

Soft computing



K.N. Toosi
University of
Technology

محاسبات نرم



Hasan Ghasemzadeh
<http://wp.kntu.ac.ir/ghasemzadeh>

Soft Computing

Neural Networks شبکه عصبی



مغز انسان

لوب پیشانی
Frontal Lobe

- Problem solving
- Emotional traits
- Reasoning (judgment)
- Speaking
- Voluntary motor activity

لوب گیجگاهی
Temporal Lobe

- Understanding language
- Behavior
- Memory
- Hearing

ساقه مغز
Brain Stem

- Breathing
- Body temperature
- Digestion
- Alertness/sleep
- Swallowing

لوب آهیانه‌ای
Parietal Lobe

- Knowing right from left
- Sensation
- Reading
- Body orientation

لوب پس سری
Occipital Lobe

- Vision
- Color perception

میخچه
Cerebellum

- Balance
- Coordination and control of voluntary movement
- Fine muscle control

Soft Computing 3

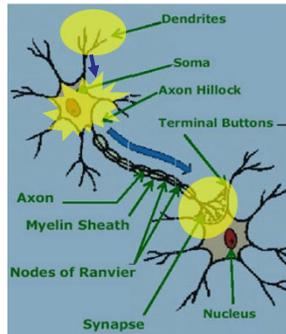
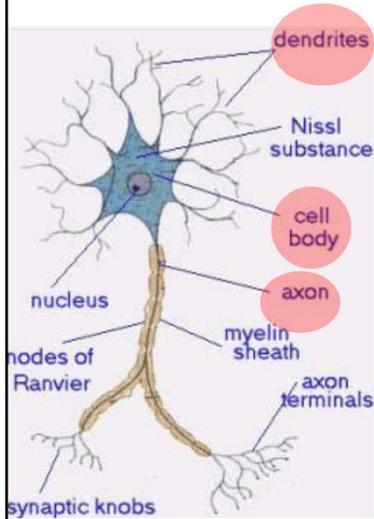
برخی ویژگیهای مغز

- یک توده بافت عصبی (مغز انسان - حدود ۱/۴ کیلوگرم و ۱/۵ لیتر)
- هدایت کل جسم بصورت خودآگاه و ناخودآگاه
- مرکز اندوختن تجربه، یادگیری و تصمیم گیری
- حجم حافظه بالا و سرعت پردازش زیاد
- نامشخص بودن نحوه عملکرد مغز (تاکنون)

Soft Computing 4

برخی ویژگیهای مغز

- مغز شامل ۸۶ میلیارد نورون (۱۹ درصد در قشر حدود ۳ میلیمتری مغز و ۸۰ درصد در مخچه)
- نورون‌ها از یک جسم سلولی، دندریت و آکسون تشکیل شده‌اند.
- نورون اطلاعات را از طریق سیگنال‌های الکتریکی و شیمیایی منتقل می‌کند.
- نورون‌ها انرژی خود را از طریق یک شکاف کوچک به نام سیناپس (بیش از ۱۰۰ تریلیون سیناپس) به یکدیگر منتقل می‌کنند



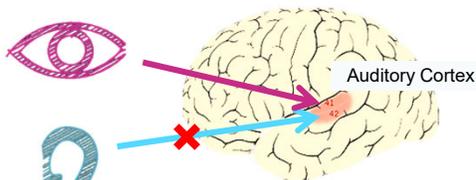
The soma, sums the incoming signals. When sufficient input is received, the cell fires; that is it transmit a signal over its axon to other cells

5

برخی ویژگیهای مغز

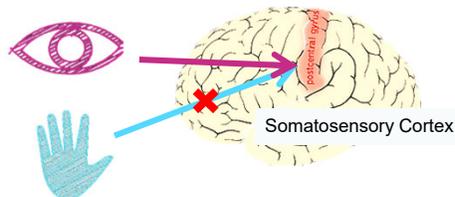
The “one learning algorithm” hypothesis

گرچه هر قسمت مغز وظیفه مخصوص خود را انجام می‌دهد ولی در شرایط خاص محرومیت از برخی سنسورها سعی بر جابجایی وظایف خود میکند



Auditory cortex learns to see

[Roe et al., 1992]



Somatosensory cortex learns to see

[Metin & Frost, 1989]

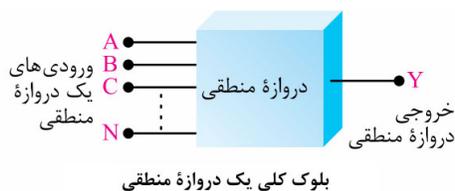
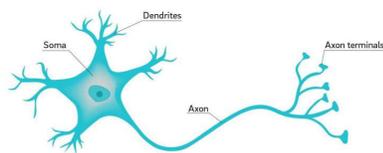
Soft Computing

6

مقایسه مغز انسان و رایانه

Feature	Human (Brain)	Computer
Processing Elements	~86 billion neurons	100 billion in modern chips (like Apple M2).
Interconnects	~10,000 synaptic connections per neuron	a few interconnects per transistor.
Cycles per Second	~200 Hz to 1000 Hz (neuron firing rate)	Up to 5 GHz
Memory	Dynamic and associative (estimated ~2.5 PB)	Explicit, structured (up to terabytes).
2X Improvement	Evolved over millions of years	~1.5-2 years

Neuron

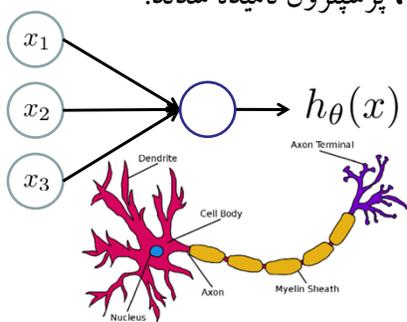


Soft Computing

7

پرسپترون

- شبکه عصبی مصنوعی از رفتار نورنهای مغز تقلید می کند.
- یک واحد منطقی مدلی از یک نورن است. Neuron model: Logistic unit
- شبکه های تک لایه، با توابع فعال سازی آستانه ای، توسط روزنبلات (۱۹۶۲) بنیان گذاری شدند که این نوع شبکه ها، پرسپترون نامیده شدند.



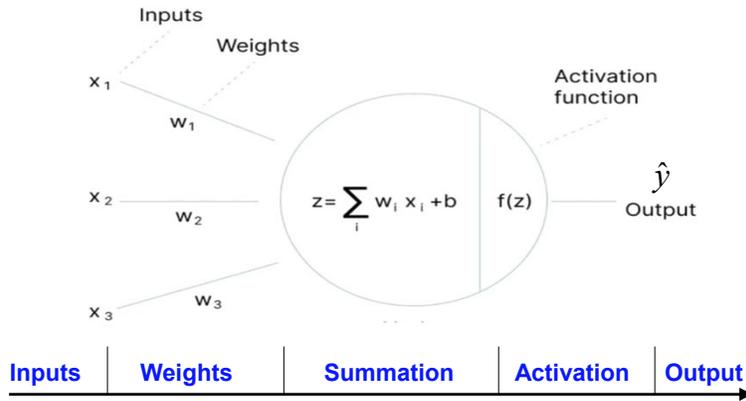
$$x = \begin{Bmatrix} x_0 \\ x_1 \\ x_2 \\ \vdots \\ x_n \end{Bmatrix} \quad w = \begin{Bmatrix} w_0 \\ w_1 \\ w_2 \\ \vdots \\ w_n \end{Bmatrix}$$

Sigmoid (logistic) activation function

Soft Computing

8

مدل ریاضی یک نرون (مک کلاخ-پیتس-۱۹۴۳)

