5, w);
        normalizeRow(lowerlowerNeighbor, w);
        moveTowardsB(upperupperNeighbor, upperNeighbor, rate / 5, w);
        normalizeRow(upperupperNeighbor, w);
    }
}

void initInputs(const char* inFileName, double*** inputs, size_t*
inputNum, size_t* inputSize, size_t* outputSize, size_t* numEpochs,
double* learningRate) {
    FILE* fp = fopen(inFileName, "r");
    if (fp == nullptr) {
        fprintf(stderr, "Error opening file \"%s\". Exiting.", inFileName);
    }
}
```

```
    exit(1);
}
fscanf(fp, "%Id", inputNum);
fscanf(fp, "%Id", inputSize);
fscanf(fp, "%Id", outputSize);
fscanf(fp, "%Id", numEpochs);
fscanf(fp, "%lf", learningRate);

*inputs = (double**)malloc(*inputNum * sizeof(double));
if (*inputs == nullptr) exit(1);

for (size_t y = 0; y < *inputNum; y++) {
    (*inputs)[y] = (double*)malloc(*inputSize * sizeof(double));
    if ((*inputs)[y] == nullptr) exit(1);
    for (size_t x = 0; x < *inputSize; x++) {
        fscanf(fp, "%lf", &((*inputs)[y][x]));
    }
}
fclose(fp);
}

#ifdef __VERBOSE
void gotoXY(size_t x, size_t y) {
    COORD destCoord;
    destCoord.X = x;
    destCoord.Y = y;
    SetConsoleCursorPosition(GetStdHandle(STD_OUTPUT_HANDLE), destCoord);
}
void rememberXY(SHORT* x, SHORT* y) {
    CONSOLE_SCREEN_BUFFER_INFO info;
    GetConsoleScreenBufferInfo(GetStdHandle(STD_OUTPUT_HANDLE), &info);
    *x = info.dwCursorPosition.X;
    *y = info.dwCursorPosition.Y;
}
void clearConsoleRow() {
    SHORT cursorX;
    SHORT cursorY;
    rememberXY(&cursorX, &cursorY);
    printf("
");
    gotoXY(cursorX, cursorY);
}
#endif

void test(char*** output, double** weights, double** inputs, size_t
inputNum, size_t inputSize, size_t outputSize) {
    (*output) = (char**)malloc(outputSize * sizeof(char));
    if ((*output) == nullptr) exit(1);
    size_t neuronNumberWidth = (size_t)(log10(outputSize)) + 1;
    size_t numberWidth = (size_t)(log10(inputNum)) + 2;
    for (size_t i = 0; i < outputSize; i++) {
        (*output)[i] = (char*)malloc((10 + neuronNumberWidth + inputNum *
numberWidth) * sizeof(char));
        if ((*output)[i] == nullptr) exit(1);
        sprintf((*output)[i], "Neuron %*Id: ", -(int)neuronNumberWidth, i);
    }
}

#ifdef TRAIN_EVEN_THEN_TEST_ODD
for (int testIndex = 1; testIndex < inputNum; testIndex += 2) {
```



```
#else
    for (int testIndex = 0; testIndex < inputNum; testIndex += 1) {
    #endif
    #ifdef SALT_WHILE_TESTING
        double* inp;
        salt(inputs[testIndex], &inp, inputSize, SALT_WHILE_TESTING_CHANCE,
        SALT_WHILE_TESTING_MAX_CHANGE);
        size_t winner = findWinner(weights, inp, outputSize, inputSize);
        free(inp);
    #else
        size_t winner = findWinner(weights, inputs[testIndex], outputSize,
        inputSize);
    #endif
        sprintf((*output)[winner] + strlen((*output)[winner]), "%d",
        (int)numberWidth, testIndex);
    }
}

void doEpoch(double** weights, double** inputs, double rate, size_t
inputNum, size_t outputSize, size_t inputSize, size_t epochIndex, size_t
epochNum) {
    size_t* indices = (size_t*)malloc(inputNum * sizeof(size_t));
    if (indices == nullptr) exit(1);
    for (size_t i = 0; i < inputNum; i++) {
        indices[i] = i;
    }
    size_t temp, randomIndex;
    for (size_t i = 0; i < inputNum; i++) {
        randomIndex = (size_t)randomI(inputNum);
        temp = indices[i];
        indices[i] = indices[randomIndex];
        indices[randomIndex] = temp;
    }

