

[受賞者] ジョン・ジョセフ・ホップフィールド (John J. Hopfield) 氏 (アメリカ)  
ジェフリー・エヴァレスト・ヒントン (Geoffrey E. Hinton) 氏 (カナダ)

## 「人工ニューラルネットワークによる機械学習を可能にした基礎的発見と発明」について

東京理科大学 創域理工学部 情報計算科学科 教授 かつらだ こういち 桂田 浩一

### ■2024年ノーベル物理学賞について

2024年のノーベル物理学賞はジョン・ホップフィールド (John Hopfield) 氏とジェフリー・ヒントン (Geoffrey Hinton) 氏が受賞した。人工知能の中核技術の一つである深層学習の基礎を築いた業績での受賞である。これまで情報科学の分野でノーベル賞を受賞した人物はおらず、ノーベル賞とは無縁の研究分野と考えられていただけに、この受賞は驚きをもって受け止められた。ヒントン氏は受賞後のインタビューで「驚いた」と述べられていたが、これは本心からの感想なのではないかと筆者は考えている。本稿では両氏の受賞の対象となった業績について解説するとともに、現在の人工知能技術との繋がりについて述べる。

### ■ホップフィールドモデル

一般的なニューラルネットワークは【図1】に示すように、入力を与えるとネットワークを通して出力が得られるような構造である。例えばChatGPTの場合は入力としてユーザの質問文が与えられ、出力として回答が得られる。ネットワーク内には多数のノードが存在し、ノードを経由するたびに演算が行われて最終

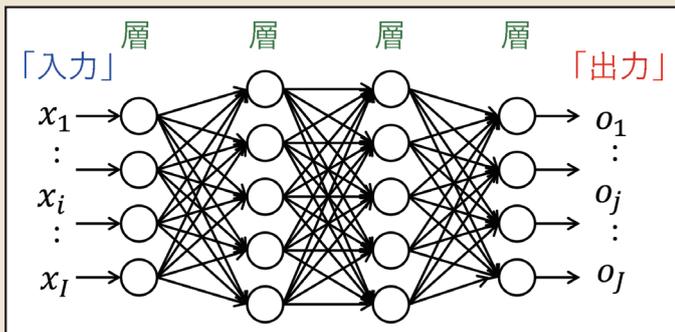
的な出力が得られる。これに対してホップフィールド氏が1982年に提案したホップフィールドモデルは、【図2】に示すような相互結合型ネットワークと呼ばれるニューラルネットワークである。ネットワーク内の各ノードに入力として適当な値を与えるとネットワーク内のノードの値が変化していき、最終的にノードの値がある値に収束する。ホップフィールドモデルのノードの間のリンクには結合荷重  $w_{j,i}$  が、ノードには閾値  $\theta_i$  が設定される。各ノード  $i$  には0もしくは1の値  $x_i$  が入力として与えられ、次式に従って  $x_i$  が更新される。

$$x_i(t+1) = \begin{cases} 1 & (\sum_{j=1}^n w_{j,i} x_j(t) > \theta_i) \\ x_i(t) & (\sum_{j=1}^n w_{j,i} x_j(t) = \theta_i) \\ 0 & (\sum_{j=1}^n w_{j,i} x_j(t) < \theta_i) \end{cases}$$

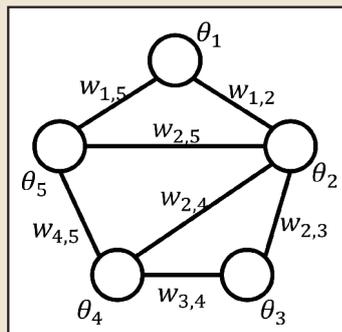
ここで  $n$  はノード数を、 $t$  は時刻を表す。時刻0から上式に従って  $x_i$  を更新し、値に変化がなくなった時点(収束した時点)で更新を停止する。その時の各ノードの値が出力となる。

ホップフィールドモデルのノード値が更新される際にはエネルギー関数と呼ばれる関数の値が常に減少し

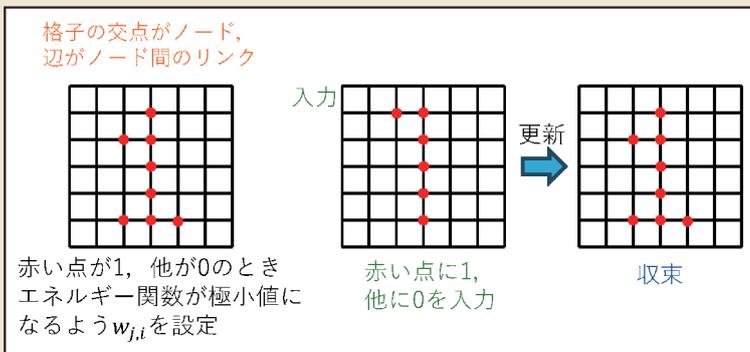
ていくという特性があり、ノード値は必ずエネルギー関数が極小となる値に収束することが示されている。この性質を利用して、特定の  $x_1^* \cdots x_n^*$  の値に収束するような  $w_{j,i}$ ,  $\theta_i$  を設定したものが、【図3】に示す連想記憶である。連想記憶ではノードの値が  $x_1^* \cdots x_n^*$  とな