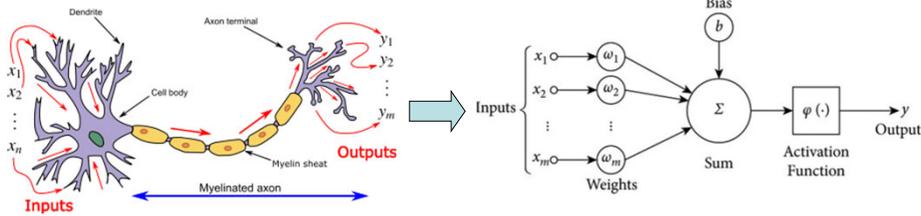


۹

Soft Computing

پرسپترون

- From biological neuron to artificial neuron (perceptron)



$$z = w_0 x_0 + w_1 x_1 + w_2 x_2 + \dots + w_n x_n$$

$$\hat{y} = activation(z) \begin{cases} \text{if } z \geq 0, & \hat{y} = 1 \\ \text{if } z < 0, & \hat{y} = 0 \end{cases}$$

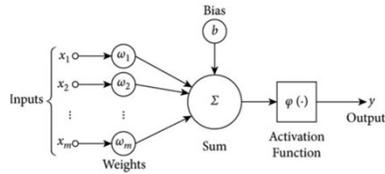
$$Error = \Delta y = y - \hat{y}$$

Soft Computing

10

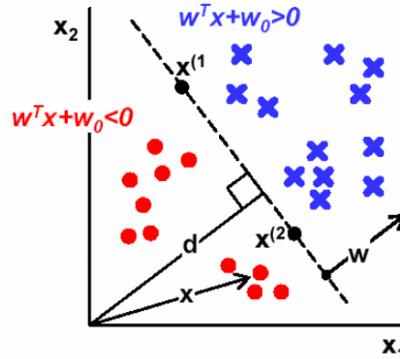
پرسپترون

- Activation function



$$z = w_0x_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n$$

$$\begin{cases} \text{if } z \geq 0, & \hat{y} = 1 \\ \text{if } z < 0, & \hat{y} = 0 \end{cases}$$



$$w_i + \eta \cdot \Delta y \cdot x_i \rightarrow w_i$$

- x_i Input feature value
- w_i Activation function
- Δy Error
- η Learning rate

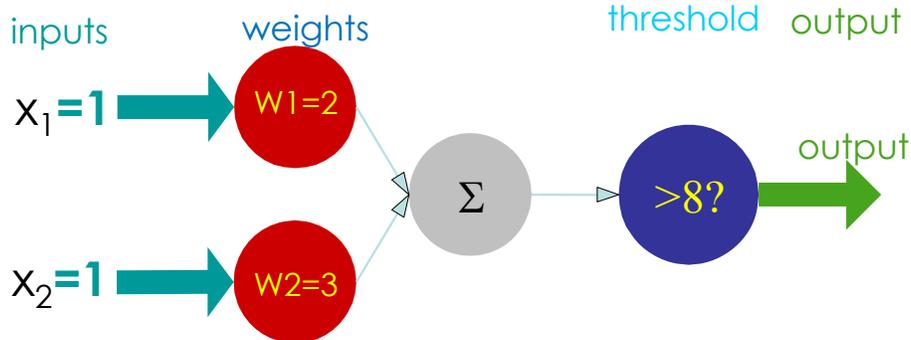
Soft Computing

11

مثال پرسپترون: Logical AND

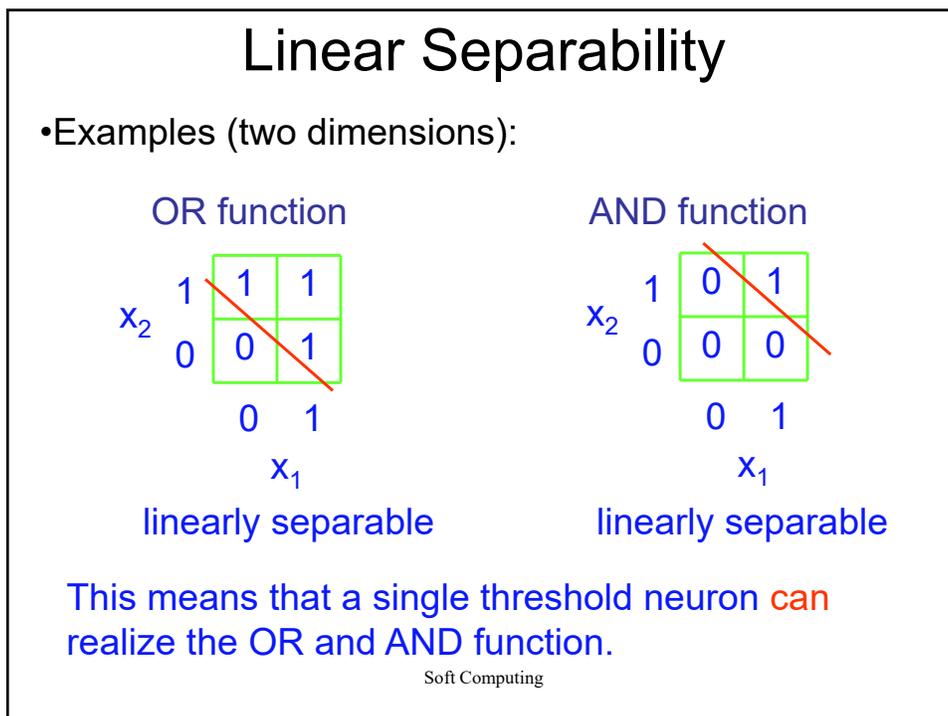
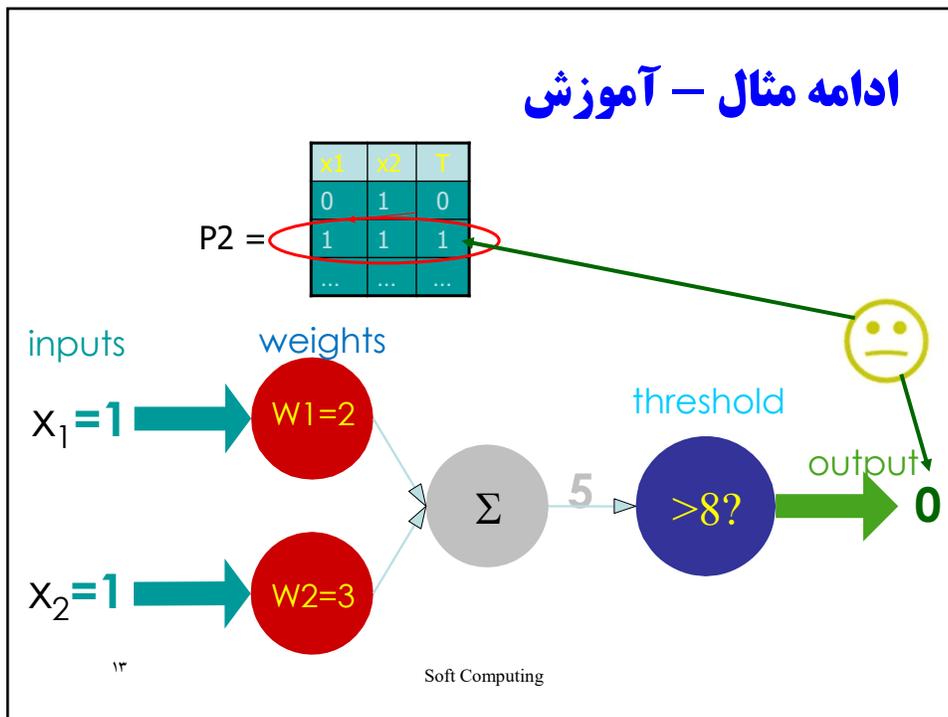
	x1	x2	T
P1 =	0	1	0
P2 =	1	1	1
Pn =