    for (int trainIndex = 0; trainIndex < inputNum; trainIndex++) {
    #ifdef TRAIN_EVEN_THEN_TEST_ODD
        if (indices[trainIndex] % 2 == 0) continue;
    #endif

        double learningRate = rate * (1.0 - ((double)trainIndex / inputNum));
        train(weights, inputs[indices[trainIndex]], learningRate, outputSize,
        inputSize, epochIndex < USE_SIMPLIFIED_WTM_ALGORYTHM_IN_FIRST_N_EPOCHS);

    #ifdef __VERBOSE
        SHORT cursorX;
        SHORT cursorY;
        rememberXY(&cursorX, &cursorY);
        fprintfWeights2(stdout, weights, outputSize, inputSize, trainIndex,
        learningRate, epochIndex);
        gotoXY(cursorX, cursorY);
    #endif
    }
    free(indices);
}

int main(int argc, char* argv[]) {
    unsigned int seed;
    double** inputs;
```

```
size_t inputNum;
size_t inputSize;
size_t outputSize;
size_t numEpochs;
double learningRate;
double** weights;
char** output;
char inFileName[128];
char outFileName[128];

seed = 0x416C6944;
//seed = time(0);
srand(seed);
if (argc > 1) {
    sprintf(inFileName, "%s.in", argv[1]);
    sprintf(outFileName, "%s.out", argv[1]);
}
else {
    char buf[100];
    printf("Podaj nazwe pliku wejsciowego (bez rozszerzenia, nie moze  
zawierac spacji i znakow specjalnych, nie moze byc dluzsza niz 100  
znakow): \n");
    printf("Nazwa pliku: "); scanf("%s", buf);
    sprintf(inFileName, "%s.in", buf);
    sprintf(outFileName, "%s.out", buf);
}
initInputs(inFileName, &inputs, &inputNum, &inputSize, &outputSize,
&numEpochs, &learningRate);
normalizeColumns(inputs, inputNum, inputSize);
normalizeRows(inputs, inputNum, inputSize);
initWeights2(&weights, inputs, inputNum, inputSize, outputSize);

FILE* fp = fopen(outFileName, "w");
if (fp == nullptr) exit(1);
fprintfInfo(stdout, seed, inFileName, inputNum, inputSize, outputSize,
numEpochs, learningRate);
fprintfInfo(fp, seed, inFileName, inputNum, inputSize, outputSize,
numEpochs, learningRate);

for (int epoch = 0; epoch < numEpochs; epoch++) {
    doEpoch(weights, inputs, learningRate, inputNum, outputSize, inputSize,
epoch, numEpochs);
}

#ifdef __VERBOSE
clearConsoleRow();
#endif
fprintfWeights(stdout, weights, outputSize, inputSize, numEpochs);
fprintfWeights(fp, weights, outputSize, inputSize, numEpochs);
test(&output, weights, inputs, inputNum, inputSize, outputSize);

fprintf(stdout, "TEST RESULTS:\n");
fprintf(fp, "TEST RESULTS:\n");

for (size_t i = 0; i < outputSize; i++) {
    fprintf(stdout, "%s\n", output[i]);
}
```

```
    fprintf(fp, "%s\n", output[i]);  
}  
fclose(fp);  
  
freeCharMatrix(output, outputSize);  
freeDoubleMatrix(weights, outputSize);  
freeDoubleMatrix(inputs, inputNum);  
  
