DEEP LEARNING INSTITUTE

第93回お試しアカウント付き並列プログラミング講習会
「REEDBUSH スパコンを用いたGPUディープラーニング入門」

ディープラーニング基礎

山崎和博
NVIDIA, ディープラーニング ソリューションアーキテクト

AGENDA

ディープラーニングとは

ディープラーニングの基本と処理の流れ

ディープラーニングを支えるソフトウェア

本日使用するフレームワーク:
Chainer&ChainerMN

ディープラーニングとは

ディープラーニングは機械学習の一分野

ディープラーニングとは

多数の層から構成されるニューラルネットワークがベース

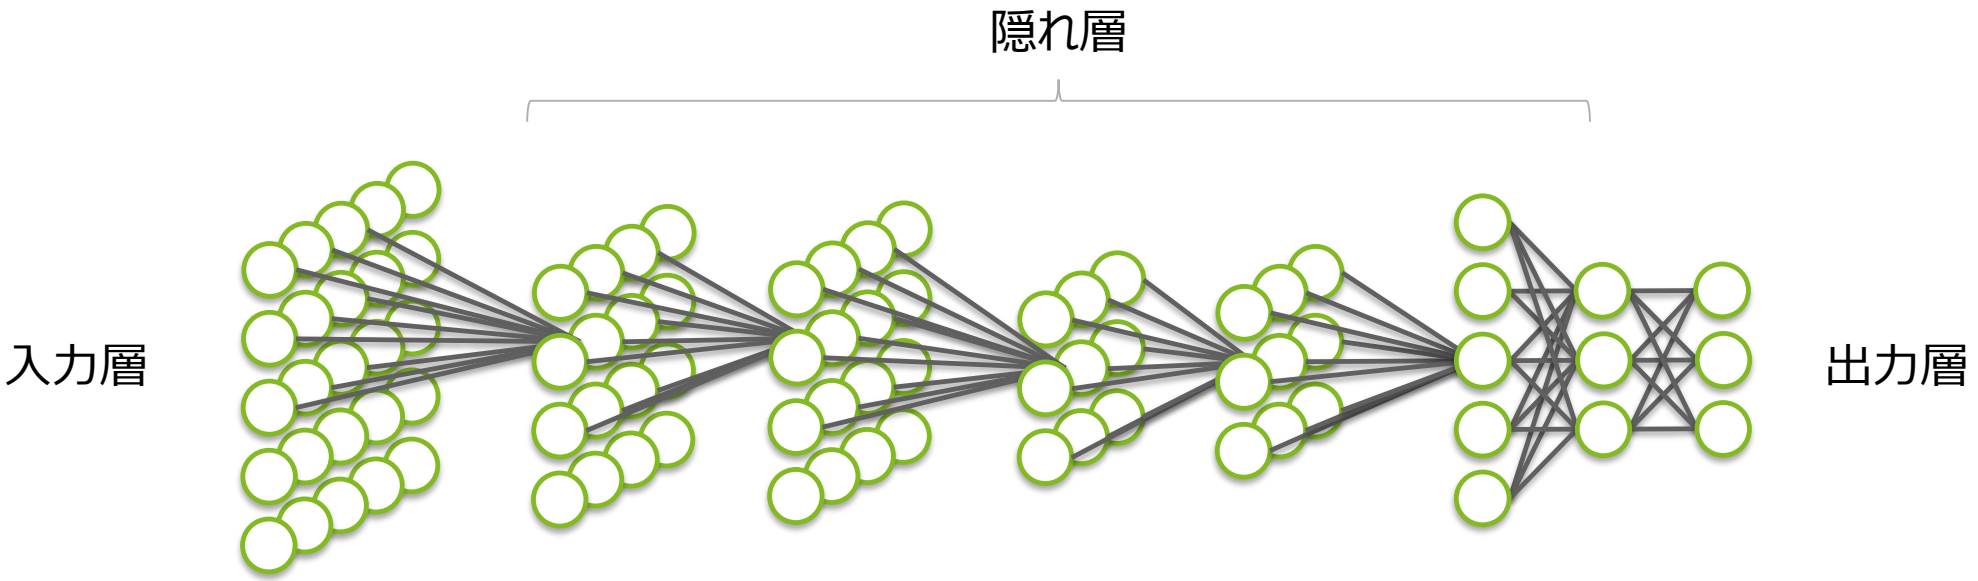

十分なトレーニングデータを与え学習させることで
複雑な問題を解くことができるようになる

ディープラーニングを加速する3つの要因

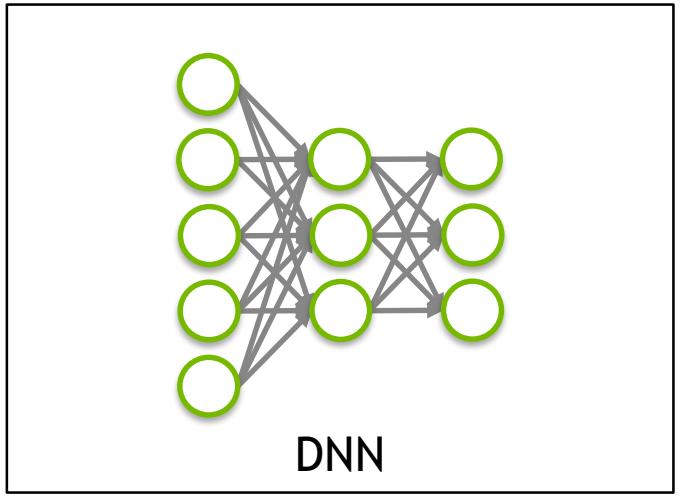

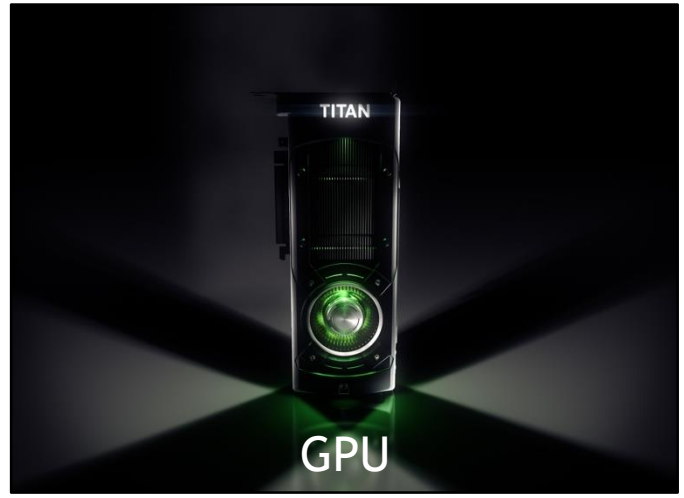

“Google’s AI engine also reflects how the world of computer hardware is changing. (It) depends on machines equipped with GPUs… And it depends on these chips more than the larger tech universe realizes.”