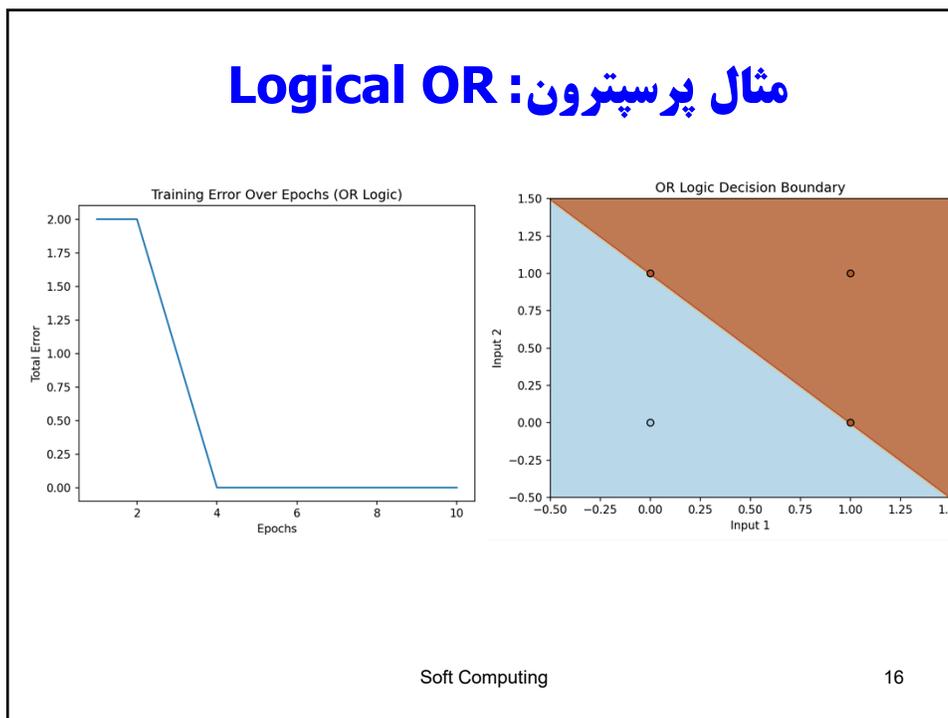
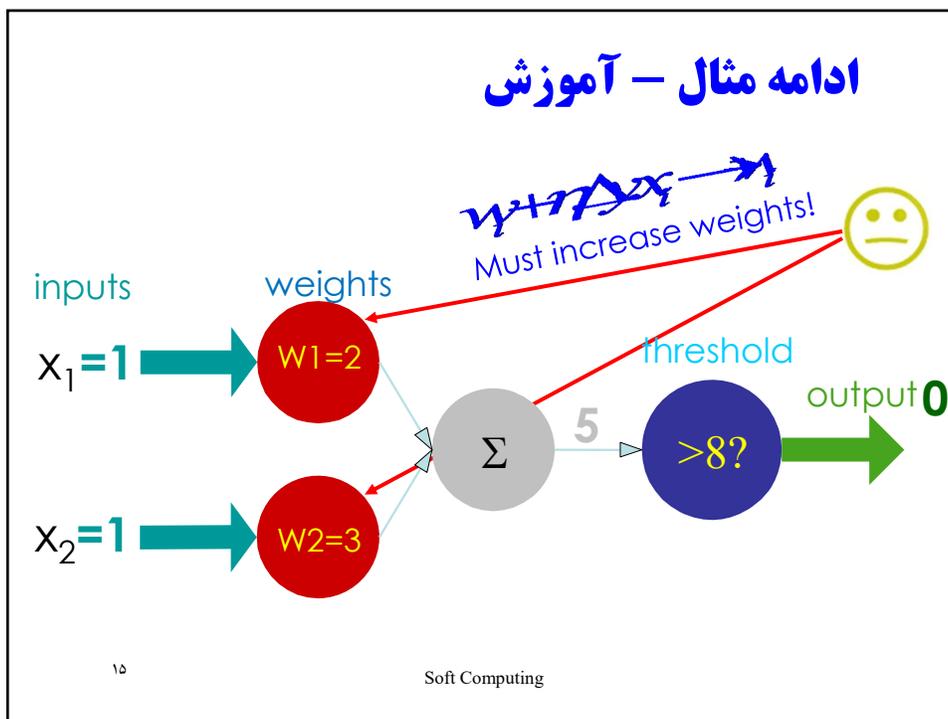
P2 الگویی است که باید پرسپترون یاد بگیرد: یعنی، اگر هر دو ورودی 1 هستند، خروجی باید 1 باشد



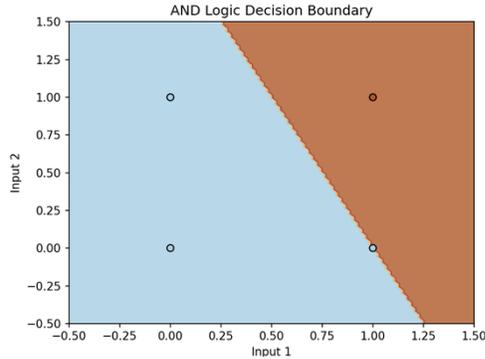
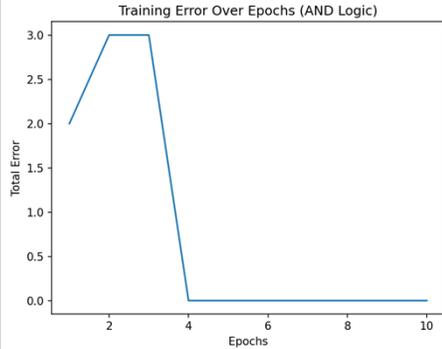
۱۲

Soft Computing





مثال پرسپترون : Logical AND



Soft Computing

17

Linear Inseparable

•Examples (two dimensions):

XOR function

	1	1	0
x_2	0	0	1
		0	1
			x_1

linearly inseparable

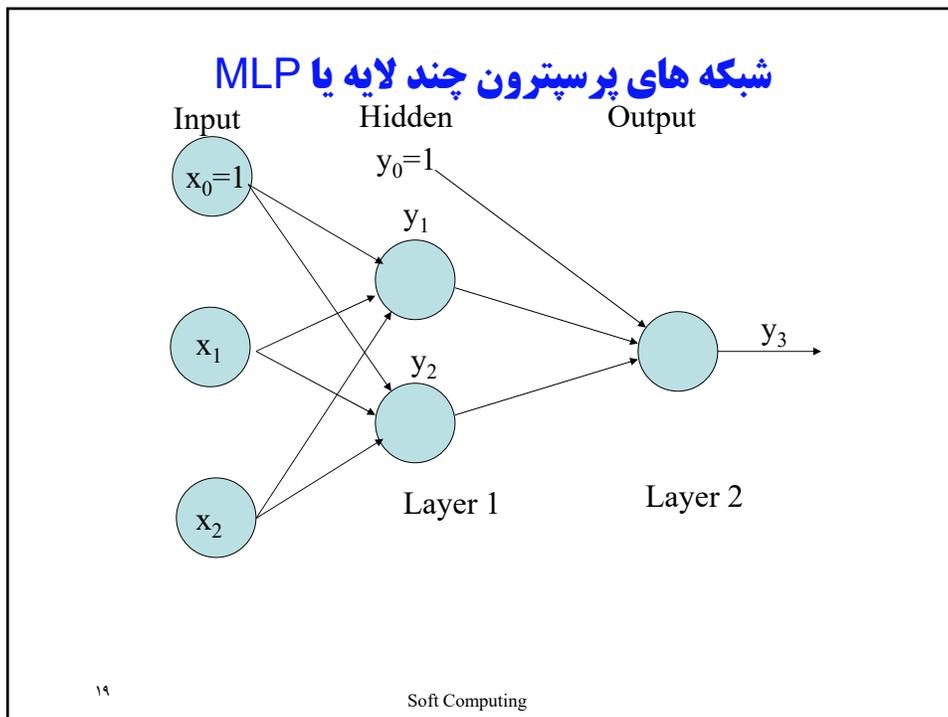
XNOR function

	1	0	1
x_2	0	1	0
		0	1
			x_1

linearly inseparable

This means that a single threshold neuron **cannot** realize the XOR and XNOR function.

