



(19) 대한민국특허청(KR)
(12) 등록특허공보(B1)

(45) 공고일자 2021년01월18일
(11) 등록번호 10-2204107
(24) 등록일자 2021년01월12일

(51) 국제특허분류(Int. Cl.)
G06N 3/04 (2006.01) G06N 3/063 (2006.01)
(52) CPC특허분류
G06N 3/049 (2013.01)
G06N 3/063 (2013.01)
(21) 출원번호 10-2020-0088313
(22) 출원일자 2020년07월16일
심사청구일자 2020년07월16일
(56) 선행기술조사문헌
KR1020190120253 A
(뒷면에 계속)

(73) 특허권자
세종대학교산학협력단
서울특별시 광진구 능동로 209 (군자동, 세종대학교)
(72) 발명자
이성주
서울특별시 광진구 뚝섬로35길 32, 308-1110
최찬욱
경기도 남양주시 식송2로 29-12, 101호
(74) 대리인
이강민, 안준형, 남승희

전체 청구항 수 : 총 6 항


심사관 : 박상현

(54) 발명의 명칭 뉴런의 임계값에 STDP(Spiking Timing Dependent Plasticity)를 적용한 스파이킹 뉴럴 네트워크(Spiking Neural Network)

(57) 요약

복수의 뉴런 레이어(Layer)를 가지는 신경망 회로에서 임의의 뉴런에서 이전 뉴런 스파이크(Spike)와 다음 뉴런 스파이크(Spike)의 시간 차의 값이 양수이고 절대값이 작을수록 뉴런의 임계값을 크게하여 인식률은 유지하고 연산 처리량은 증가하지 않는 뉴런의 임계값 STDP를 적용한다.

대표도 - 도1



(56) 선행기술조사문헌
 KR1020140141778 A
 KR1020200085491 A
 KR1020160010477 A*
 KR1020200108173 A

*는 심사관에 의하여 인용된 문헌

이 발명을 지원한 국가연구개발사업

과제고유번호 1711116145
 과제번호 2018-0-01423-003
 부처명 과학기술정보통신부
 과제관리(전문)기관명 정보통신기획평가원
 연구사업명 정보통신방송혁신인재양성(R&D)
 연구과제명 지능형 비행로봇 융합기술 연구
 기여율 1/2
 과제수행기관명 세종대학교 산학협력단
 연구기간 2020.01.01 ~ 2020.12.31

이 발명을 지원한 국가연구개발사업

과제고유번호 1711108024
 과제번호 2020R1A2C1007546
 부처명 과학기술정보통신부
 과제관리(전문)기관명 한국연구재단
 연구사업명 개인기초연구(과기정통부)(R&D)
 연구과제명 실내보안용 초고해상도 지능형 레이더센서 신호처리 연구
 기여율 1/2
 과제수행기관명 세종대학교
 연구기간 2020.03.01 ~ 2021.02.28

명세서

청구범위

청구항 1

입력 뉴런;

출력 뉴런;

상기 입력 뉴런에서 발생하는 소정의 전위인 입력 스파이크를 상기 출력 뉴런으로 전달하는 시냅스; 로 구성되며,

상기 출력 뉴런은 소정의 발화 임계값을 가지며,

상기 시냅스는,

입력 스파이크에 대하여 고정된 시냅스 가중치를 가지며;

상기 출력 뉴런의 발화 임계값은,

상기 입력 뉴런의 스파이크 및 상기 출력 뉴런의 스파이크가 각각 발생하는 시간의 시간차에 의해서 변동되는 임계값 변화량으로 변동되는 것;

을 특징으로 하는 뉴럴 네트워크.

청구항 2

제 1항에 있어서,

상기 임계값 변화량은 , 수학식 1에 의해서 결정되는 것;

을 특징으로 하는 뉴럴 네트워크.

수학식 1

$$\Delta T = \begin{cases} i) A e^{-\frac{\Delta t}{\tau}} (\Delta t > 0, A < 0) \\ ii) B e^{\frac{\Delta t}{\tau}} (\Delta t \leq 0, B > 0) \end{cases}$$

ΔT = 임계값의 변화량;

Δt = 출력 스파이크가 발생한 시간 - 입력 스파이크가 발생한 시간;

τ = 기울기;

A, B = 크기를 나타내는 상수.