WIRED

ディープラーニングの基本と処理の流れ

人工ニューラルネットワーク

基本単位

人工ニューロン（パーセプトロン）

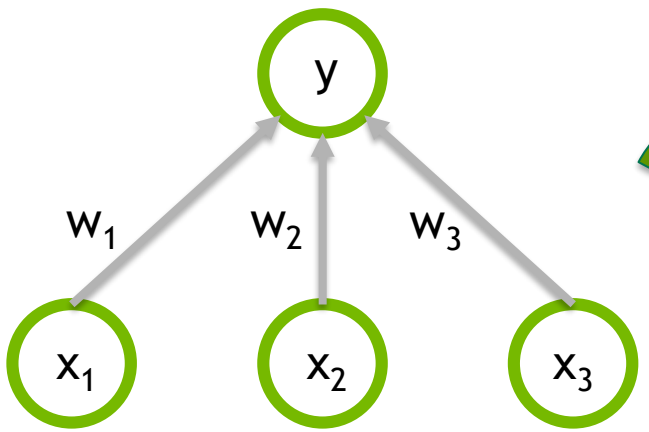

$y=w_1x_1+w_2x_2+w_3x_3$

人工ニューロンを
たくさんの層として組み合わせる

各層にそれぞれ
重みパラメータを持つ

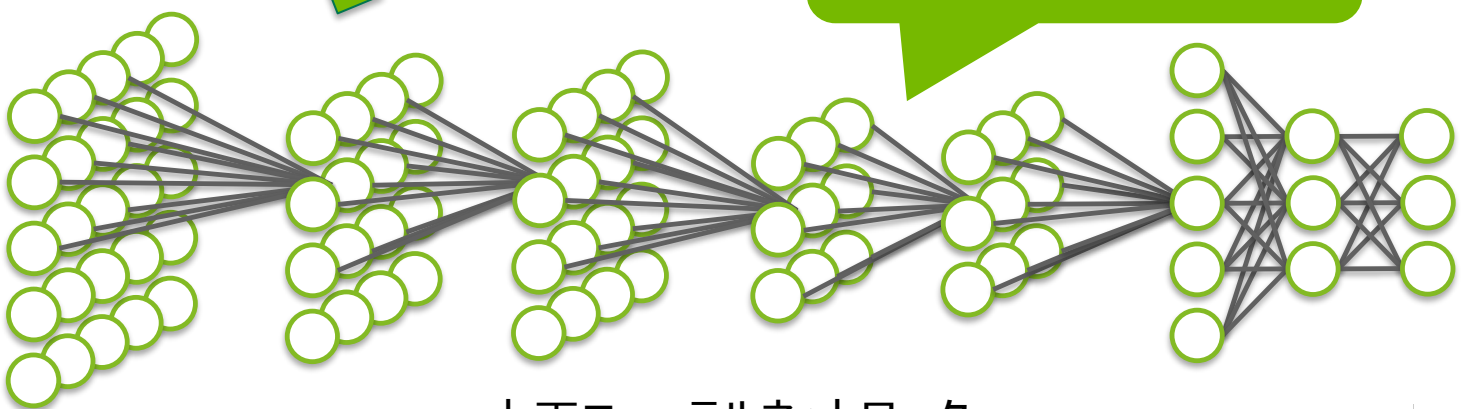

人工ニューラルネットワーク

人工ニューラルネットワーク

活性化関数

人工ニューロン（パーセプトロン）

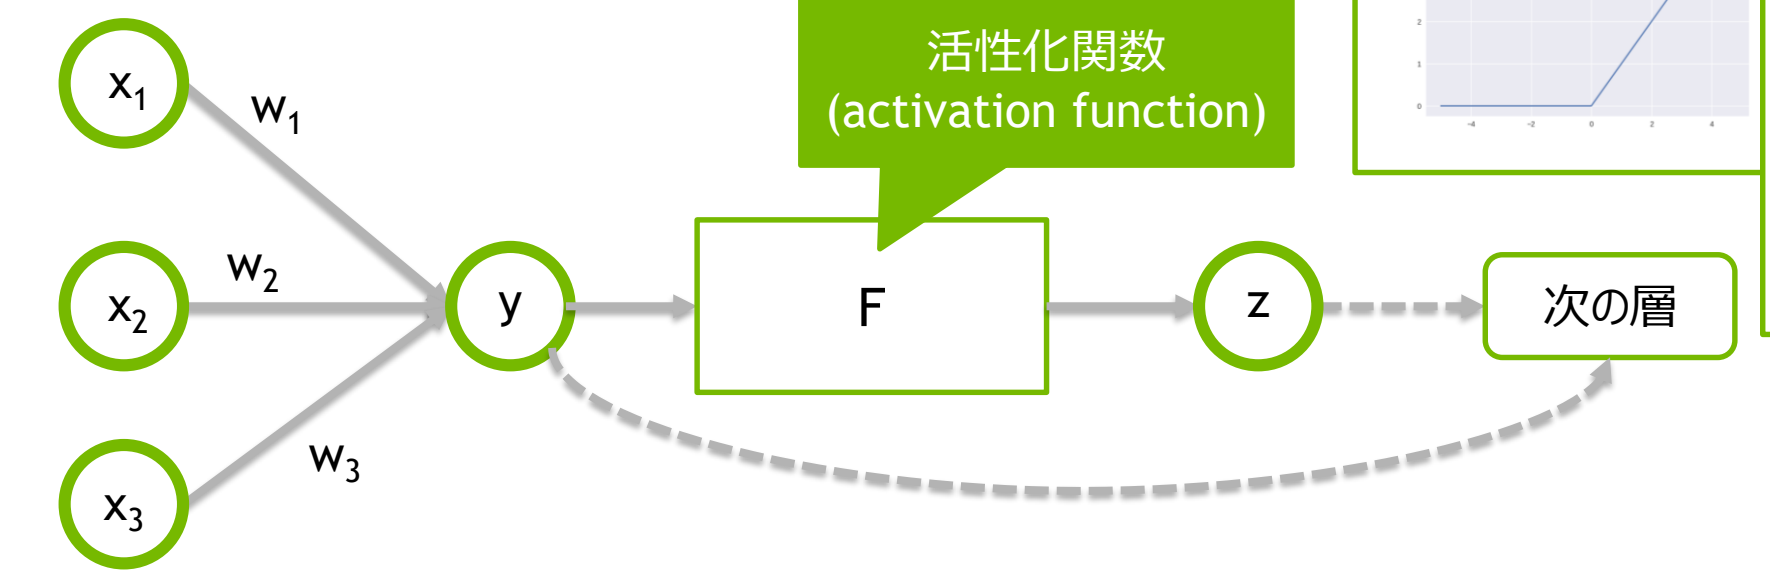

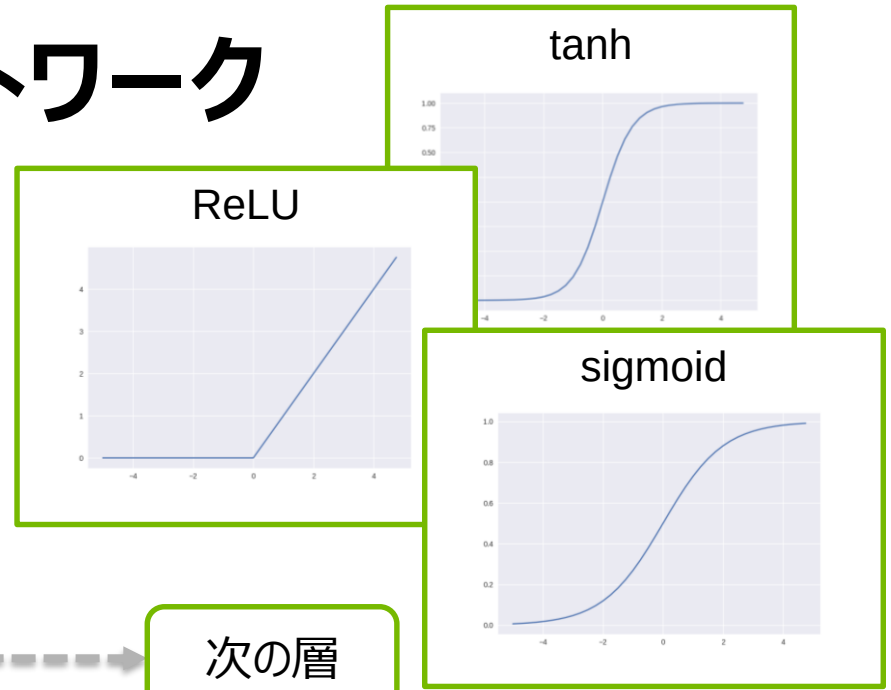

$y=w_1x_1+w_2x_2+w_3x_3$

$z=F(y)$

F: activation function

人工ニューラルネットワーク

基本構造のまとめ

各ユニット（ノードとも）の出力は、
各層の重みと積算され次の層へ

活性化関数

各ノードは