}
```

Powyższy kod implementuje prostą wersję algorytmu map samoorganizujących Kohonena. SOM to algorytm uczenia nienadzorowanego używany do grupowania i wizualizacji danych o wysokiej wymiarowości. Poniżej przedstawiam kilka kluczowych punktów dotyczących tego kodu:

Kluczowe punkty kodu

Nagłówki

Kod zawiera różne standardowe nagłówki C++ (<cmath>, <cstdio>, <cstdlib>, <ctime>, <float>) oraz nagłówek specyficzny dla systemu Windows - <windows.h>, używany do funkcji związanych z konsolą.

Dyrektywy preprocesora i definicje

Istnieje wiele dyrektyw preprocesora (#define), które kontrolują zachowanie kodu, takie jak drukowanie szczegółów, opcje dodawania „soli” (szumu) podczas treningu i testowania oraz używanie uproszczonego algorytmu w pierwszych epokach.

Definicje funkcji

Zdefiniowano kilka funkcji, w tym funkcje do drukowania wektorów i wag, normalizacji macierzy, obliczania odległości, inicjalizacji wag oraz główne funkcje uczenia i testowania.

Algorytm uczący

Funkcja ucząca (train) aktualizuje wagi neuronów na podstawie danych wejściowych i neuronu-zwycięzcy (tego, którego wektor wag jest najbliższy wektorowi wejściowemu).

Generowanie liczb losowych

Funkcje generujące liczby losowe (randomI i randomD) są używane do inicjalizacji wag oraz wprowadzania szumu podczas treningu i testowania.

Obsługa pliku wejściowego

Kod czyta parametry wejściowe i dane z pliku, który jest określony jako argument wiersza poleceń lub wprowadzany przez użytkownika podczas działania programu.

Testowanie

Funkcja test ocenia wytrenowany SOM na danych wejściowych i generuje ciągi wyjściowe wskazujące, które wejścia są skojarzone z każdym neuronem.

Pętla Epok

Główna funkcja zawiera pętlę, która przechodzi przez epoki, wywołując funkcję uczącą (doEpoch) w każdej iteracji.

Wyjście

Ostateczne wagi i wyniki testów są drukowane na konsolę i zapisywane do pliku wyjściowego.

Interakcja z konsolą (opcjonalna)

Istnieją fragmenty kodu związane z interakcją z konsolą, takie jak pozycjonowanie kursora i czyszczenie wierszy konsoli. Są one używane do drukowania szczegółów i celów debugowania.

Zarządzanie pamięcią

Pamięć jest dynamicznie alokowana dla różnych macierzy i tablic, a na końcu programu zarezerwowana pamięć się zwalnia.

Algorytm

W tym konkretnym kodzie, używana jest jedna z podstawowych form algorytmu SOM, znana jako algorytm Winner-Takes-All (WTA). Oto ogólne kroki działania tego algorytmu:

Inicjalizacja wag

Na początku programu wagi neuronów są inicjalizowane losowo.

Normalizacja danych wejściowych

Dane wejściowe (wektory) są zazwyczaj normalizowane, aby uniezależnić algorytm od skali wartości.

Trening

Algorytm przechodzi przez kilka epok treningowych. W każdej epoce, dla każdego przykładu treningowego:

- Obliczana jest odległość między wektorem wejściowym a wagami wszystkich neuronów.
- Wybierany jest neuron-zwycięzca (ten, którego waga jest najbliższa wektorowi wejściowemu).
- Wagi tego zwycięzcy¹ są aktualizowane w kierunku wektora wejściowego.

Normalizacja wag

Po aktualizacji wag w każdej iteracji treningowej, wagi neuronów są normalizowane, aby zachować ich jednostkową długość (normalizacja wektorów wag).

Testowanie

Po zakończeniu treningu można przeprowadzić testowanie, gdzie dla każdego wektora testowego obliczany jest neuron-zwycięzca, czyli ten, którego waga jest najbliższa wektorowi testowemu.

Zmęczenie neuronów

Aby zapobiec zmęczeniu neuronów istnieje opcja zastosowania uproszczonej wersji algorytmu WTM w pierwszych kilku epokach. Używając tej opcji można było zaobserwować większej skuteczności, dzięki temu że więcej neuronów się aktywuje.

Drugi pomysł na zapobieganie zmęczenia neuronów to dodawanie niewielkiego szumu do danych wejściowych podczas uczenia (i/lub testowania) sieci.

¹ W algorytmie Winner-Takes-All (WTA) wagi neuronów są aktualizowane tylko dla zwycięzcy, co oznacza, że tylko najbliższy neuron ma zmienione wagi w danym kroku treningowym. Kod zawiera także pewne modyfikację: uproszczony algorytm WTM (Winner-Takes-Most) polega na tym, że nie tylko zwycięzca zostaje „przyciągany” do wektora uczącego ale także neurony sąsiadujące w mniejszym stopniu.

Tryb __VERBOSE

Jeśli usuniemy „//” przed linii #define __VERBOSE, oznacza to, że ta dyrektywa preprocesora stanie się aktywna, co skutkuje włączeniem trybu szczegółowego w kodzie. Tryb ten służy do wypisywania dodatkowych informacji diagnostycznych na standardowe wyjście (konsolę). Wykorzystanie tego trybu jest związane z funkcjami fprintWeights2 i związanymi z nimi fragmentami kodu.

W tym trybie pojawiają się dodatkowe informacje diagnostyczne podczas treningu. W tych dodatkowych informacjach znajdują się szczegóły dotyczące wag neuronów, aktualnych epok treningowych, indeksów próbek treningowych oraz współczynnika uczenia.

Uwaga, ten tryb jest bardzo wolny w stosunku do trybu normalnego (poprzez wyświetlanie informacji).

Plik wejściowy

Struktura pliku wejściowego dla tego programu jest opisana w kodzie. Poniżej przedstawiam przykład, jak może wyglądać plik wejściowy:

4	3	2	1	0.1
0.2	0.4	0.6		
0.8	0.1	0.3		
0.5	0.7	0.9		
0.2	0.5	0.7		

Gdzie:

- Pierwsza liczba (4) oznacza liczbę wektorów wejściowych.
- Druga liczba (3) to rozmiar wektora wejściowego.
- Trzecia liczba (2) to liczba neuronów.
- Czwarta liczba (1) to liczba epok treningu.
- Piąta liczba (0.1) to (początkowy) współczynnik uczenia.

Przykłady działania

Ryby