청구항 3

제 1항에 있어서,

상기 임계값 변화량은, 수학식 2에 의해서 결정되는 것;

을 특징으로 하는 뉴럴 네트워크.

수학식 2

$$\Delta T = \begin{cases} \alpha^{-T_{old}} (N - T_{old}) (\Delta t > 0) \\ \alpha^{+T_{old}} (N - T_{old}) (\Delta t \leq 0) \end{cases}$$

$$T_{new} = T_{old} + \Delta T$$

ΔT = 임계값의 변화량;

$\alpha \pm$ = 학습률 상수

N = 입력 뉴런의 개수

T_{old} = 기존의 임계값

T_{new} = 새로운 임계값

청구항 4

입력 뉴런, 입력뉴런의 스파이크를 입력받는 출력 뉴런, 입력 뉴런에서 발생하는 소정의 전위인 입력 스파이크를 상기 출력 뉴런으로 전달하는 시냅스로 구성된 뉴럴 네트워크의 신호 전달 방법으로서, 입력 뉴런의 스파이크에 대하여 고정된 시냅스 가중치를 가하여 출력 뉴런에 입력하는 스파이크 입력 단계;

입력 스파이크에 따른 입력 스파이크와 출력 스파이크의 발생시간을 측정하는 스파이크 발생 시간을 측정하는 발화시점 측정단계;

상기 발화시점 측정단계에서의 입력 스파이크와 출력 스파이크가 각각 발생하는 시간의 시간차를 측정하는 스파이크 시간차 측정단계;

상기 출력 뉴런의 발화 임계값을 변동시키는 발화 임계값 변경 단계;

상기 스파이크 입력 단계에서 입력된 입력값이 상기 출력 뉴런의 발화 임계값을 초과하는 경우, 출력 스파이크를 발생시키는 출력 스파이크 발생 단계;로 구성되며,

상기 발화 임계값 변경 단계는,

상기 측정된 입력 스파이크와 출력 스파이크가 각각 발생하는 시간의 시간차에 의해서 변동되는 임계값 변화량으로 발화 임계값을 변동시키는 것;

을 특징으로 하는 뉴럴 네트워크의 신호 전달 방법.

청구항 5

삭제

청구항 6

제4항에 있어서, 상기 임계값 변화량은, 수학적 식 1에 의해서 결정되는 것;

을 특징으로 하는 뉴럴 네트워크의 신호 전달 방법.

수학적 식 1

$$\Delta T = \begin{cases} i) A e^{-\frac{\Delta t}{\tau}} (\Delta t > 0, A < 0) \\ ii) B e^{\frac{\Delta t}{\tau}} (\Delta t \leq 0, B > 0) \end{cases}$$

ΔT = 임계값의 변화량;

Δt = 출력 스파이크가 발생한 시간 - 입력 스파이크가 발생한 시간;

τ = 기울기;

$A, B =$ 크기를 나타내는 상수.

청구항 7

제4항에 있어서, 임계값 변화량은, 수학적 2에 의해서 결정되는 것;
을 특징으로 하는 뉴럴 네트워크의 신호 전달 방법.

수학적 6

$$\Delta T = \begin{cases} \alpha^- T_{old} (N - T_{old}) (\Delta t > 0) \\ \alpha^+ T_{old} (N - T_{old}) (\Delta t \leq 0) \end{cases}$$

$$T_{new} = T_{old} + \Delta T$$

$\Delta T =$ 임계값의 변화량;

$\alpha^\pm =$ 학습률 상수

$N =$ 입력 뉴런의 개수

$T_{old} =$ 기존의 임계값

$T_{new} =$ 새로운 임계값

발명의 설명

기술 분야

[0001] 본 발명은 뉴럴 네트워크에서 뉴런의 출력을 제어하는 방법에 관한 것으로서, 입력 시냅스의 가중치 부여 값을 학습하여 출력을 제어하는 종래의 기술과 달리, 뉴런의 임계값을 변동하는 방식을 학습하여 최적의 출력을 제어하는 방법에 관한 것이다.