Soft Computing



عملکرد پرسپترون چند لایه یا MLP

0,1
-1,0 1,0
0,-1

مثال:
چگونه می توان با پرسپترون نقاط داخل مربع را از سایر نقاط جدا کرد

x_2
0,1
-1,0 1,0 x_1
0,-1

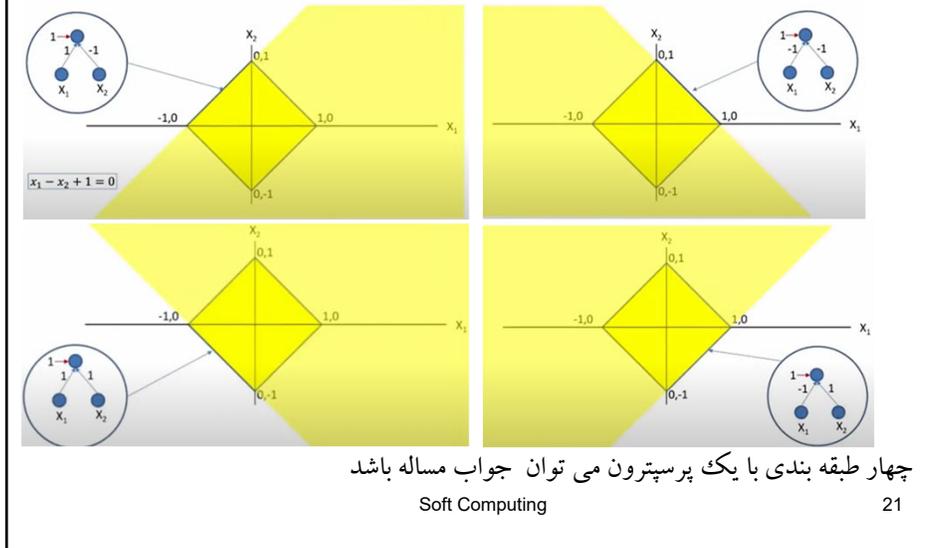
$x_1 - x_2 + 1 = 0$

حل:
به دلیل غیرخطی بودن کلاس وسط مربع با **یک پرسپترون نمی توان** طبقه بندی انجام داد

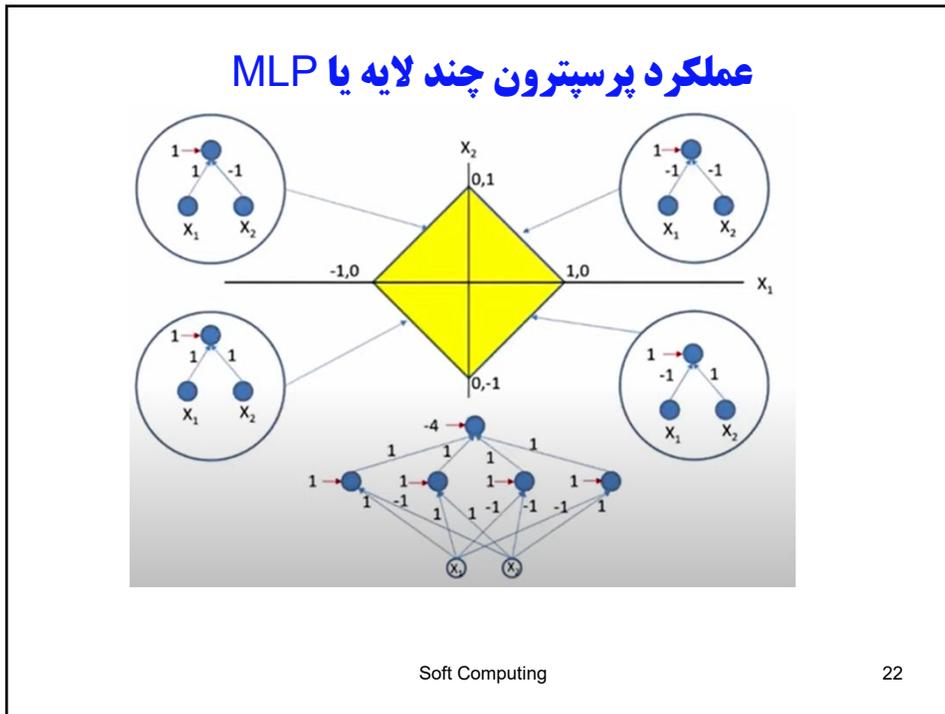
طبقه بندی با یک پرسپترون فقط خطی است

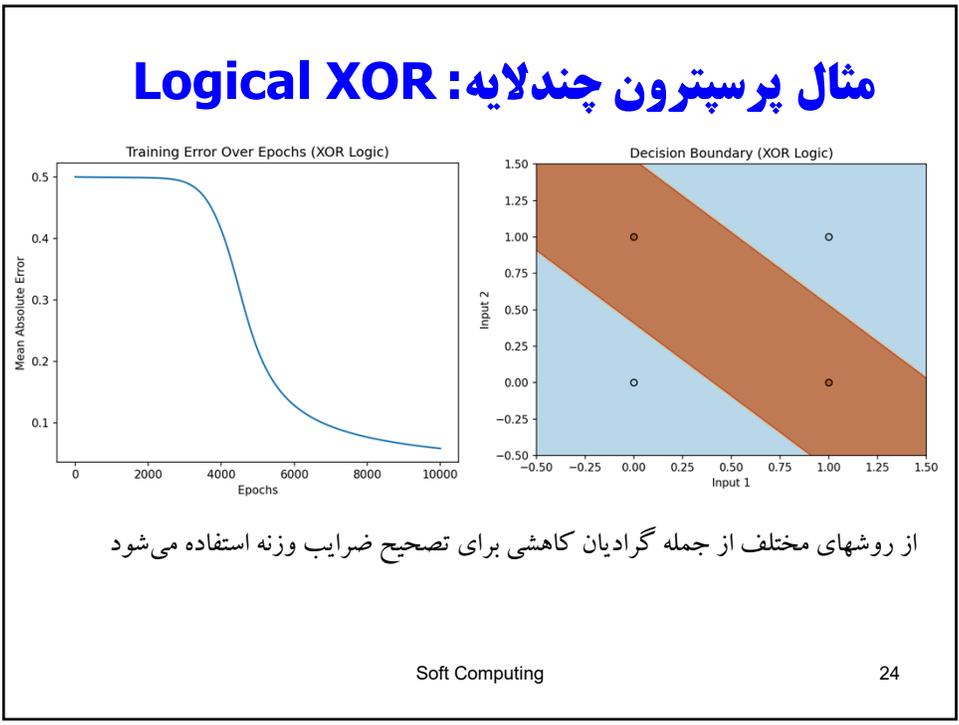
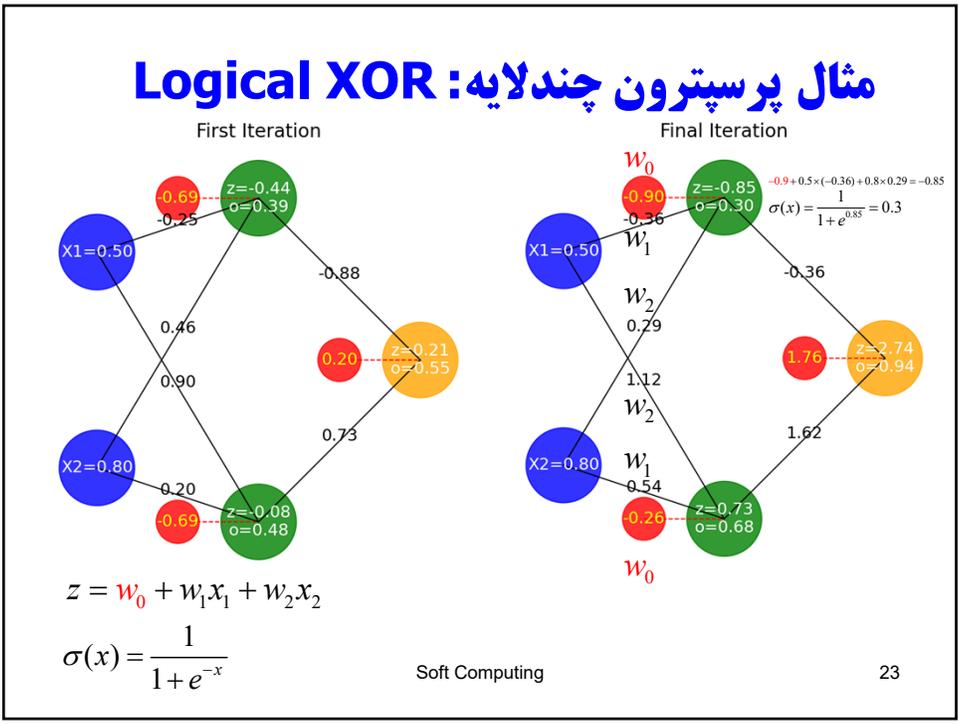
20