入力された値を合計して出力

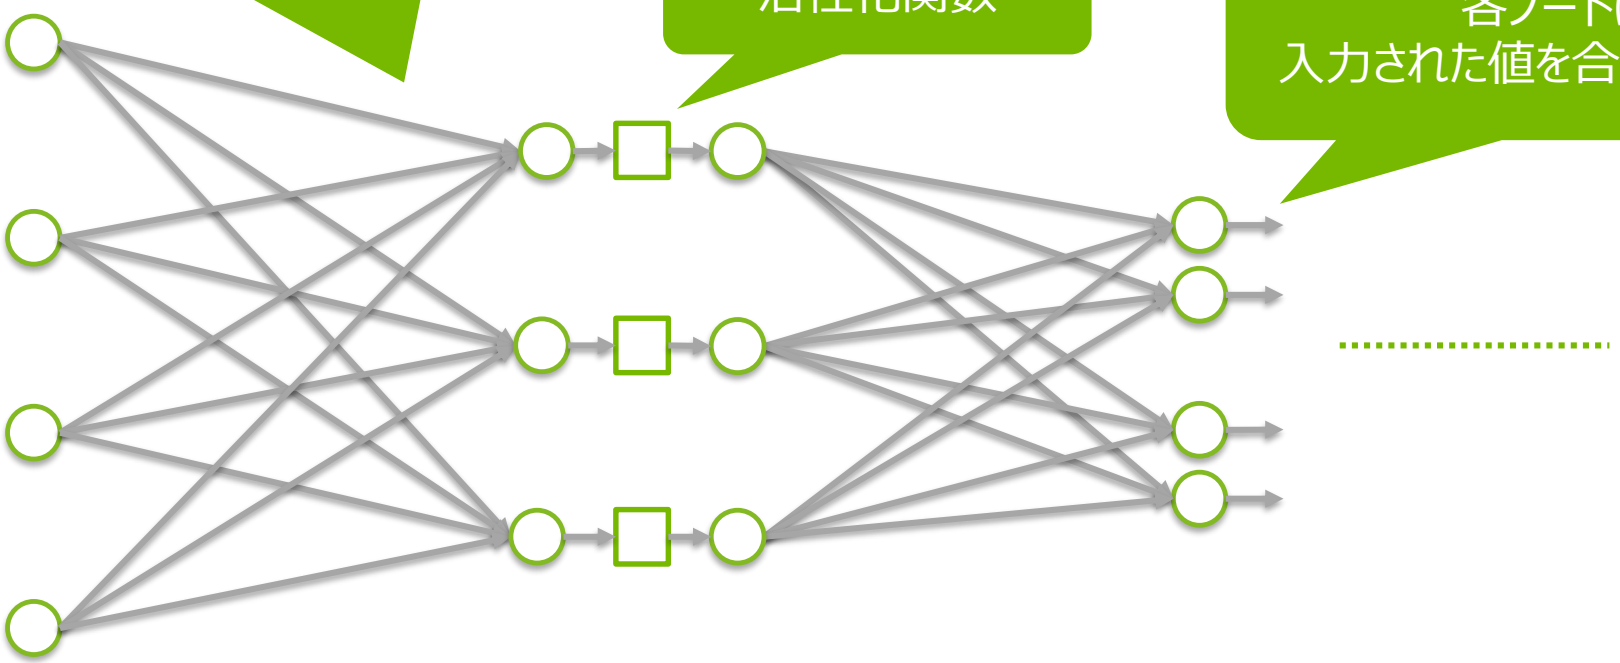

人工ニューラルネットワーク

基本構造のまとめ

各ユニット（ノードとも）の出力は、
各層の重みと積算され次の層へ

活性化関数

各ノードは
入力された値を合計して出力

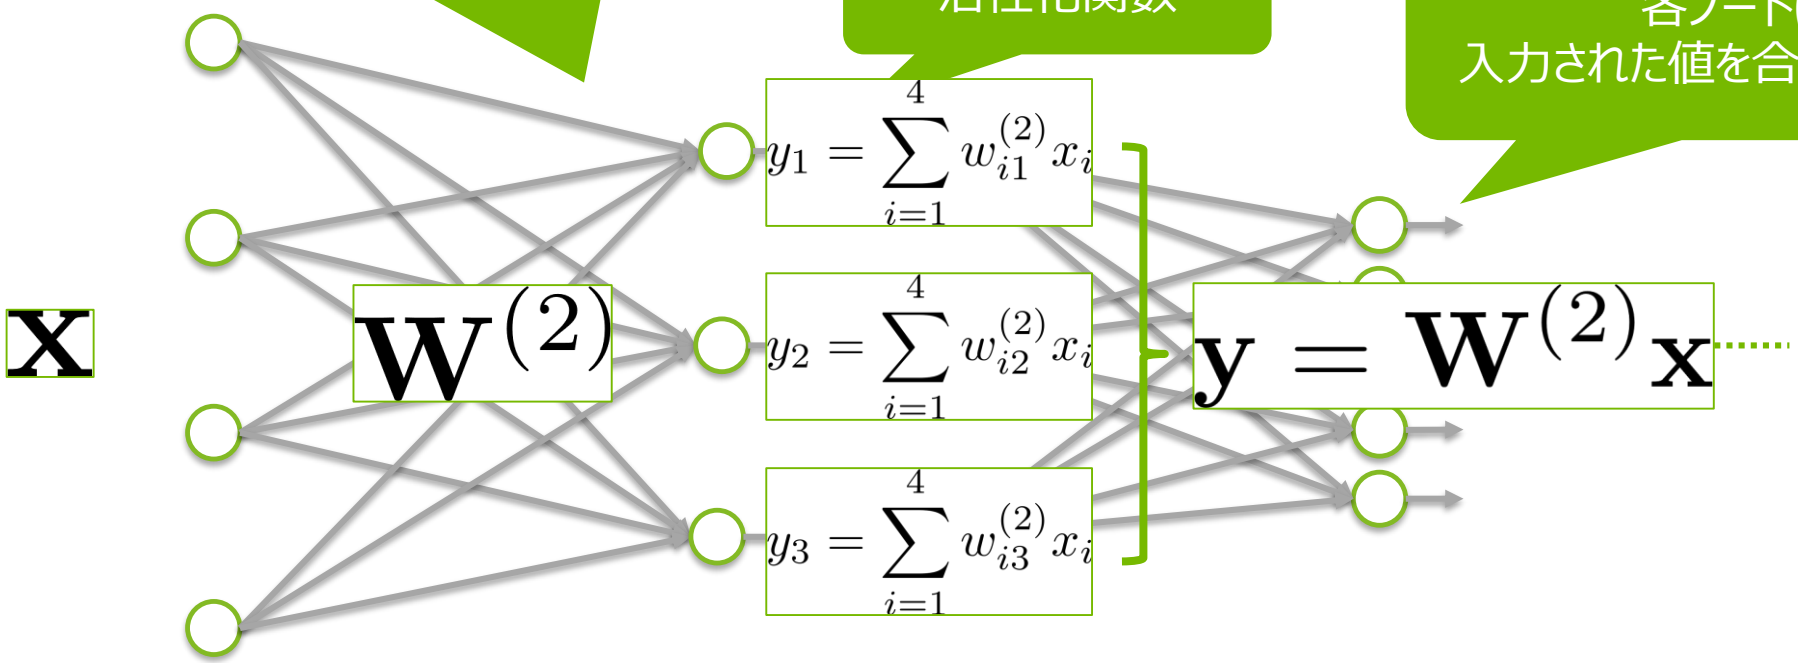

ディープラーニングの2つのフェーズ

学習(training):

フィードバックにより
重みを調整

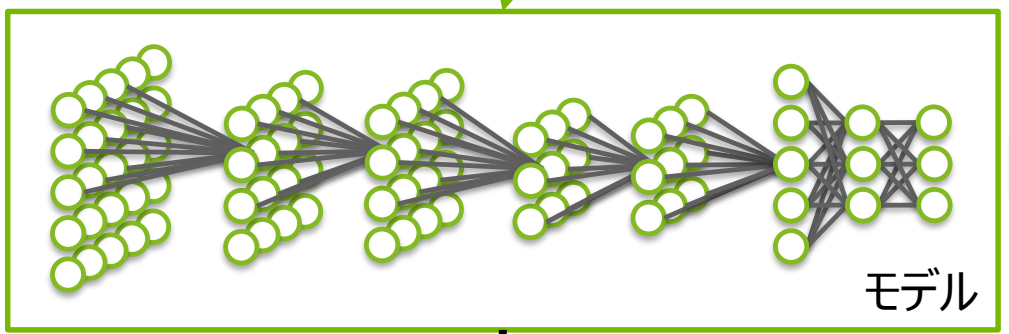

猫 ✓
犬 ✓
狸 ✗

学習した結果を用いる

推論(inference):

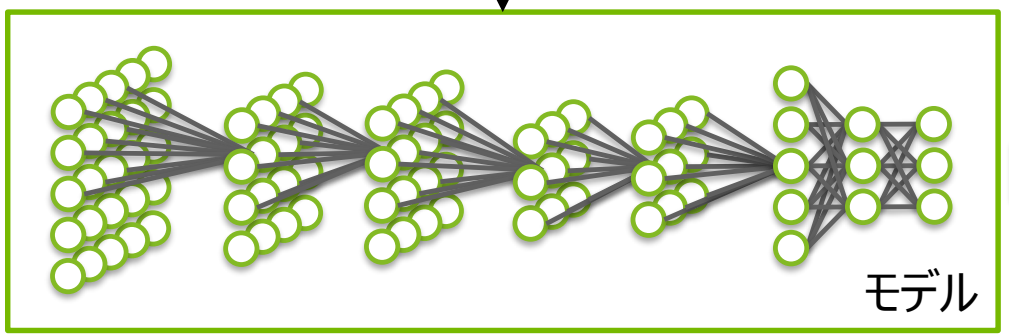

犬 ✓

ディープラーニングの学習フロー

トレーニングデータ

4.誤差が小さくなるまで繰り返す

1.入力されたデータにしたがい結果を出力

出力

“tiger”

3.誤差を用いてネットワークを更新

2.期待結果との違いを誤差として計算

誤差

正解ラベル

“lion”