배경 기술

[0002] 신경망이란 인간 두뇌의 신경망을 모방하여 데이터 마이닝, 언어 인식, 이미지 처리, 신호처리 등과 같은 여러 산업에서 적용하는 인공지능 기법이다. 종래에, 회선 신경망(Convolution neural network) 기법을 많이 사용하였으나, 이는 이미지 데이터를 추출하고 비교 후 데이터를 모두 저장하여야 하기 때문에 대용량의 메모리와 높은 소모 전력을 요구하여 소형 시스템에 적용이 어렵다. 이에 인간의 두뇌 학습 및 정보처리 방식과 유사하고 적은 양의 데이터를 사용하는 SNN(Spiking Neural Network) 방식을 대두되었다.

[0003] SNN에서는 통상, STDP(Spiking Timing Dependent Plasticity)라는 비지도 학습 방식을 사용한다. SNN은 다수의 레이어(Layer)로 구성되어 있고 각각의 레이어(Layer)에는 다수의 뉴런이 존재한다. 임의의 레이어(Layer)를 기준으로 했을 때 이전 레이어(Layer)의 뉴런을 프리 시냅틱 뉴런(Pre-Synaptic Neuron)이라 하고 기준이 되는 레이어(Layer)의 뉴런을 포스트 시냅틱 뉴런이라고 정의하게 되는데 프리 시냅틱 뉴런(Pre-Synaptic Neuron)과 포스트 시냅틱 뉴런(Post-Synaptic Neuron) 사이는 시냅스(Synapse)로 연결되어 있다. 뉴런과 뉴런 사이를 연결하는 시냅스(Synapse)는 특정 가중치를 가지고 있다. STDP는 포스트 시냅틱 뉴런(Post-Synaptic Neuron)에서의 스파이크(Spike) 발생 시간과 프리 시냅틱 뉴런(Pre-Synaptic Neuron)에서의 스파이크(Spike) 발생 시간 차이로 시냅스의 가중치를 조절하는 비지도 학습 방법이다.

[0004] 포스트 시냅틱 뉴런(Post-Synaptic Neuron)은, 프리 시냅틱 뉴런(Pre-Synaptic Neuron)으로부터 입력으로 들어오는 스파이크(Spike)에 각각 시냅스 가중치를 곱하고 이를 모두 더한 값이 특정 임계값을 넘게 되면 다음 레

이어(Layer)로 발화한다.

[0005] 이에 특정 임계값을 넘을 수 있도록 최적화 가중치를 찾아야 하며, 가중치의 변화량을 조절하여 새로운 시냅스 가중치를 구한 후 위와 같은 계산을 반복하여 출력을 제어한다. 이때, 입력 뉴런의 개수가 증가하면 증가한 개수만큼 시냅스 가중치의 수가 증가하고 학습하는 가중치의 개수도 증가하게 된다. 이에 처리해야 하는 연산량이 증가하여 연산 처리 시간이 길어지게 되기 때문에 소모 전력이 늘어나는 문제점이 있다.

발명의 내용

해결하려는 과제

[0007] 본 발명은 상기와 같은 문제점을 해결하기 위한 것으로서 입력 뉴런의 개수가 증가하여도 연산량이 증가하지 않는 뉴런의 임계값 STDP 학습 방법을 제공하고자 한다.

과제의 해결 수단

[0008] 상기의 문제를 해결하기 위하여 본 발명에서는, 입력 뉴런; 출력 뉴런; 상기 입력 뉴런에서 발생하는 소정의 전위인 입력 스파이크를 상기 출력 뉴런으로 전달하는 시냅스;로 구성되며,

[0009] 상기 출력 뉴런은 소정의 발화 임계값을 가지며, 상기 출력 뉴런의 발화 임계값은 변동되는 것; 을 특징으로 하는 뉴런 네트워크를 구성한다.

[0010] 구체적으로 상기 시냅스는, 입력 스파이크에 대하여 고정된 시냅스 가중치를 가지는 것; 입력 뉴런, 입력뉴런의 스파이크를 입력 받는 출력 뉴런, 입력 뉴런에서 발생하는 소정의 전위인 입력 스파이크를 상기 출력 뉴런으로 전달하는 시냅스로 구성된 뉴런 네트워크의 신호 전달 방법을 포함하고 있다.