عملکرد پرسپترون چند لایه یا MLP

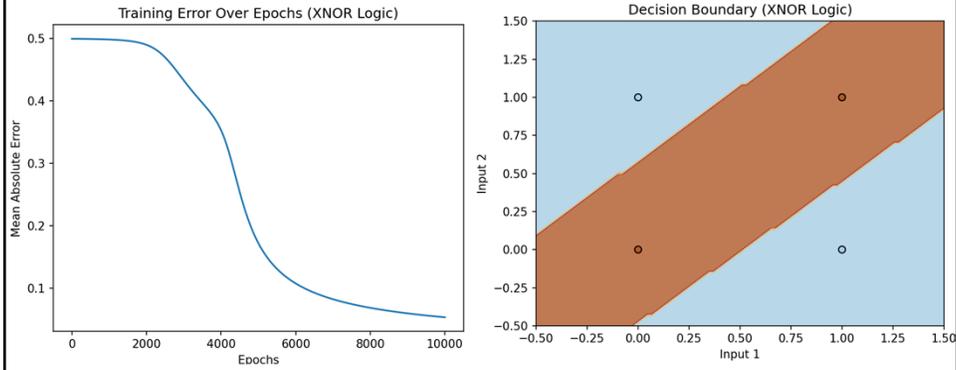


عملکرد پرسپترون چند لایه یا MLP





مثال پرسپترون چند لایه : Logical XNOR



پرسپترون چند لایه، شبکه عصبی یا شبکه ژرف نیز نامیده می شود

Soft Computing

25

شبکه عصبی - ویژگی های تابع فعال سازی

ویژگی های مورد نیاز

- پیوسته

- مشتق پذیر

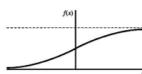
- دارا بودن کارایی محاسباتی (به راحتی قابل محاسبه باشد)
- مشتق تابع را بتوان برحسب مقدار خود تابع نوشت

- به صورت یکنوا غیر نزولی

- قابلیت اشباع (Saturate)

- به صورت مجانبی به مقادیر بیشینه و کمینه خود نزدیک شود

سیگموئید دودویی

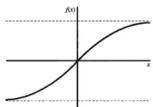


$$f(x) = \frac{1}{1 + \exp(-x)}$$

$$f'(x) = f(x)[1 - f(x)]$$

سیگموئید دو قطبی

- شباهت به تانژانت هپربولیک



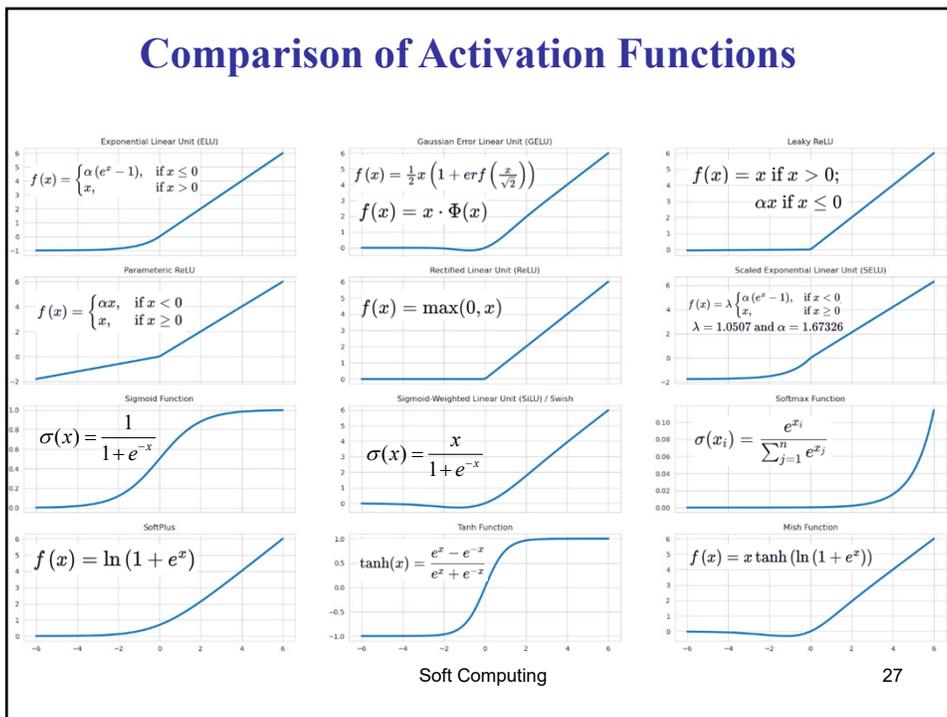
$$f_2(x) = \frac{2}{1 + \exp(-x)} - 1$$

$$f_2'(x) = f_2(x) \cdot [1 - f_2(x)]$$

$$f_1(x) = \frac{1}{1 + \exp(-x)}$$

با کشف الگوریتم پس-انتشار توسط رملهات، هینتن و ویلیامز در سال ۱۹۸۶ مطالعات جدید بر روی شبکه های عصبی مجددا شروع شد. اهمیت ویژه این الگوریتم این بود که شبکه های عصبی چند لایه توسط آن می توانستند آموزش داده شوند.