【図1】一般的なニューラルネットワーク



【図2】ホップフィールドモデル



【図3】連想記憶

ときにエネルギー関数が極小値になるよう  $w_{j,i}$ ,  $\theta_i$  が設定される。その結果,  $x_1^* \cdots x_n^*$  に近い  $x_1 \cdots x_n$  を各ノードの入力として与えた場合に, エネルギー関数の小さい方向に  $x_1 \cdots x_n$  の値が更新されていき, 結果として  $x_1^* \cdots x_n^*$  を得ることができる。記憶されていた値に近い値を入力した場合に, 記憶されていた値を思い出すような挙動を示すことから, 連想記憶と呼ばれる。

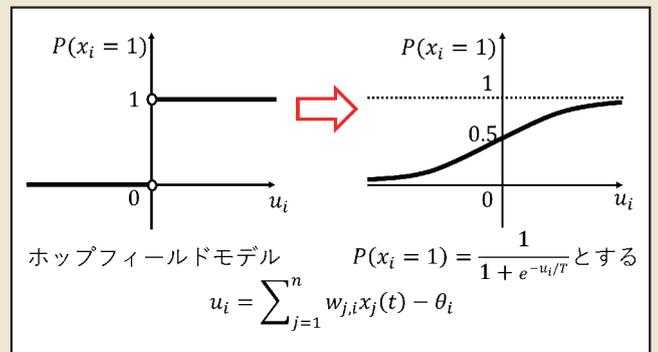
### ■ボルツマンマシン

ホップフィールドモデルは必ずエネルギー関数が小さくなる方向にノードの値が更新される。しかしこの方法ではエネルギー関数の極小値にノードの値が留まり, エネルギー関数を最小にする方向にノードの値が更新されない。これに対処するために, ヒントン氏らは  $x_i$  の更新に確率的な要素を導入することを考えた。

$$P(x_i=1) = \frac{1}{1 + e^{-(\sum_{j=1}^n w_{j,i} x_j(t) - \theta_i)/T}}$$

$P(x_i=1)$  は  $x_i$  が1になる確率を表す。  $T$  は定数である。右辺の関数はシグモイド関数と呼ばれるもので, 【図4右】の様な値を取る。ホップフィールドモデルでは【図4左】に示すように  $\sum_{j=1}^n w_{j,i} x_j(t) > \theta_i$  である時に必ず  $x_i=1$  (すなわち1になる確率が1) になるのに対し, ヒントン氏らの手法では【図4右】に示すように  $\sum_{j=1}^n w_{j,i} x_j(t) - \theta_i$  の値によってただらかに確率が変化する。これにより, エネルギー関数が大きくなる方向にノードの値が変化する可能性が生じるため, エネルギー関数は極小値に留まらず, 最小値になる方向にノードの値が更新されていくことになる。

この方法によりエネルギー関数が最小値に向かって更新されていくことになるが, 一方でエネルギー関数の値は確率的に変動して動くため, 最小値に収束することもなくなる。このときエネルギー関数は最小値を中心にボルツマン分布と呼ばれる分布を取る。このため, このネットワークはボルツマンマシンと名付けられた。世の中のデータには分布を取るものが多く存在する。例えば「あ」と発話した時の音声の波形や, 様々な猫の画像などである。ボルツマンマシンは十分



【図4】ノードの値が1に更新される確率

にノードの値を更新した時のエネルギー関数が分布を取ることから, ネットワークを「分布」を学習するために用いることをヒントン氏らは考えた。ノードの値が何らかの分布に対応するようボルツマンマシンの  $w_{j,i}$  や  $\theta_i$  を学習することで, 分布に従う様々な生成物を出力することが可能になる。このように分布に従ったデータを生成するモデルは生成モデルと呼ばれている。生成AIはこのような考え方を応用したものである。

### ■ディープラーニング

一般的なニューラルネットワークは【図1】に示したように, 入力から出力の方向にリンクが向かう構造になっており, リンクによって層と呼ばれる中間ノードの集合が形成される。このようなニューラルネットワークの学習には, 一般的に誤差逆伝播法と呼ばれる学習方法が用いられる。(ヒントン氏は誤差逆伝播法の論文の共著者にもなっている。)しかしこの方法には一つの問題が知られていた。層を多くした場合に入力に近い層では全く学習が行われず, 実質的に層の数が少ない場合と同じ性能しか得られない, という問題であった。

ヒントン氏らは相互結合型のボルツマンマシンを層が構成できるよう改良した上で, 誤差逆伝播法を使わない学習方法を用いることにより, 層の数が多くても学習が進む方法を提案した。これにより層の数が深い学習(深層学習:ディープラーニング)が可能になり, その後の深層学習の発展への道筋を開いた。また, ヒントン氏らは深層学習が画像処理の分野において高い性能を示すことも明らかにした。

### ■おわりに

深層学習は様々な分野において活用されており, 現代社会において必要不可欠なものになりつつある。この点においてもホップフィールド氏とヒントン氏の業績はノーベル賞受賞に値するといえる。情報科学は発展の著しい分野であることから, 今後も後続の研究者が同様の賞を受賞することを期待したい。