[0011] 또한, 본 발명에서는 입력 뉴런의 스파이크에 대하여 고정된 시냅스 가중치를 가하여 출력 뉴런에 입력 하는 스파이크 입력 단계; 상기 출력 뉴런의 발화 임계값을 변동시키는 발화 임계값 변경 단계; 상기 스파이크 입력 단계에서 입력된 입력값이 상기 출력 뉴런의 발화 임계값을 초과하는 경우, 출력 스파이크를 발생시키는 출력 스파이크 발생 단계; 를 포함하여 구성되는 뉴런 네트워크의 신호 전달 방법에서의 다수의 단계로 구성된다.

[0012] 더욱 구체적으로, 상기 발화 임계값 변경 단계 이전에, 입력 스파이크에 따른 입력 스파이크와 출력 스파이크의 발생시간을 측정하는 스파이크 발생시간을 측정하는 발화시점 측정단계; 상기 발화시점 측정단계에서의 입력 스파이크와 출력 스파이크가 각각 발생하는 시간의 시간차를 측정하는 스파이크 시간차 측정단계; 를 추가로 포함하며, 상기 발화 임계값 변경 단계는, 상기 측정된 입력 스파이크와 출력 스파이크가 각각 발생하는 시간의 시간차에 의해서 임계값 변화량을 가지도록 발화 임계값을 변동시키는 것; 을 특징으로 하는 뉴런 네트워크의 신호 전달 방법으로 구성된다.

[0013] 본 발명에서의 임계값 변화량은, 수학식 4에 의해서 결정되는 것; 을 특징으로 하는 뉴런 네트워크의 신호 전달 방법이다.

[0014] 수학식 4

[0015]
$$\Delta T = \begin{cases} i) A e^{-\frac{\Delta t}{\tau}} (\Delta t > 0, A < 0) \\ ii) B e^{\frac{\Delta t}{\tau}} (\Delta t \leq 0, B > 0) \end{cases}$$

[0016] 수학식 4는 ΔT = 임계값의 변화량; Δt = 출력 스파이크가 발생한 시간 - 입력 스파이크가 발생한 시간; τ = 기울기; A, B = 크기를 나타내는 상수로 나타낼 수 있다.

[0017] 본 발명의 수단으로 임계값 변화량은, 수학식 6에 의해서 결정되는 것; 을 특징으로 하는 뉴런 네트워크의 신호 전달 방법에 사용된다.

[0018] 수학적식 6

$$\Delta T = \begin{cases} \alpha^- T_{old} (N - T_{old}) & (\Delta t > 0) \\ \alpha^+ T_{old} (N - T_{old}) & (\Delta t \leq 0) \end{cases}$$

$$T_{new} = T_{old} + \Delta T$$

[0021] 수학적식 6은 ΔT = 임계값의 변화량; α^\pm = 학습률 상수; N = 입력뉴런의 개수; T_{old} = 기존의 임계값; T_{new} = 새로운 임계값으로 나타낼 수 있다.

발명의 효과

[0022] 기존의 학습법은 증가한 입력 뉴런의 개수만큼 시냅스 가중치의 개수도 증가하게 되어, 학습해야 하는 가중치의 개수가 늘어남으로 연산량이 늘어나게 되지만, 본 발명에서의 임계값 학습법은 입력 뉴런의 개수가 증가하여도 학습해야 하는 임계값의 개수가 늘지 않아 처리해야 하는 연산량이 증가하지 않는다.

[0023] 이에 본 발명은 기존의 방법보다 연산 처리 시간이 줄어들고, 대용량의 연산 처리 장치를 요구하지 않으며, 연산 처리 시간이 길어지지 않아 소모 전력이 증가하지 않는다. 또한, 본 발명은 입력 뉴런의 개수가 증가하면 인식률의 정확도가 올라간다는 장점을 가지고 있다. 본 발명은 드론, 전기 자동차 등과 같은 배터리를 사용하는 시스템에 적용 가능하며, 저전력 소형 시스템에도 용이하게 사용될 수 있다.

도면의 간단한 설명

[0024] 도 1 은 본 발명의 뉴럴 네트워크의 일부를 나타낸 것이다.