ディープラーニングの学習フロー

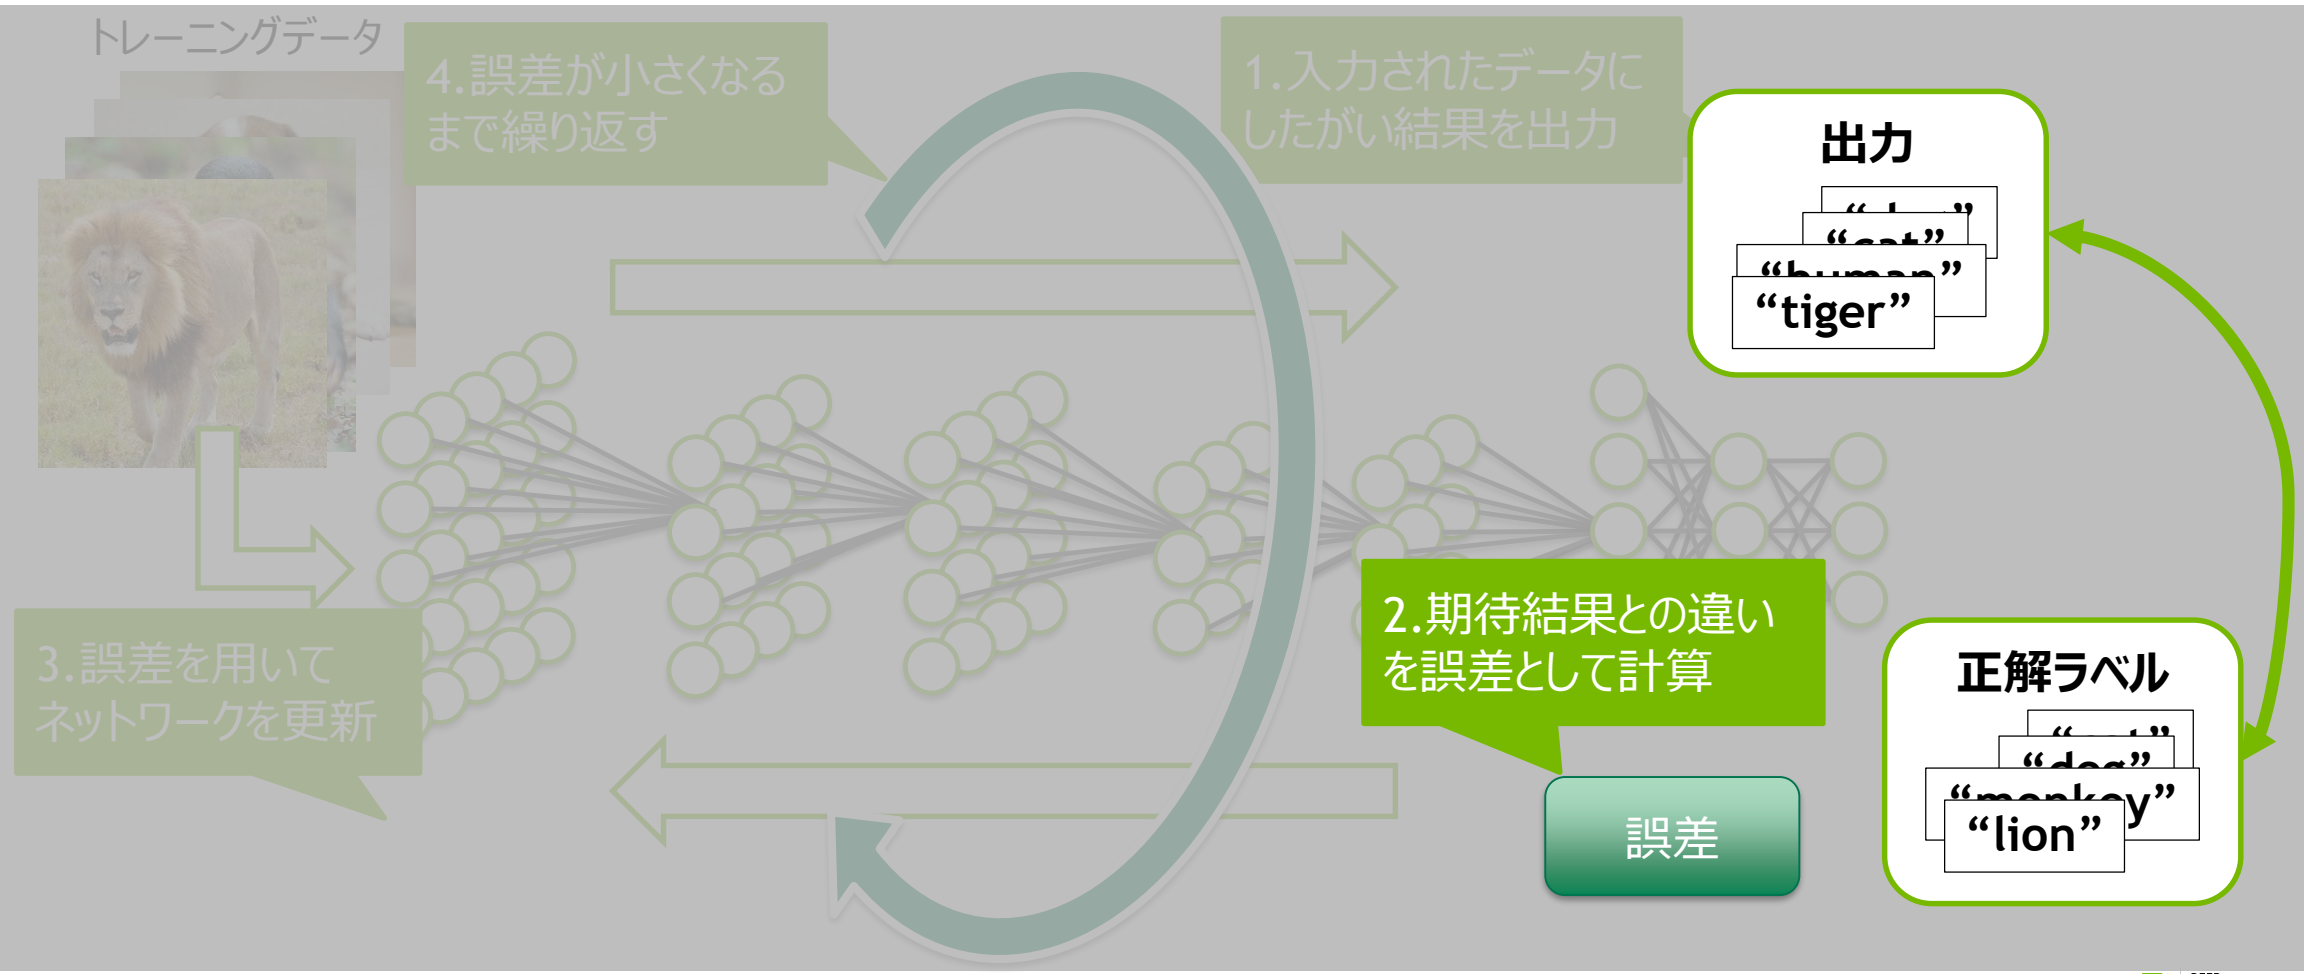

誤差の計算

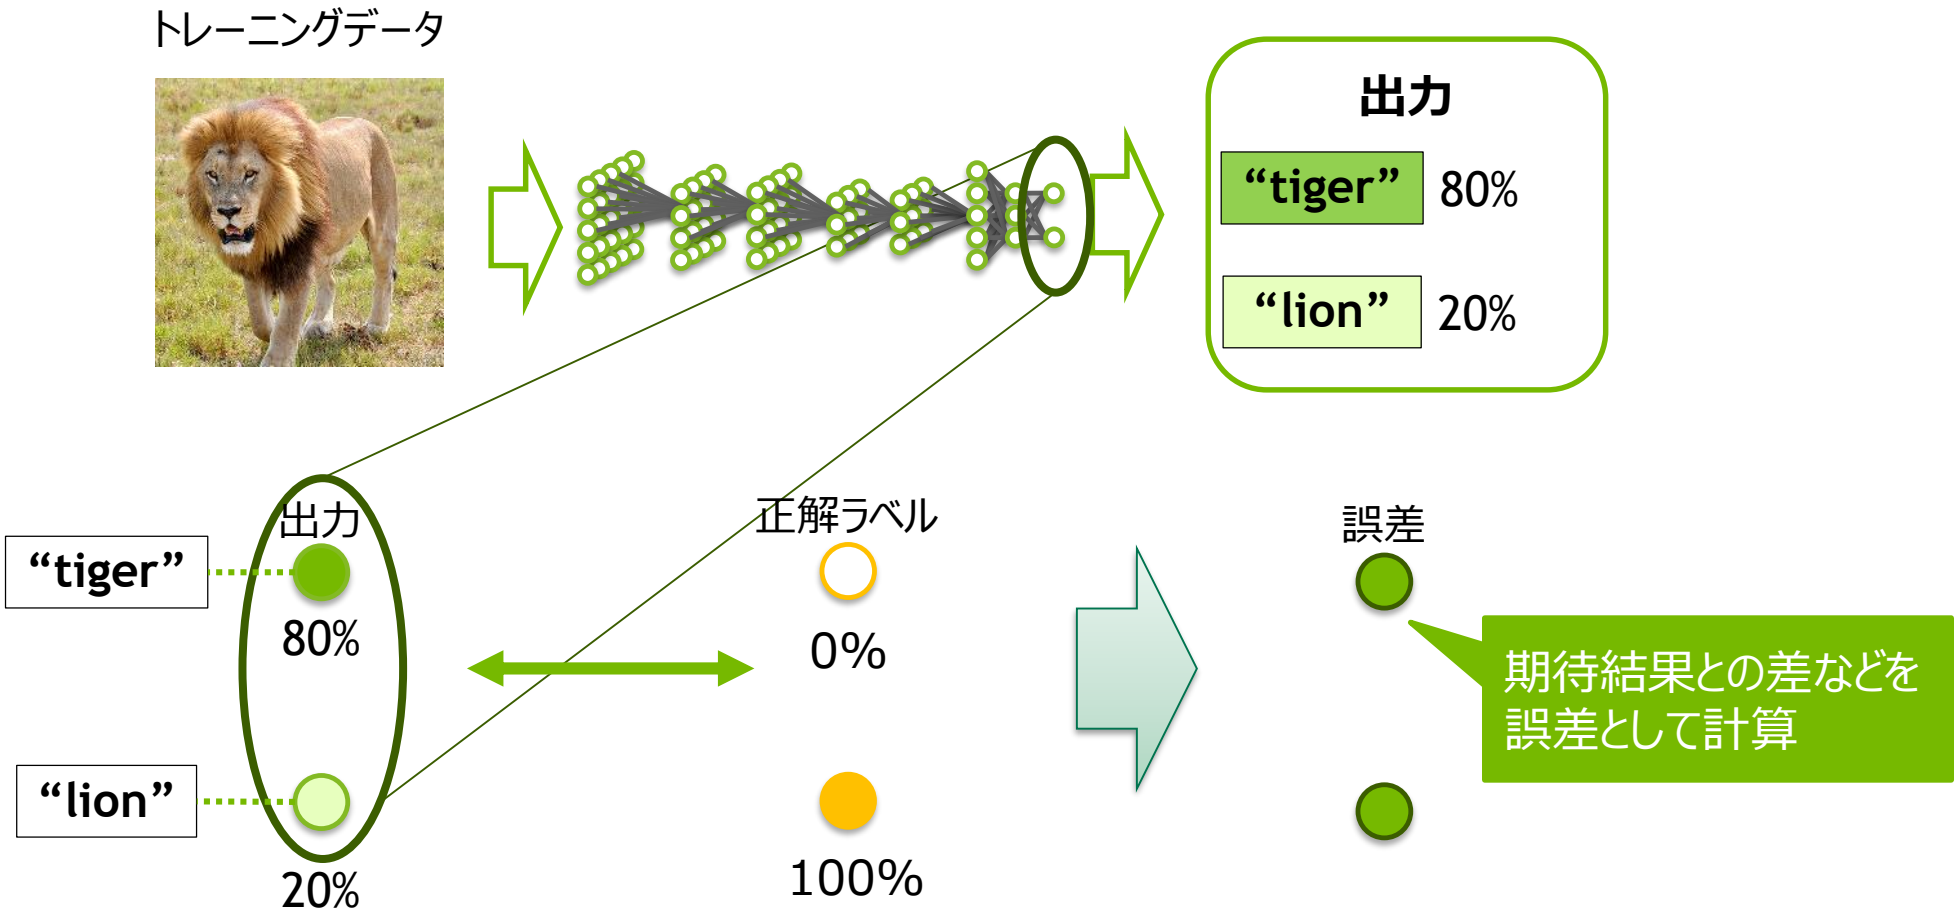

誤差の計算

トレーニングデータ

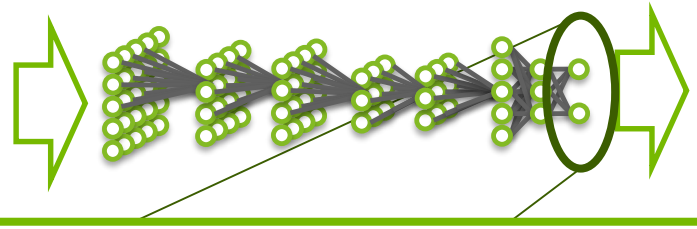

出力

“tiger” 80%

“lion” 20%

誤差の例: 交差エントロピー(cross entropy)

$$E = -\left(d_1 \log z_1(\mathbf{x}) + d_2 \log z_2(\mathbf{x})\right)$$

d_1 : 入力がtigerかを示す正解(0 or 1)　d_2 : 入力がlionかを示す正解(0 or 1)