```
Microsoft Visual Studio Debug Console
Podaj nazwę pliku wejściowego (bez rozszerzenia, nie może zawierać spacji i znaków specjalnych, nie może być dłuższa niż 100 znaków):
Nazwa pliku: ryby
Random seed: 0x416c6944
Number of inputs: 512
Size of inputs: 21
Number of neurons: 19
Number of epochs: 5
Learning rate: 0.300000
WEIGHTS AFTER 5 EPOCHS:
Neuron 0 : { 23 36 37 42 20 5 20 18 16 10 13 10 13 17 14 9 41 10 18 19 5 }
Neuron 1 : { 36 36 36 36 18 0 0 33 11 14 14 10 14 15 18 8 34 1 21 15 0 }
Neuron 2 : { 39 0 0 39 20 0 0 15 9 14 4 14 13 9 2 30 37 1 37 20 39 }
Neuron 3 : { 36 0 0 36 36 0 0 11 13 11 28 29 3 34 18 3 34 1 34 17 0 }
Neuron 4 : { 45 0 0 0 23 0 0 14 12 9 6 39 8 42 25 11 43 1 27 18 0 }
Neuron 5 : { 44 0 0 0 0 44 0 19 8 17 7 8 5 38 26 11 41 25 6 25 0 }
Neuron 6 : { 39 0 0 0 20 0 0 17 14 15 3 32 2 35 18 8 38 35 31 32 0 }
Neuron 7 : { 44 0 0 0 22 0 0 18 19 8 13 41 5 39 2 36 42 3 12 16 0 }
Neuron 8 : { 0 48 0 0 24 0 0 36 10 19 10 16 30 11 7 41 41 8 20 2 0 }
Neuron 9 : { 11 46 9 26 27 1 0 24 10 22 13 16 27 17 7 34 33 7 23 10 27 }
Neuron 10 : { 0 48 0 48 24 0 0 0 3 30 8 2 29 4 4 21 4 4 18 2 48 }
Neuron 11 : { 0 36 36 36 18 0 0 35 5 9 15 5 9 16 5 25 29 3 29 18 36 }
Neuron 12 : { 35 35 35 35 17 0 0 10 7 9 23 5 22 17 5 27 30 3 12 15 35 }
Neuron 13 : { 33 33 33 33 16 0 0 16 7 9 20 14 13 24 13 9 31 5 29 24 33 }
Neuron 14 : { 33 33 33 0 16 0 0 10 12 10 25 30 5 28 19 9 31 5 21 28 33 }
Neuron 15 : { 0 0 45 0 0 45 30 9 7 20 9 9 19 11 7 35 37 1 29 20 0 }
Neuron 16 : { 5 29 45 25 5 36 28 14 8 14 17 9 14 18 9 19 40 4 23 19 5 }
Neuron 17 : { 0 40 40 40 0 40 27 18 3 11 18 2 10 18 4 7 35 1 13 14 0 }
Neuron 18 : { 0 40 40 40 20 0 40 0 21 2 9 6 10 12 14 1 38 20 4 18 0 }
TEST RESULTS:
Neuron 0 :
Neuron 1 : 416 417 418 419 420 421 422 423 424 425 426 427 428 429 430 431 432 433 434 435 436 437 438 439 440 441 442 443 444 445 446 447
Neuron 2 : 256 257 258 259 260 261 262 263 264 265 266 267 268 269 270 271 272 273 274 275 276 277 278 279 280 281 282 283 284 285 286 287
Neuron 3 : 480 481 482 483 484 485 486 487 488 489 490 491 492 493 494 495 496 497 498 499 500 501 502 503 504 505 506 507 508 509 510 511
Neuron 4 : 288 289 290 291 292 293 294 295 296 297 298 299 300 301 302 303 304 305 306 307 308 309 310 311 312 313 314 315 316 317 318 319
Neuron 5 : 192 193 194 195 196 197 198 199 200 201 202 203 204 205 206 207 208 209 210 211 212 213 214 215 216 217 218 219 220 221 222 223