도 2 는 본 발명의 스파이크 발생 시간 표현이다.

도 3은 본 발명의 출력 뉴런 발화 임계값의 변화량을 나타낸 것이다.

도 4는 본 발명의 출력 뉴런 발화 임계값의 변화량과 출력 뉴런 발화 임계값의 관계를 나타낸 그래프이다.

발명을 실시하기 위한 구체적인 내용

[0025] 아래에서는 첨부한 도면을 참조하여 본 발명이 속하는 기술분야에서 통상의 지식을 가진 자가 용이하게 실시할 수 있도록 본 발명의 실시 예를 상세히 설명한다. 그러나 본 발명은 여러 가지 상이한 형태로 구현될 수 있으며 여기에서 설명하는 실시 예에 한정되지 않는다. 그리고 도면에서 본 발명을 명확하게 설명하기 위해서 설명과 관계없는 부분은 생략하였으며, 명세서 전체를 통하여 유사한 부분에 대해서는 유사한 도면부호를 붙였다.

[0026] 1. 뉴럴 네트워크

[0027] 인간의 신경망 구조를 모방한 인공 지능 기법인 뉴럴 네트워크는 다수의 뉴런들이 시냅스로 연결되어 네트워크를 형성하고 신호를 전달하는 것이다. 뉴럴 네트워크는 뉴런, 레이어(Layer), 시냅스(Synapse)로 구성된다. 이하 뉴럴 네트워크의 구성 요소와 구조에 대하여 설명한다.

[0028] 도 1 (100)은 본 발명의 뉴럴 네트워크의 일부를 나타내는 도면이다. 레이어(Layer)(110)는 같은 방향성을 가진 다수의 뉴런의 집단을 나타낸다. 각각 다른 레이어(Layer)(110)에 존재하는 뉴런을 연결하고 신호를 전달하는 것을 시냅스(Synapse)(130)라 한다. 뉴럴 네트워크에서는 시냅스(Synapse)(130)를 기준으로 이전의 뉴런을 프리 시냅틱 뉴런(Pre-Synaptic Neuron)이라 하고, 본 발명에서는 입력 뉴런(120)이라 한다. 시냅스(130)를 통해 입력 뉴런(120)과 연결되어 있는 시냅스(Synapse) 이후의 뉴런을 포스트 시냅틱 뉴런(Post-Synaptic Neuron)이라 하고 본 발명에서는 출력 뉴런(150)이라 한다. 입력 뉴런(120)에서 발생하고 시냅스(Synapse)(130)를 통하여 출력 뉴런(150)에 전달되는 신호를 입력 스파이크(Spike)(140)라 한다. 출력 스파이크(Spike)(160)는 출력 뉴런(150)에서 발생하는 신호이다.

[0029] 1.1. 뉴럴 네트워크의 출력

[0030] 인간의 신경망 구조에서 신경 세포는 다수의 자극을 받게 되는데 이때 모든 자극에 반응할 수는 없다. 이처럼 뉴럴 네트워크에서도 출력 뉴런(150)이 입력 뉴런(120)으로부터 발생하는 입력 신호들 모두를 받아 들이고 발화

하여 출력이 되지 않는다. 이 때문에 출력 뉴런의 발화 임계값을 설정하고 그 이상의 값만을 신호로 받아들여 출력을 제어한다.

[0031] SNN(Spiking Neural Network)은 입력 스파이크(Spike)(140)의 합이 출력 뉴런의 발화 임계값 이상이 될 때만 출력 스파이크(Spike)(160)가 발생하는 뉴럴 네트워크 방식이다.

[0032] 이하, 본 발명에서 임계값이라 함은 출력 뉴런의 발화 임계값을 의미한다.