$z_1(\mathbf{x})$: 入力がtigerと予測した確率　$z_2(\mathbf{x})$: 入力がlionと予測した確率

ディープラーニングの学習フロー

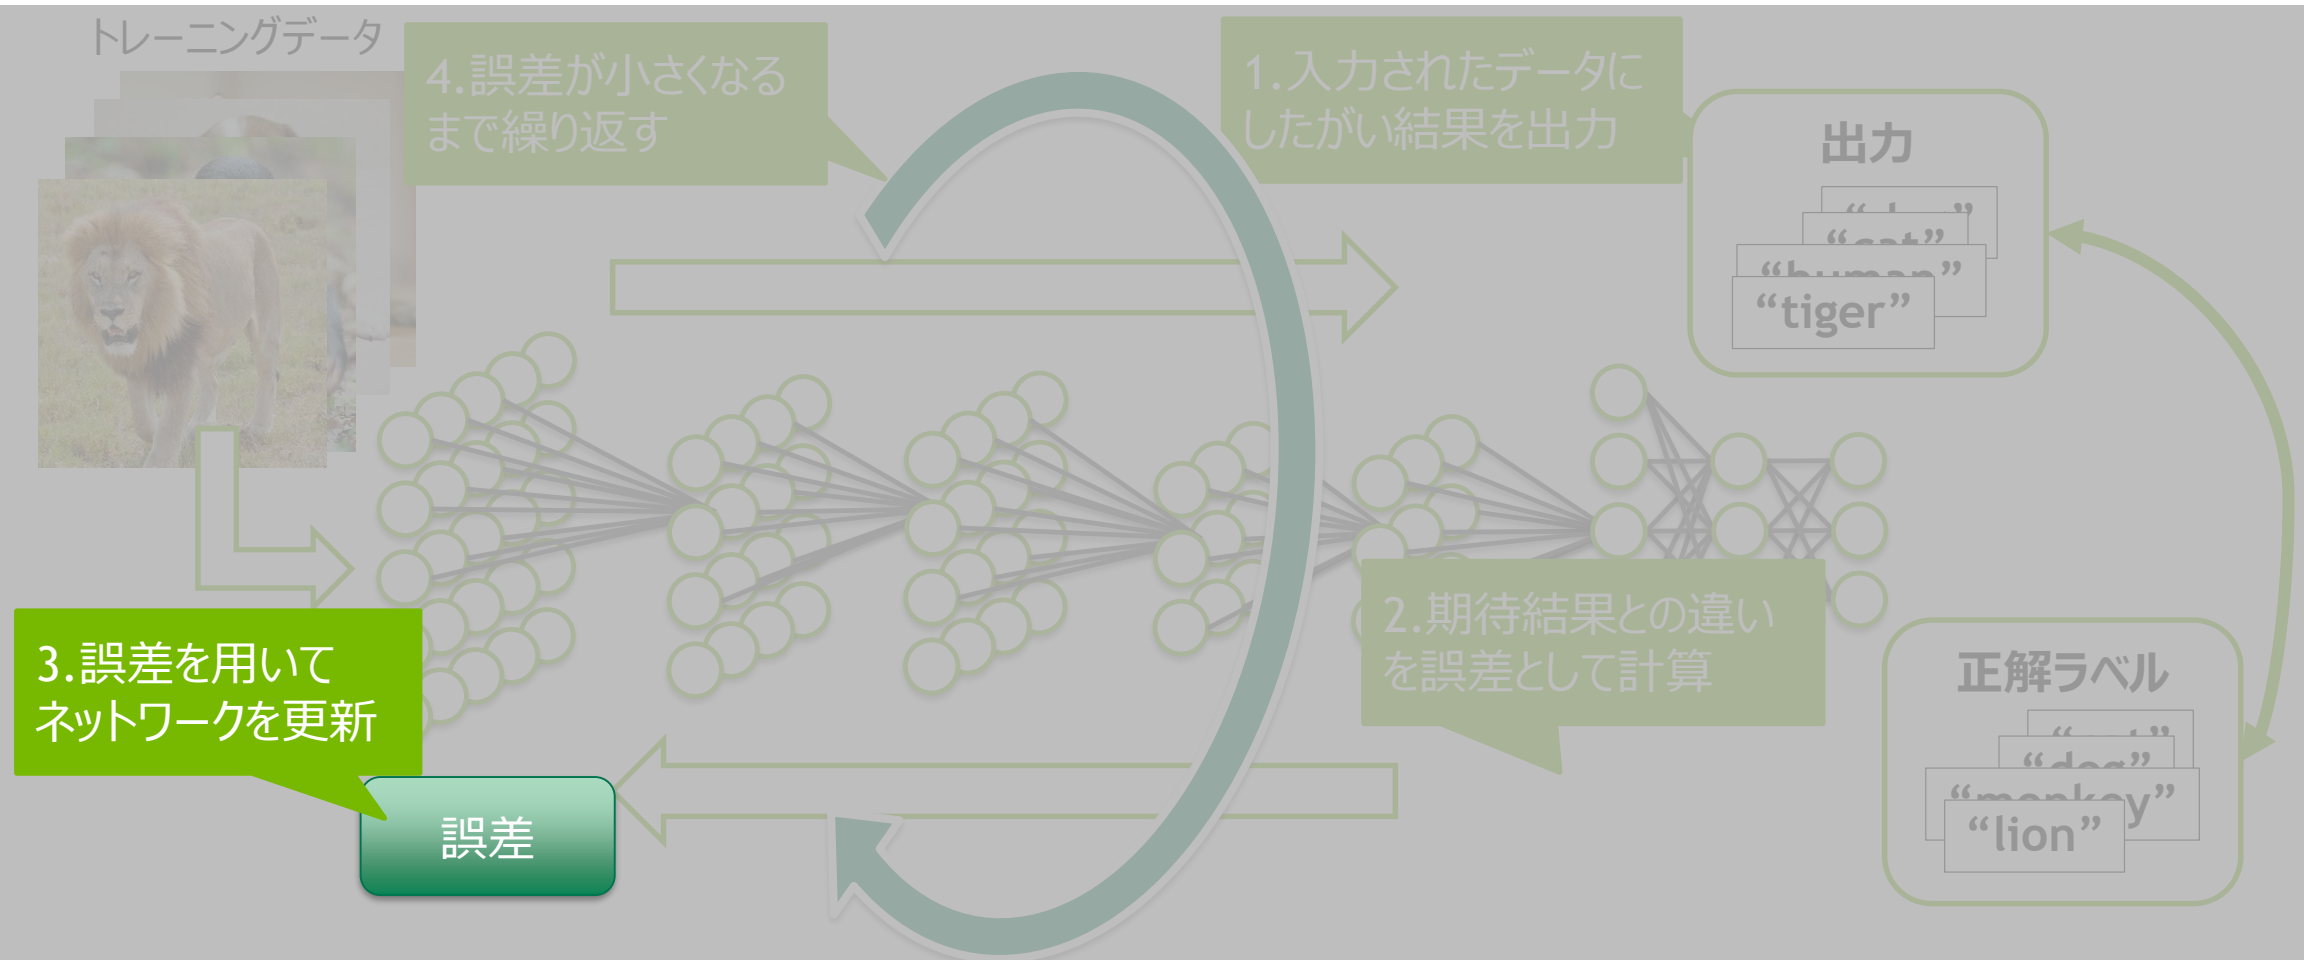

重み更新