Neuron 6 : 64 65 66 67 68 69 70 71 72 73 74 75 76 77 78 79 80 81 82 83 84 85 86 87 88 89 90 91 92 93 94 95
Neuron 7 : 160 161 162 163 164 165 166 167 168 169 170 171 172 173 174 175 176 177 178 179 180 181 182 183 184 185 186 187 188 189 190 191
Neuron 8 : 224 225 226 227 228 229 230 231 232 233 234 235 236 237 238 239 240 241 242 243 244 245 246 247 248 249 250 251 252 253 254 255
Neuron 9 :
Neuron 10 : 32 33 34 35 36 37 38 39 40 41 42 43 44 45 46 47 48 49 50 51 52 53 54 55 56 57 58 59 60 61 62 63
Neuron 11 : 320 321 322 323 324 325 326 327 328 329 330 331 332 333 334 335 336 337 338 339 340 341 342 343 344 345 346 347 348 349 350 351
Neuron 12 : 96 97 98 99 100 101 102 103 104 105 106 107 108 109 110 111 112 113 114 115 116 117 118 119 120 121 122 123 124 125 126 127
Neuron 13 : 352 353 354 355 356 357 358 359 360 361 362 363 364 365 366 367 368 369 370 371 372 373 374 375 376 377 378 379 380 381 382 383
Neuron 14 : 448 449 450 451 452 453 454 455 456 457 458 459 460 461 462 463 464 465 466 467 468 469 470 471 472 473 474 475 476 477 478 479
Neuron 15 : 128 129 130 131 132 133 134 135 136 137 138 139 140 141 142 143 144 145 146 147 148 149 150 151 152 153 154 155 156 157 158 159
Neuron 16 :
Neuron 17 : 0 1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 21 22 23 24 25 26 27 28 29 30 31
Neuron 18 : 384 385 386 387 388 389 390 391 392 393 394 395 396 397 398 399 400 401 402 403 404 405 406 407 408 409 410 411 412 413 414 415
C:\Users\alida\source\repos\SOM\x64\Debug\SOM.exe (process 7840) exited with code 0.
To automatically close the console when debugging stops, enable Tools->Options->Debugging->Automatically close the console when debugging stops.
Press any key to close this window . . .
```

Plik ryby.in zawiera dane związane z 512 osobników 16 różnych gatunków ryb (każdy gatunek po 32 osobników). Każdy osobnik jest opisane 21 atrybutami. Zostaje tworzony 19 neuronów, proces uczenia trwa 5 epoki z początkującymi współczynnikami uczenia o wartości 0.3. Dane uczące są posortowane według gatunków.

Podczas działania programu oprócz wyświetlania wyników na konsoli także powstał plik ryby.out.

W tym analizując wyniki widzimy, że każdy neuron (który w ogóle się aktywował podczas testów) się aktywował 32 razy, i sieć 100%-ową skutecznością sklasyfikował każdego osobnika.

Iris