[0033] 2. 종래 기술

[0034] SNN에서 입력 스파이크(Spike)(140)가 시냅스(Synapse)(130)를 통하여 출력 뉴런(150)에 전달 될 때, 각 시냅스(Synapse)(130)에는 시냅스 가중치가 있다. 시냅스 가중치는 입력 스파이크(Spike)(140)와 곱해져 입력 스파이크(Spike)(140)를 증폭 또는 감폭하는 임의의 값이다. 시냅스 가중치가 곱해진 입력 스파이크(Spike)(140)들을 모두 더하여 출력의 뉴런 임계값과 비교하여 출력을 제어한다. 이에 출력을 제어하기 위한 최적화된 시냅스 가중치 설계가 필요하게 된다. STDP(Spiking Timing Dependent Plasticity)는 입력 스파이크(Spike)가 발생한 시간과 출력 스파이크(Spike)가 발생한 시간의 차를 이용하여 시냅스 가중치의 변화량을 구하는 함수이다. STDP 학습법으로 시냅스 가중치를 최적화 하여 출력을 제어할 수 있다.

[0035] 도 2는 스파이크(Spike)가 발생한 시간을 수직선으로 나타낸 것이다. 입력 스파이크(Spike)가 발생한 시간(210) 및 출력 스파이크(Spike)가 발생한 시간(220)을 나타낸 그래프이다. j개의 입력 뉴런에서의 입력 스파이크(Spike)가 발생한 시간(220)은 t_j^{pre} 로 표현하며, i개의 출력 뉴런에서의 출력 스파이크(Spike)가 발생한 시간(230) t_i^{post} 이다. 도 2에서 시간 차(Δt)를 나타내는 구간을 표현하였다. 수학적 식 1은 출력 스파이크(Spike)가 발생한 시간(220)과 입력 스파이크(Spike)가 발생한 시간의 차(210)(이하 시간 차라 표기한다.)를 나타내는 식이다.

[0036] 수학적 식 1

[0037]
$$\Delta t = t_i^{post} - t_j^{pre}$$

[0038] 제 1 구간(230)은 $\Delta t > 0$ 이며 입력 스파이크(Spike)보다 출력 스파이크(Spike)의 발화 시점이 늦는 것을 나타낸다. 제 2 구간(240)은 $\Delta t \leq 0$ 인 경우이며 출력 스파이크가 입력 스파이크(Spike)보다 먼저 발화한 것을 나타낸 것이다.

[0039] 수학적 식 2는 SNN의 기본 원리를 나타낸 식이다. 수학적 식 2는 도 1와 같이 j개의 입력 뉴런을 가진 각각의 입력 스파이크(Spike)(S_j^{pre})에 시냅스 가중치(ω_j^{pre})를 곱하여 합한 것을 나타낸 식이다. 수학적 식 2의 계산 결과 값은 β 로 표현하였고, 임계값은 T 로 나타낸다.

[0040] 수학적 식 2

[0041]
$$\omega_1^{pre} \times S_1^{pre} + \omega_2^{pre} \times S_2^{pre} \dots + \omega_j^{pre} \times S_j^{pre} = \beta$$

[0042] 상기 수학적 식 2에서 $\beta < T$ 일 때, 즉 계산값(β)이 임계값(T)보다 작으면 출력 스파이크(Spike)의 값은 0으로 출력된다.

[0043] $\beta \geq T$ 일 경우, 계산값(β)는 임계값(T)보다 크거나 같으면 출력 스파이크(Spike)의 값은 1로 출력된다.

[0044] 3. 본 발명의 기술

[0045] 3.1. 본 발명에 따른 뉴럴 네트워크의 동작

[0046] 종래의 STDP 학습법에서는 입력 뉴런(120)의 개수가 늘어나면 시냅스(Synapse)의 개수가 늘어나게 되어 학습해야 하는 시냅스 가중치(ω)의 개수도 늘어난다. 즉, 늘어나는 시냅스 가중치(ω)의 개수만큼 처리해야 하는 연

산량도 증가한다.

[0047] 반면, 본 발명에서는 시냅스 가중치(ω)는 시스템의 설정된 고정 값이 되고, 출력 뉴런의 임계값(T)을 변화시켜 최적의 임계값을 찾아 출력을 제어한다. 이하 이에 대하여 설명한다.