Soft Computing



Comparison of Activation Functions

Activation Function	Range	Use Case	Advantages	Limitations
$\sigma(x) = \frac{1}{1 + e^{-x}}$ Sigmoid	(0, 1)	Binary classification	Smooth, probabilistic output	Vanishing gradient, not zero-centered
$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$ Tanh	(-1, 1)	Hidden layers	Zero-centered output	Vanishing gradient
$f(x) = \max(0, x)$ ReLU (Rectified Linear Unit)	[0, ∞)	Hidden layers	Efficient, avoids vanishing gradient	Dying neurons
$f(x) = \begin{cases} x & \text{if } x > 0; \\ \alpha x & \text{if } x \leq 0 \end{cases}$ Leaky ReLU	(-∞, ∞)	Hidden layers	Avoids dying neurons	Arbitrary slope choice
$\sigma(x_i) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}}$ Softmax	(0, 1)	Output for multi-class problems	Probabilistic interpretation	Expensive for large datasets
$f(x) = x \cdot \sigma(x)$ Swish	(-∞, ∞)	Deep networks	Smooth and flexible	Slightly more computationally intensive
$f(x) = x \cdot \Phi(x)$ GELU	(-∞, ∞)	Transformer-based architectures	Smooth and efficient	Relatively new, computationally expensive

Soft Computing
28

شبکه عصبی مصنوعی

افزایش تعداد لایه‌های برای پردازش مسایل پیچیده‌تر

Layer 1

Layer 2

Layer 3

$z = w_0x_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n$

$a_i^{(l+1)}(x) = b_i^{(l)} + \sum_j w_{ji}^{(l)} a_j^{(l)}$

$a_i^{(l+1)}$ activation of unit i in layer $l+1$

$w_{ji}^{(l)}$ Weight of unit i in layer $l+1$ receiving from unit j in layer l which control function mapping from layer l to layer $l+1$

Soft Computing 29

شبکه عصبی مصنوعی

Layer 2

Layer 3

$a_1^{(2)}(x) = g(b_1^{(1)}x_0^{(1)} + w_{11}^{(1)}x_1^{(1)} + w_{21}^{(1)}x_2^{(1)} + w_{31}^{(1)}x_3^{(1)})$

$a_2^{(2)}(x) = g(b_2^{(1)}x_0^{(1)} + w_{12}^{(1)}x_1^{(1)} + w_{22}^{(1)}x_2^{(1)} + w_{32}^{(1)}x_3^{(1)})$

$a_3^{(2)}(x) = g(b_3^{(1)}x_0^{(1)} + w_{13}^{(1)}x_1^{(1)} + w_{23}^{(1)}x_2^{(1)} + w_{33}^{(1)}x_3^{(1)})$

$h_w(x) = a_1^{(3)}(x) = g(b_1^{(2)}a_0^{(2)} + w_{11}^{(2)}a_1^{(2)} + w_{21}^{(2)}a_2^{(2)} + w_{31}^{(2)}a_3^{(2)})$

Learnable parameter for l layer

$$\sum_{l=1}^{L-1} (N_l + 1)(N_{l+1}) = (N_1 + 1)N_2 + (N_2 + 1)N_3 \dots (N_{L-1} + 1)N_L$$

N_l Number of neuron in l layer

Soft Computing 30

شبکه عصبی مصنوعی

pip install tensorflow

pip install intel-tensorflow Use Intel-optimized TensorFlow

```
import os
import numpy as np
import random
import matplotlib.pyplot as plt
from sklearn.datasets import make_classification
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler
from sklearn.metrics import accuracy_score, ConfusionMatrixDisplay

# Optional: Disable oneDNN custom operations to avoid floating-point warnings
os.environ["TF_ENABLE_ONEDNN_OPTS"] = "0"
os.environ['TF_CPP_MIN_LOG_LEVEL'] = '2' #Suppress TensorFlow INFO and WARNING logs

import tensorflow as tf
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Input

# Set random seeds for reproducibility
np.random.seed(42)
tf.random.set_seed(42)
random.seed(42)
```

13 ANN.py

Soft Computing

31

شبکه عصبی مصنوعی

```
# Generate a 2D dataset for visualization
X, y = make_classification(
    n_samples=200, n_features=2, n_informative=2, n_redundant=0,
    n_clusters_per_class=1, random_state=42
)

# Standardize the dataset
scaler = StandardScaler()
X = scaler.fit_transform(X)

# Split the dataset into training and testing sets
X_train, X_test, y_train, y_test = train_test_split(X, y,
    test_size=0.3, random_state=42)

# Build the ANN model
def build_model(input_dim, output_dim):
    """Build a simple feedforward ANN model with two hidden layers.
    """
    model = Sequential([
        Input(shape=(input_dim,)), # Explicit Input layer
        Dense(4, activation='relu'), # 4 neuron First hidden layer
        Dense(2, activation='relu'), # 2 neuron Second hidden layer
        Dense(output_dim, activation='sigmoid') # Output layer for
        binary classification
    ])
    return model
```

Soft Computing

32

شبکه عصبی مصنوعی

```
# Train, evaluate, and plot ANN
def train_evaluate_ann(epochs=50, batch_size=8):
    """Train the ANN, evaluate on test data, and visualize results.
    print("Training Artificial Neural Network...")

    # Build and compile the model
    model = build_model(input_dim=2, output_dim=1)
    model.compile(optimizer='adam', loss='binary_crossentropy',
metrics=[ 'accuracy'])

    # Train the model
    history = model.fit(X_train, y_train, epochs=epochs,
batch_size=batch_size, verbose=0)

    # Evaluate on test set
    y_pred = (model.predict(X_test) > 0.5).astype(int)
    accuracy = accuracy_score(y_test, y_pred)
    print(f"Test Accuracy: {accuracy:.2f}")

    # Plot decision boundary
    plot_ann_with_boundary(X_train, y_train, model, accuracy)

# Run the ANN training and visualization
if __name__ == "__main__":
    try:
        train_evaluate_ann(epochs=50, batch_size=8)
    except Exception as e:
        print(f"An error occurred: {e}")

# Predict a new example
predict_new_example(model, scaler, target_names)
```

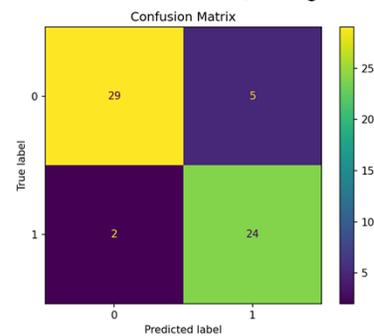
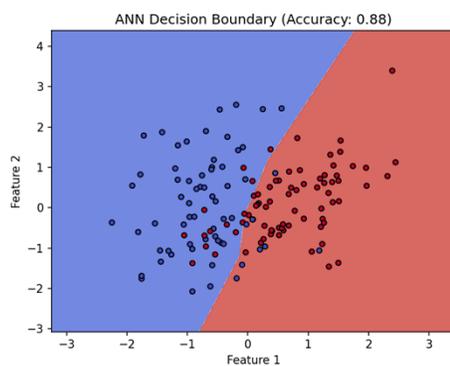
33

Soft Computing

مثال

حل مساله به روش شبکه عصبی برای مثال دسته بندی در قسمت SVM

• اجرای اول



```
model = Sequential([
    Input(shape=(input_dim,)), # Explicit Input layer
    Dense(4, activation='relu'), # 4 neuron First hidden layer
    Dense(2, activation='relu'), # 2 neuron Second hidden layer
    Dense(output_dim, activation='sigmoid') # Output layer for binary classification
```