勾配降下法による更新

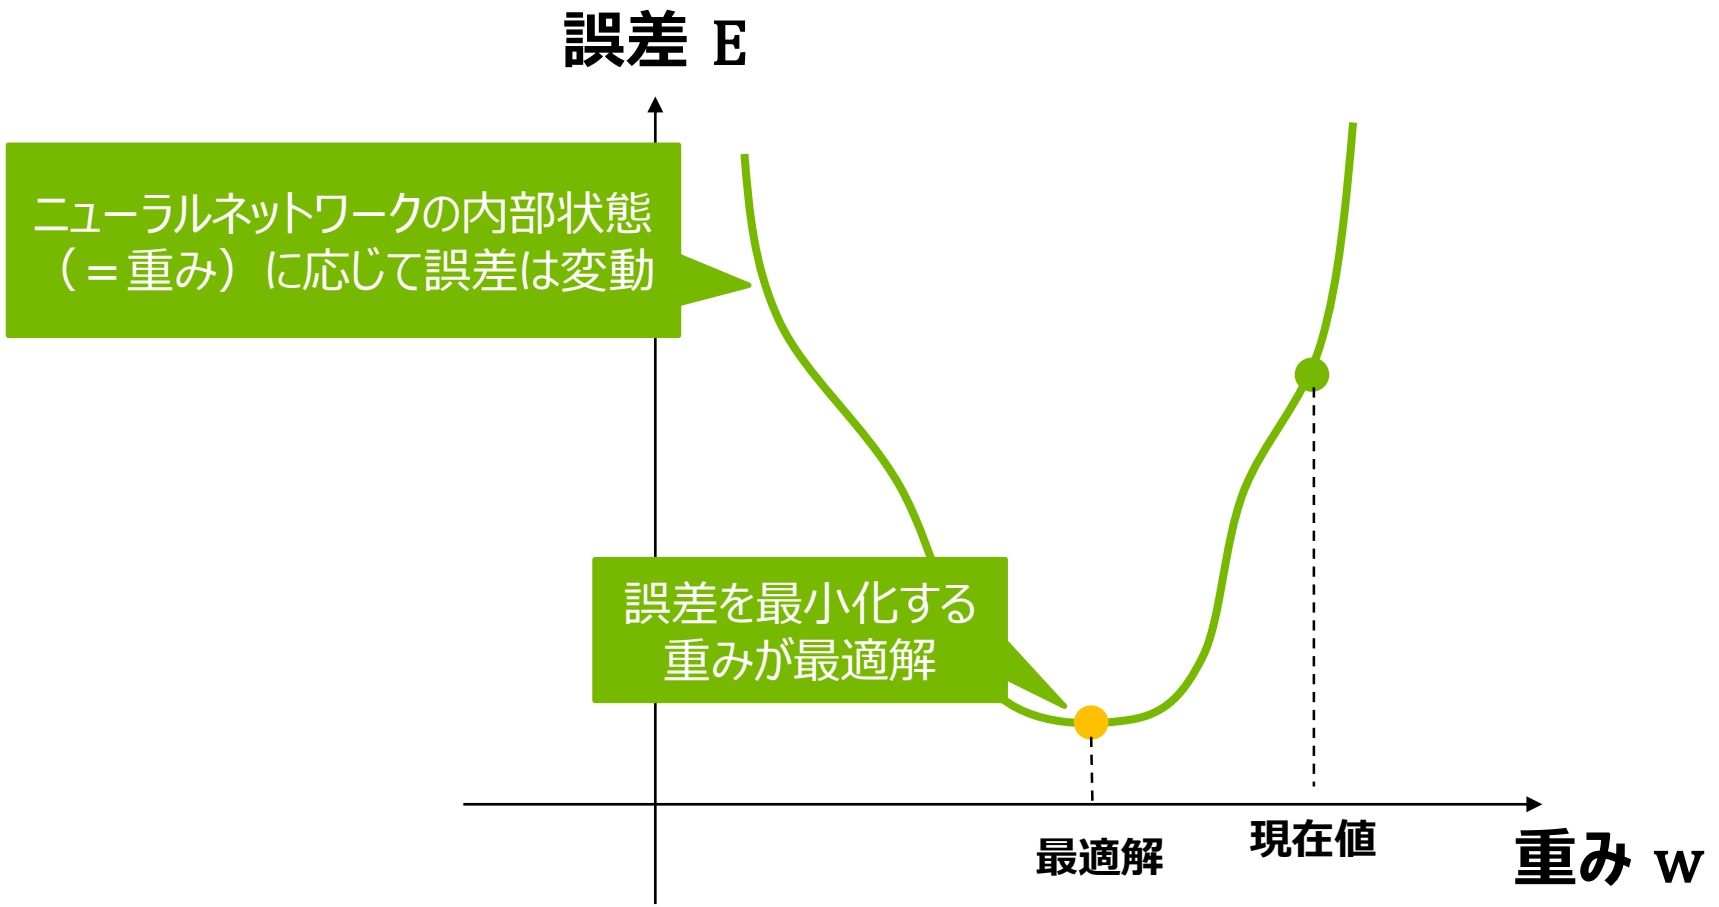

重み更新

勾配降下法による更新

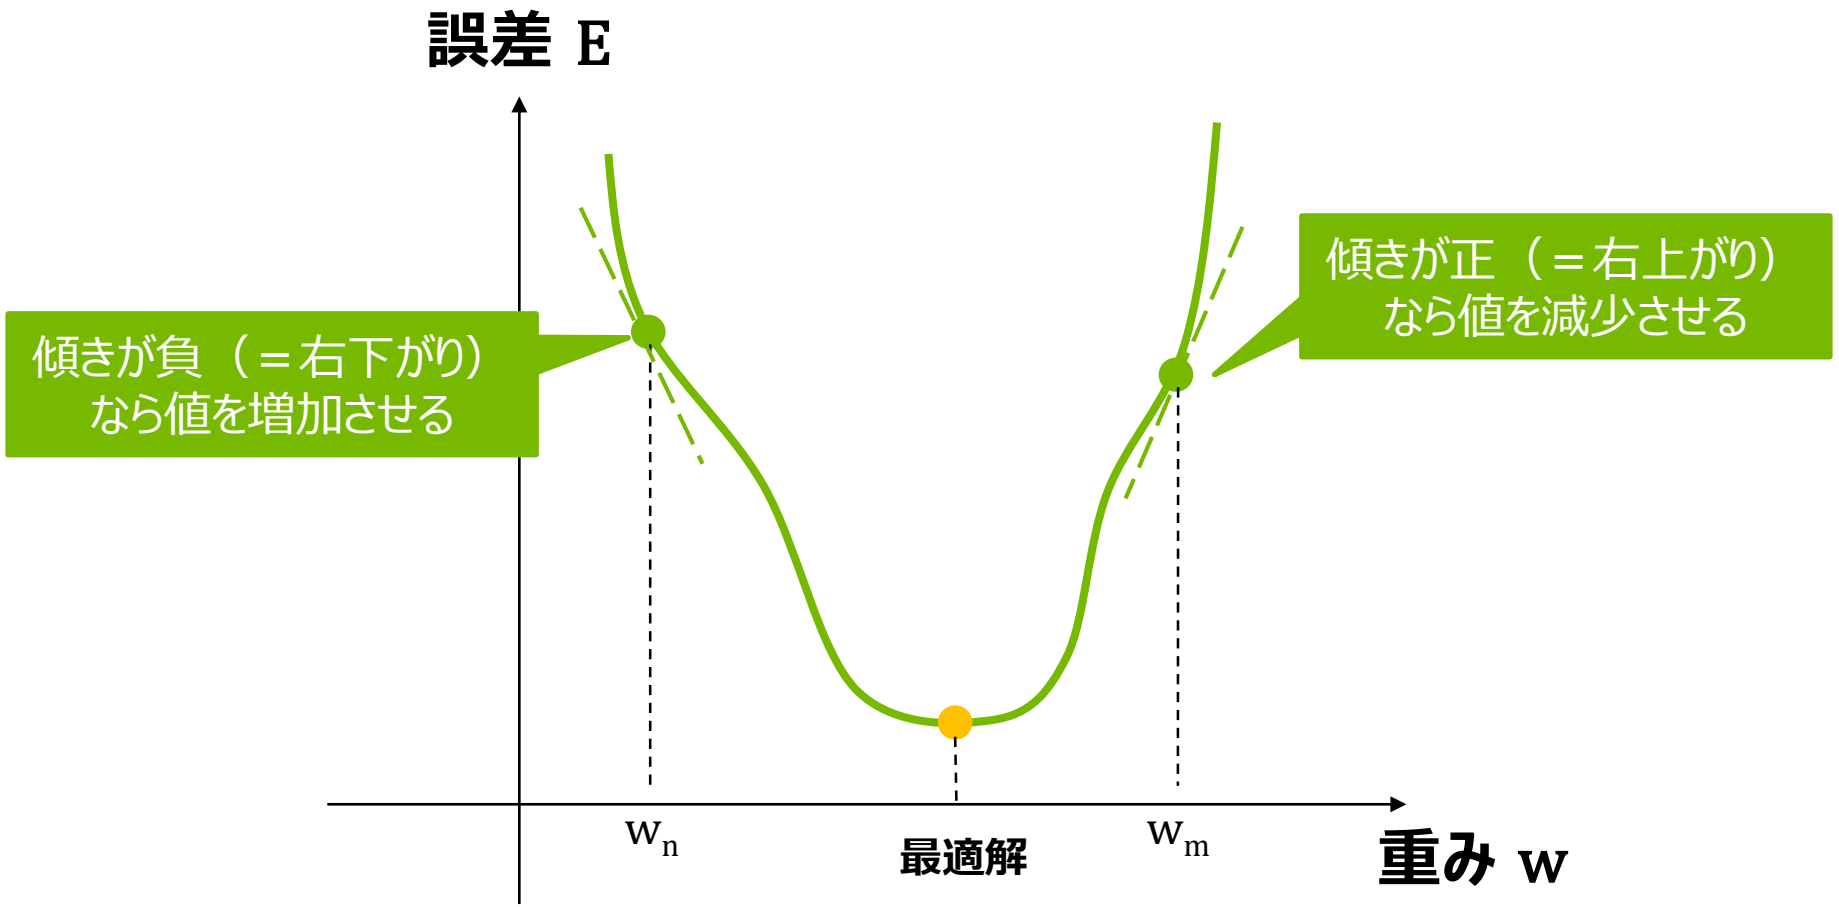

重み更新

勾配降下法による更新