```
Microsoft Visual Studio Debug Console
Podaj nazwę pliku wejściowego (bez rozszerzenia, nie może zawierać spacji i znaków specjalnych, nie może być dłuższa niż 100 znaków):
Nazwa pliku: iris
Random seed: 0x416c6944
Number of inputs: 150
Size of inputs: 4
Number of neurons: 6
Number of epochs: 10
Learning rate: 0.200000
WEIGHTS AFTER 10 EPOCHS:
Neuron 0: { 55 33 58 51 }
Neuron 1: { 42 21 63 61 }
Neuron 2: { 43 37 57 60 }
Neuron 3: { 36 82 25 36 }
Neuron 4: { 32 94 12 8 }
Neuron 5: { 44 71 40 37 }
TEST RESULTS:
Neuron 0: 50 51 52 54 58 62 63 65 67 71 73 74 75 76 77 79 82 86 92 97 102 105 107 117 122 125 129 130 131 133 135
Neuron 1: 53 57 60 68 69 72 80 81 83 87 89 90 93 101 106 108 111 113 114 118 119 121 123 128 132 134 142 146
Neuron 2: 55 56 59 61 64 66 70 78 84 85 88 91 94 95 96 98 99 100 103 104 109 110 112 115 116 120 124 126 127 136 137 138 139 140 141 143 144 145 147 148 149
Neuron 3: 23 41 43
Neuron 4: 0 1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 21 22 24 25 26 27 28 29 30 31 32 33 34 35 36 37 38 39 40 42 44 45 46 47 48 49
Neuron 5: 0 1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 21 22 24 25 26 27 28 29 30 31 32 33 34 35 36 37 38 39 40 42 44 45 46 47 48 49
C:\Users\alida\source\repos\SOM\src\Debug\SOM.exe (process 23440) exited with code 0.
To automatically close the console when debugging stops, enable Tools->Options->Debugging->Automatically close the console when debugging stops.
Press any key to close this window . . .
```

Na iris.in (źródło: https://en.wikipedia.org/wiki/Iris_flower_data_set) – z ustawieniami widocznymi na rzucie ekranu – wyniki są następujące:

	I. setosa [szt]	I. versicolor [szt]	I. virginica [szt]
Neuron 0	-	20	11
Neuron 1	-	13	15
Neuron 2	-	17	24
Neuron 3	3	-	-
Neuron 4	47	-	-
Neuron 5	-	-	-

Czyli w miarę skutecznie udało się rozpoznawać gatunki I. setosa, ale ogólnie sieć ma problemy z rozpoznawaniem gatunków I. versicolor oraz I. virginica. Aby doprowadzić do lepszych wyników trzeba będzie eksperymentować z różnymi ustawieniami.

Opinia

Bardzo ciekawy projekt.

Spis plików

Nazwa pliku	Opis
<i>SOM.cpp</i>	Źródło C++ programu
<i>DAVID ALI - SOM - Sprawozdanie.docx</i>	To sprawozdanie w formacie docx.
<i>DAVID ALI - SOM - Sprawozdanie.pdf</i>	To sprawozdanie w formacie pdf.
<i>iris.in</i>	Dane wejściowe „iris”
<i>iris.out</i>	Dane wyjściowe „iris”
<i>ryby.in</i>	Dane wejściowe „ryby”
<i>ryby.out</i>	Dane wyjściowe „ryby”