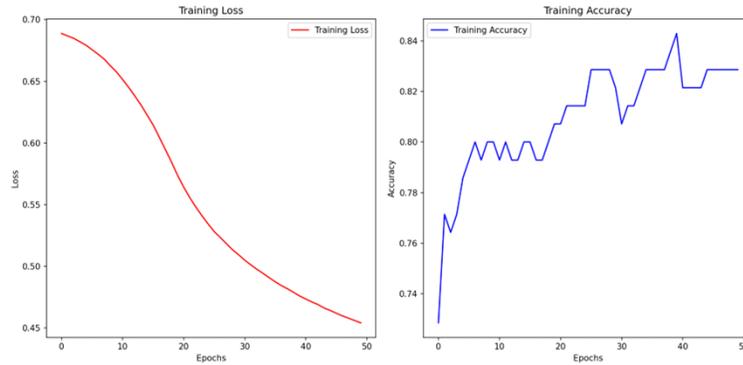
Soft Computing

34

مثال

حل مساله به روش شبکه عصبی برای مثال دسته بندی در قسمت SVM

• اجرای اول



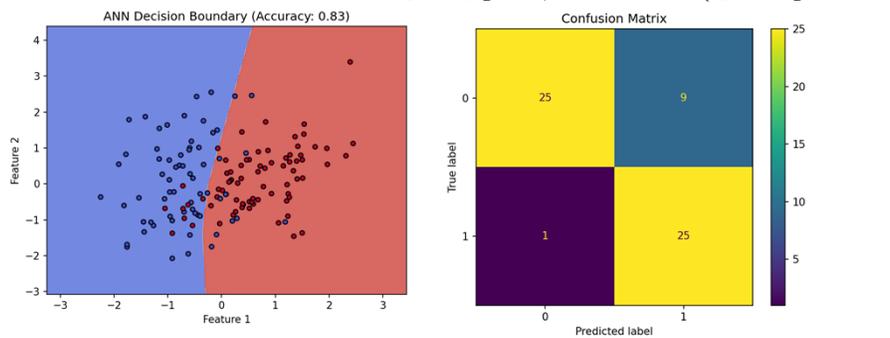
Soft Computing

35

مثال

حل مساله به روش شبکه عصبی برای مثال دسته بندی در قسمت SVM

• اجرای دوم - حساسیت به شرایط اولیه



```
model = Sequential([
    Input(shape=(input_dim,)), # Explicit Input layer
    Dense(4, activation='relu'), # 4 neuron First hidden layer
    Dense(2, activation='relu'), # 2 neuron Second hidden layer
    Dense(output_dim, activation='sigmoid') # Output layer for binary classification
])
```

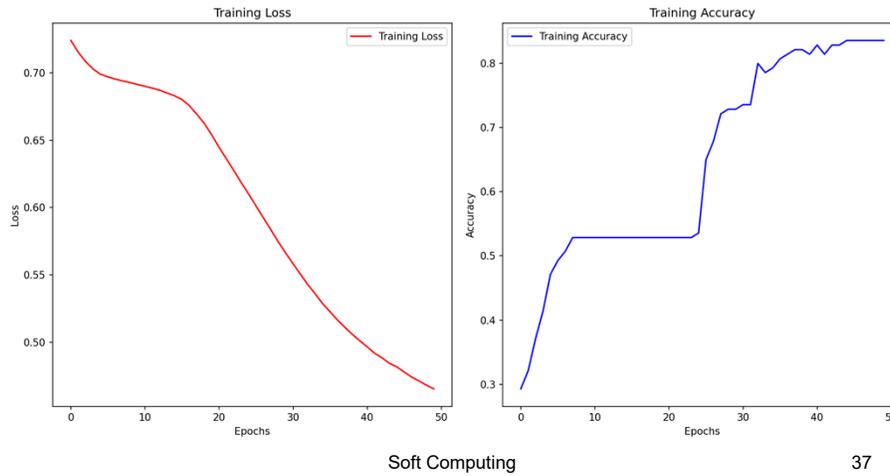
Soft Computing

36

مثال

حل مساله به روش شبکه عصبی برای مثال دسته بندی در قسمت SVM

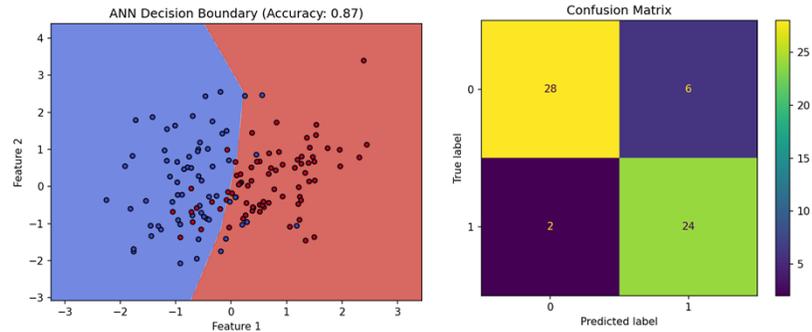
• اجرای دوم



مثال

حل مساله به روش شبکه عصبی برای مثال دسته بندی در قسمت SVM

• اجرای سوم - شرایط اولیه یکسان



Set Random Seeds:

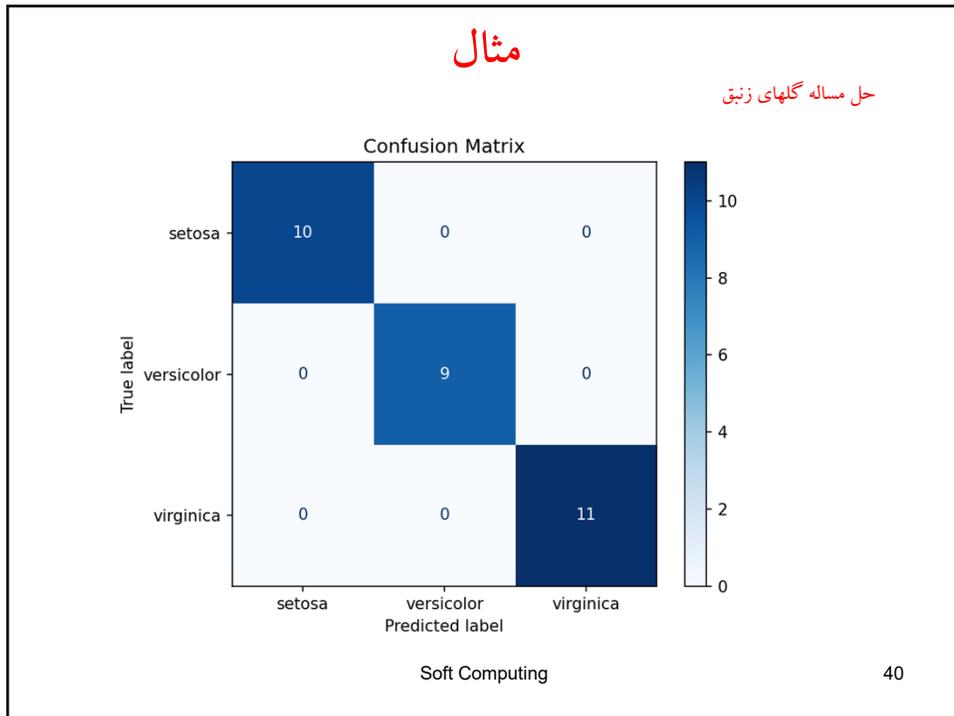
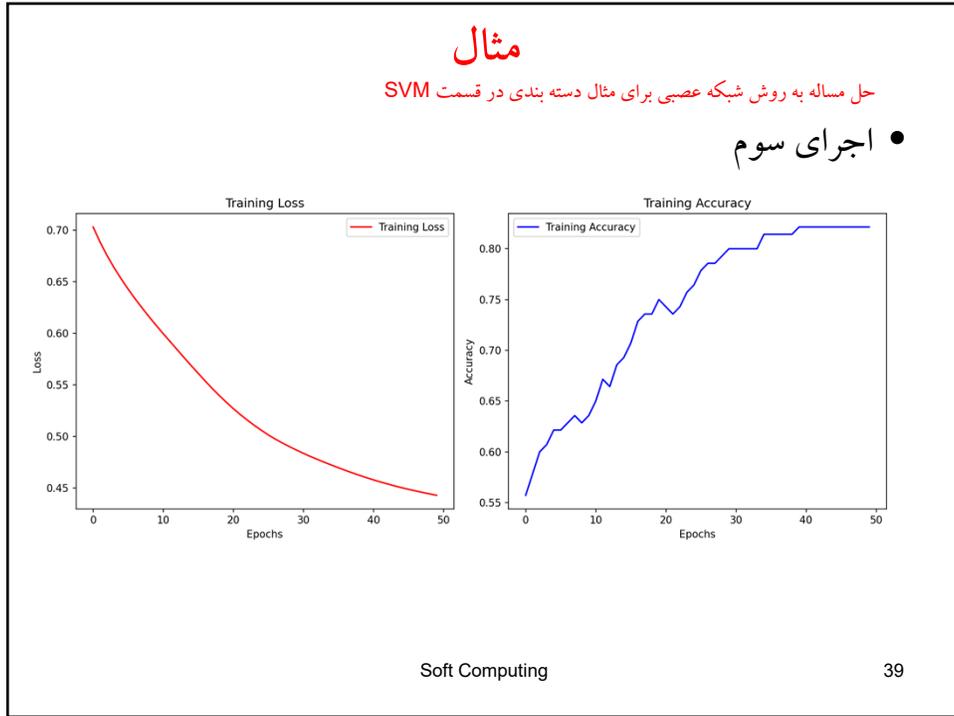
- Fixing the random seed ensures reproducibility across runs.

```
np.random.seed(42)
tf.random.set_seed(42)
random.seed(42)
```