[0048] 수학적식 3

$$[0049] \omega_1^{pre} \times S_1^{pre} + \omega_2^{pre} \times S_2^{pre} \dots + \omega_j^{pre} \times S_j^{pre} + \omega_{j+k}^{pre} \times S_{j+k}^{pre} \leq \beta + k$$

[0050] 예를 들면 입력 뉴런(120)이 k개 증가 할 때, 수학적식 3 같이 기존의 j개의 연산 항에서 k개 만큼의 연산 항이 증가하여 총 j+k개의 연산 항이 존재하게 된다. 입력 뉴런(120)이 k개 만큼 증가하면 학습해야 하는 시냅스 가중치(ω)도 k개가 추가되는 것이 종래의 기술이다. 반면 본 발명은 시냅스 가중치가 k개 더 증가하긴 하나, 고정된 설정 값이기 때문에 k개 만큼을 추가로 학습할 필요는 없다. 또한 하나의 입력 스파이크(120)와 시냅스 가중치(ω)의 곱이 될 수 있는 최대값은 1이기 때문에 계산 결과의 최대값도 $\beta+k$ 가 된다. 시냅스 가중치(ω)는 시스템의 설계 시 고정 값이며 여러 번의 연산을 걸쳐도 계산값은 $\beta+k$ 을 넘지 않는다. 본 발명에서 입력 뉴런의 개수가 증가해도 학습해야 하는 임계값의 개수는 늘어 나지 않는다.

[0051] 상기 수학적식 3과 같이 입력 뉴런의 개수가 k 개 증가하면 계산 결과 $\beta+k$ 가 되고, 계산 결과 $\beta+k$ 를 임계값(T)과 비교하여 출력을 제어한다.

[0052] $\beta+k < T$ 인 경우, 계산값이 출력 뉴런의 발화 임계값을 넘지 못하여 출력 스파이크는 발화하지 않아 0이 된다. 이와 반대로 $\beta+k \geq T$ 일 때, 계산값이 임계값을 넘어 출력 스파이크는 1로 발화한다. 이는 상기 수학적식 2의 출력 제어와 유사하다.

[0053] 도 3은 본 발명의 시간 차(Δt)에 따른 임계값의 변화량(ΔT)을 나타내는 그래프 이다. 본 발명은 시간 차(Δt)를 독립 변수로 사용한 임계값의 변화량(ΔT)을 함수이다. 그래프에서 가로축은 시간 차(Δt)를 나타내고 세로축은 임계값의 변화량(ΔT)을 나타낸다. $\Delta t > 0$ (310)구간에서는 시간 차가 작을수록, 임계값의 절대값 변화량은 더 크다. $\Delta t \leq 0$ (320)구간에서는 시간 차가 작을수록, 임계값의 절대값 변화량은 크다.

[0054] 수학적식 4

$$[0055] \Delta T = \begin{cases} i) A e^{-\frac{\Delta t}{\tau}} (\Delta t > 0, A < 0) \\ ii) B e^{\frac{\Delta t}{\tau}} (\Delta t \leq 0, B > 0) \end{cases}$$

[0056] 상기 수학적식 4는 도 3의 그래프의 계산식이다. 수학적식 4의 독립변수는 입출력 스파이크의 시간 차 (Δt), 종속 변수는 임계값의 변화량(ΔT)이다. i)는 $\Delta t > 0$ 에서 적용하는 학습 함수이고 ii)는 $\Delta t \leq 0$ 에서 적용하는 학습 함수이다.

[0057] 상기 수학적식 4에서 A 및 B 는 크기 상수이고 τ 는 기울기를 나타내는 상수이며 설정 값이다.

[0058] 수학적식 5

$$[0059] T_{New} = \begin{cases} T_{old} + \sigma \Delta T (N - T_{old}) (\Delta T > 0) \\ T_{old} + \sigma \Delta T (T_{old}) (\Delta T \leq 0) \end{cases}$$

[0060] 수학적식 5는 상기 수학적식 4을 통하여 얻은 임계값의 변화량(ΔT)을 적용하여 새로운 임계값을 구하는 식이다.

수학식 5의 T_{old} 는 기존의 임계값을 나타내고 T_{new} 는 함수식을 통해 새롭게 도출해낸 임계값이다. N 는 입력 뉴런의 개수이고 σ 는 학습률 상수이며 설정 값이다. σ 에 따라 임계값의 변화량의 크기가 결정되며, 이 함수 식을 통하여 임계값의 범위가 $0 \sim N$ 이라는 결과가 나올 수 있다.