13 ANN replace SVM.py

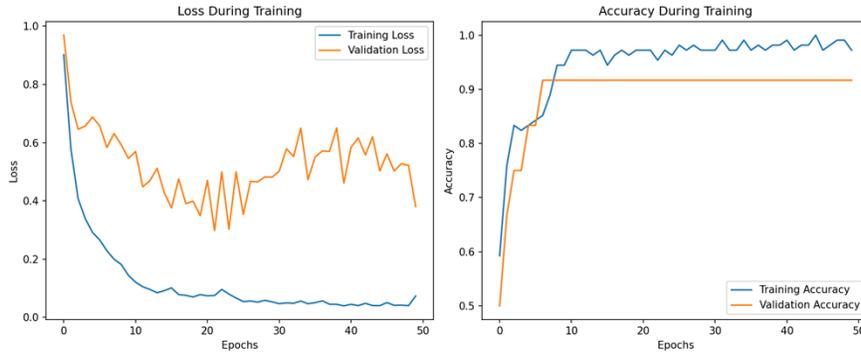
Soft Computing

38



مثال

حل مساله گلهاي زنيق



New Example Features: [5.9 3. 5.1 1.8]
 Predicted Class: virginica

Soft Computing

41

معماری شبکه هوش مصنوعی

- First hidden layer, the number of neurons is often: $n > n_{input\ features} + n_{output\ targets}$
- Subsequent layers, try reducing the number of neurons progressively (e.g., $64 \rightarrow 32 \rightarrow 16$).

Example

1. Binary Classification

- Input Features: 10
- Output Classes: 2

• Suggested Architecture:

- Input Layer: 10 neurons (input size).
- Hidden Layer 1: 16 neurons (capture interactions).
- Hidden Layer 2: 8 neurons (reduce complexity).
- Output Layer: 2 neuron (sigmoid activation).

2. Multiclass Classification

- Input Features: 20
- Output Classes: 5

• Suggested Architecture:

- Input Layer: 20 neurons.
- Hidden Layer 1: 32 neurons (capture higher-level features).
- Hidden Layer 2: 16 neurons.
- Output Layer: 5 neurons (softmax activation).

3. Regression

- Input Features: 5
- Output: Continuous value

• Suggested Architecture:

- Input Layer: 5 neurons.
- Hidden Layer 1: 10 neurons (nonlinear mapping).
- Output Layer: 1 neuron (linear activation).

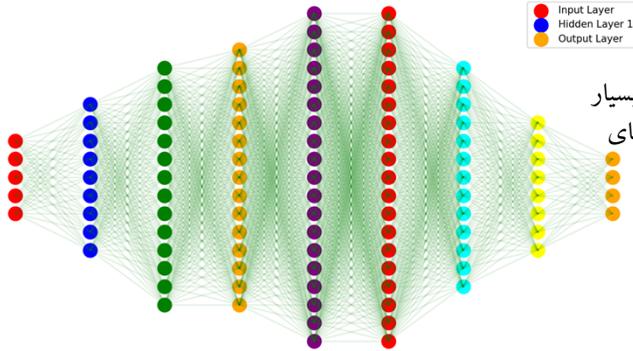
Use learning curves to analyze underfitting (high training loss) or overfitting (low training loss, high validation loss)

42

Soft Computing

شبکه عصبی مصنوعی

Neural Network with 7 Hidden Layers



شبکه عصبی می تواند بسیار پیچیده شده و پارامترهای زیادی داشته باشد

Feature	GPT-3	GPT-4 (Speculated)
Number of Layers	96	Likely >120
Parameters	175 billion	500 billion to 1 trillion
Context Length	2,048 to 4,096 tokens	Up to 32,768 tokens (or more)
Training Data	570 GB of filtered text	Larger and more diverse dataset
Vector Dimension	12,288	Likely 16,384 or more

43

Soft Computing

شبکه عصبی مصنوعی کانولوشنی

CNN: Convolutional Neural Networks

نوعی از شبکه‌های عصبی مصنوعی است که می‌تواند داده‌های تصویری را به صورت خودکار تحلیل و یاد بگیرد. برخلاف شبکه‌های عصبی سنتی که نیاز به پیش پردازش دستی ویژگی‌ها دارند، CNN ویژگی‌های مهم تصویر را به صورت خودکار استخراج می‌کند

مؤلفه

لایه کانولوشن
Convolution Layer

لایه فعال سازی
ReLU

لایه زیر نمونه گیری
Pooling

لایه اتصال کامل
Fully Connected

Softmax

توضیح

فیلترهایی (Kernel) را روی تصویر حرکت می‌دهد تا ویژگی‌هایی مثل لبه، گوشه یا بافت را شناسایی کند.

عملیات غیرخطی (مثل $\text{ReLU: max}(0, x)$) برای افزایش توانایی مدل در یادگیری روابط پیچیده.

اندازه تصویر را کاهش می‌دهد و به مدل کمک می‌کند تا نسبت به جابه‌جایی‌ها مقاوم شود.

پس از استخراج ویژگی‌ها، تصمیم‌گیری نهایی (مثلاً طبقه‌بندی) را انجام می‌دهد.

خروجی نهایی برای دسته‌بندی (مثلاً احتمال تعلق تصویر به هر کلاس).

Soft Computing

44

تمرین برنامه نویسی

تمرین: یک برنامه به زبان پایتون بنویسید که یک فایل داده را خوانده و به روش شبکه عصبی مصنوعی موارد زیر را انجام دهد.

۱- تعریف یک مدل MLP

۲- تعیین و تنظیم تعداد لایه‌های پنهان و نرونها

۳- تعیین توابع فعالسازی مناسب

Data set: "Concrete Compressive Strength"

Input.: 8 Features

Output: Concrete strength

Sample No.: 1030

۴- پیش بینی مناسب مقاومت فشاری بتن

۵- تعیین میزان خطا

PyTorch: کتابخانه متن‌باز برای یادگیری عمیق که در سال ۲۰۱۶ توسط فیسبوک توسعه داده شده است. علاوه بر سادگی و پشتیبانی قوی در انجمن‌ها و شبکه‌های اجتماعی دارای ویژگی‌های زیر است:

- کتابخانه‌های غنی. مثل torchvision (کار با تصاویر)، torchtex (پردازش متن) و torchaudio (کار با صدا).
- محاسبات گراف‌های پویا (قابلیت تعریف و تغییر مدل و گراف محاسباتی حین اجرا)
- سازگاری با سایر کتابخانه‌ها نظیر Numpy و Scikit-Learn
- پشتیبانی از کارت‌های گرافیک

Soft Computing

45