[0061] 수학식 6

$$1) \Delta T = \begin{cases} \alpha^- T_{old} (N - T_{old}) (\Delta t > 0) \\ \alpha^+ T_{old} (N - T_{old}) (\Delta t \leq 0) \end{cases}$$

$$2) T_{new} = T_{old} + \Delta T$$

[0062] 수학식 6은 상기 수학식 4를 단순화하여 만든 학습 함수이다. 수학식 6에서는 독립 변수 시간 차(Δt)의 크기와 상관 없으며, 시간 차(Δt)는 함수의 범위만 영향을 준다. ΔT 는 임계값의 변화량이며, N 는 입력 뉴런의 개수 및 임계값의 최대값이다. 상기 α^\pm 는 학습률 상수로 설정 값이다. α^\pm 는 임계값의 변화량의 크기에 영향을 주는 상수이다. 도 4는 수학식 6에 따른 그래프이다. 세로축은 임계값(T)이며, 가로축은 출력 뉴런의 임계값의 절대값 변화량($|\Delta T|$)이다. 본 그래프는 임계값의 절대값 변화량과 임계값의 변화량에 따른 그래프를 나타낸 것이다. 본 그래프를 통해 임계값의 범위가 $0 \sim N$ 임을 알 수 있다.

[0066] 3.2. 본 발명에 따른 뉴런 네트워크에서 신호의 전달 방법

[0067] 본 발명에서 적용한 SNN은 입력 스파이크와 시냅스 가중치를 곱하여 더한 계산값을 임계값과 비교하고 계산값이 임계값 이상이면 출력 스파이크를 1로 결정하는 뉴런 네트워크이다. 이때 시냅스 가중치를 변화하여 상기 과정을 거친 계산값이 임계값 보다 크거나 작게하여 출력을 제어하는 것이 종래 STDP 학습법이다. 반면 본 발명은 시냅스 가중치를 변화시키지 않아 계산값은 고정되고 임계값을 변동시켜 계산값과 임계값을 비교하고, 이때 계산값보다 임계값이 작으면 출력 스파이크는 발화한다.

[0068] 도 3에서와 같이 $\Delta t > 0$ (310)이면서 크기가 작을수록, 임계값 변화량의 크기는 음의 방향으로 증가하게 된다. 이에 수학식 6의 2)와 같이 새로운 임계값은 기존의 임계값에 임계값의 변화량을 더한 것으로 새로운 임계값은 기존의 임계값 보다 작아지게 된다. 반면, $\Delta t \leq 0$ (320)이면서 크기가 작을수록, 임계값 변화량의 크기가 양의 방향으로 증가하여 상기와 같은 계산으로 새로운 임계값은 기존의 임계값보다 더 커지게 된다.

[0069] 이와 같이 임계값의 변화량을 조절하여 새로운 임계값을 만들고 최적화된 임계값을 찾는다. 본 발명에서는 새로운 임계값과 계산 결과 값을 비교하는 과정을 거쳐 출력을 제어하는 신호 전달이 이루어진다.

[0070] 한편, 본 발명의 기술적 사상은 상기 실시 예에 따라 구체적으로 기술되었으나, 상기 실시 예는 그 설명을 위한 것이며, 그 제한을 위한 것이 아님을 주의해야 한다. 또한, 본 발명의 기술분야에서 당업자는 본 발명의 기술 사상의 범위 내에서 다양한 실시 예가 가능함을 이해할 수 있을 것이다.

부호의 설명

- [0071] 110 레이어 (111, 112)
- 120 입력 뉴런 (121, 122, 123)
- 130 시냅스 (131, 132, 133, 134, 135, 136)
- 140 입력 스파이크 (141, 142, 143, 144, 145, 146, 147, 148, 149)
- 150 출력 뉴런 (151, 152)
- 160 출력 스파이크 (161, 162, 163)

210 입력 스파이크가 발생한 시간(211,212)

220 출력 스파이크가 발생한 시간(221)

230 제 1 구간: $\Delta t > 0$


240 제 2 구간: $\Delta t \leq 0$

310 $\Delta t > 0$


320 $\Delta t \leq 0$

도면


도면1



도면2



도면3



도면4