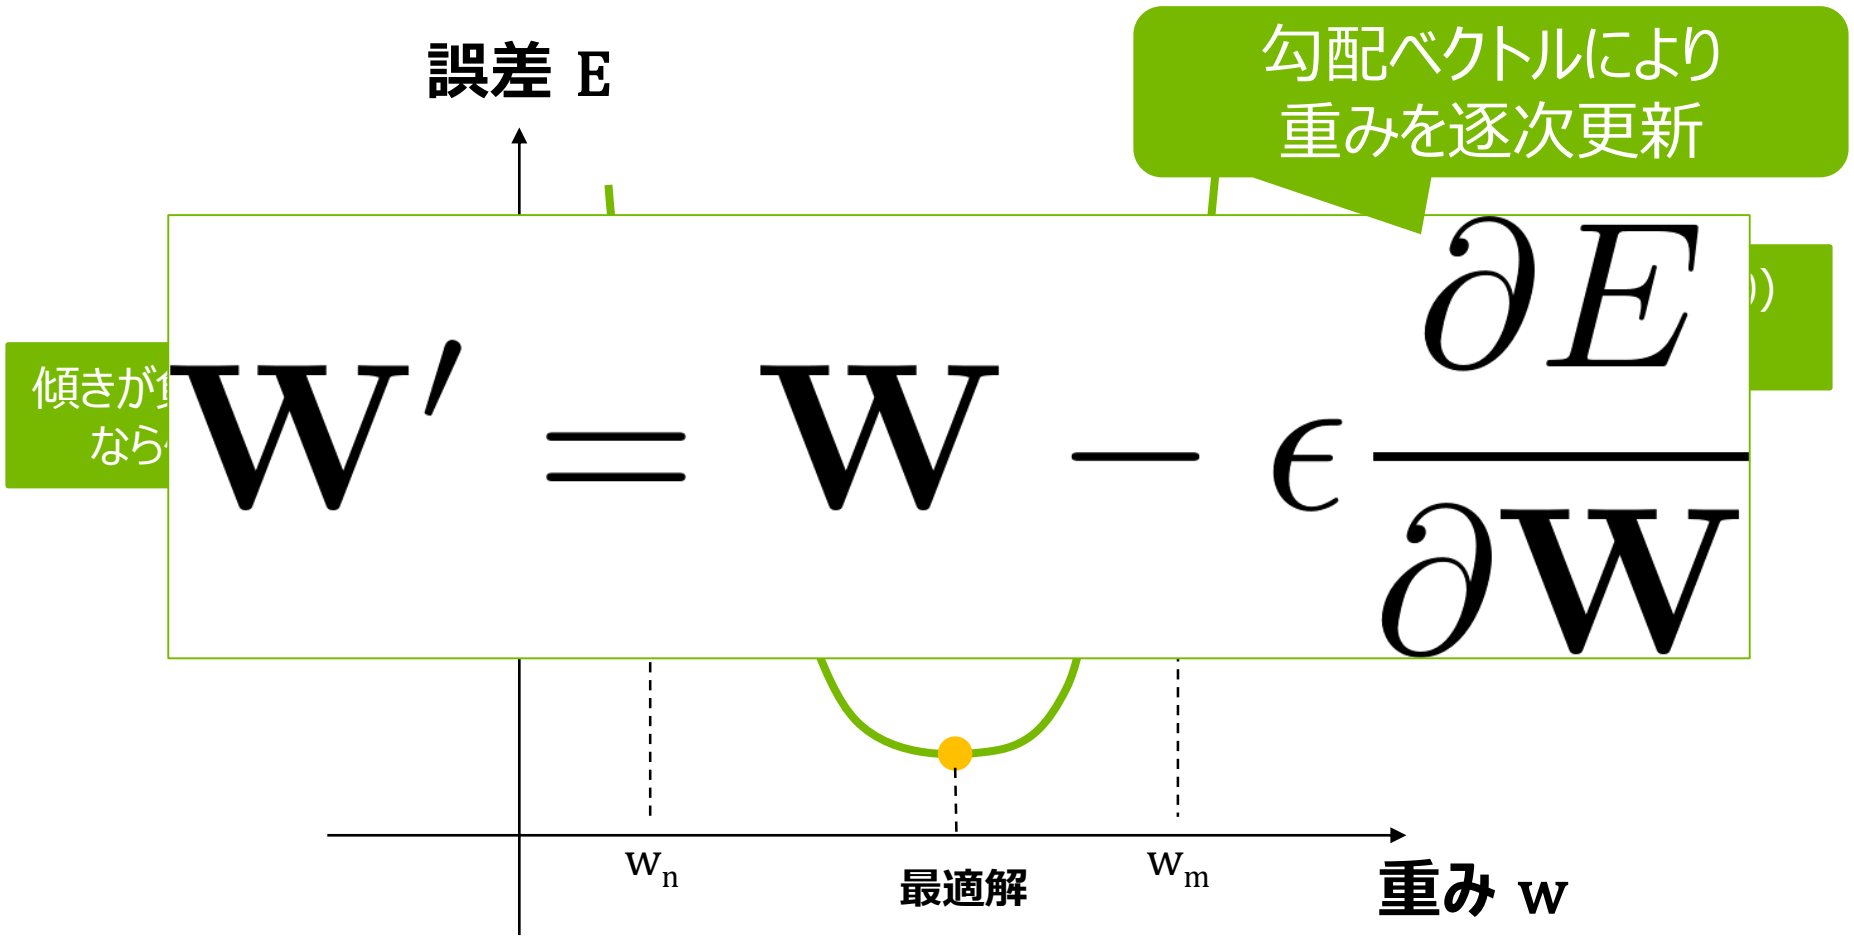

ディープラーニングの学習フロー

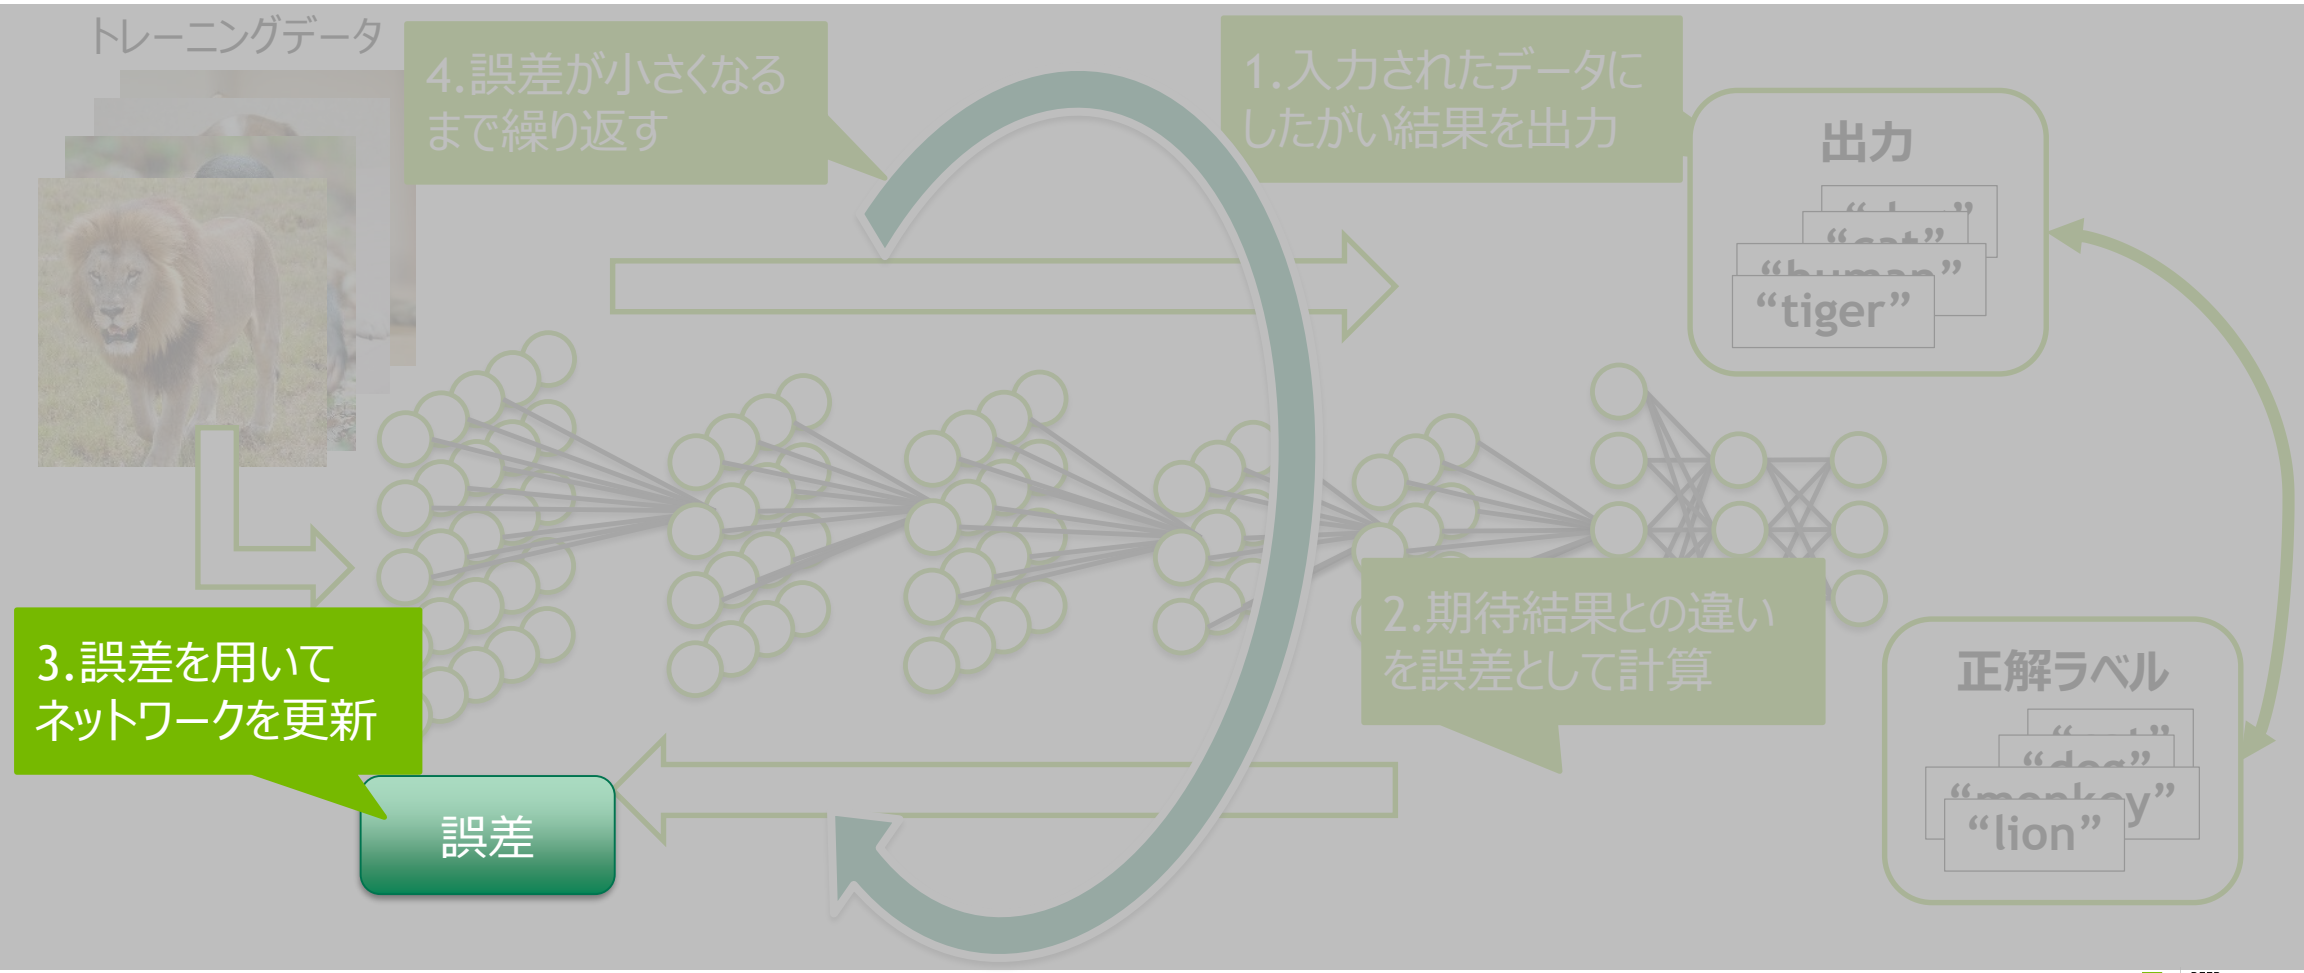

誤差逆伝播法

$w_{ji}^{(l)}$ を更新したい

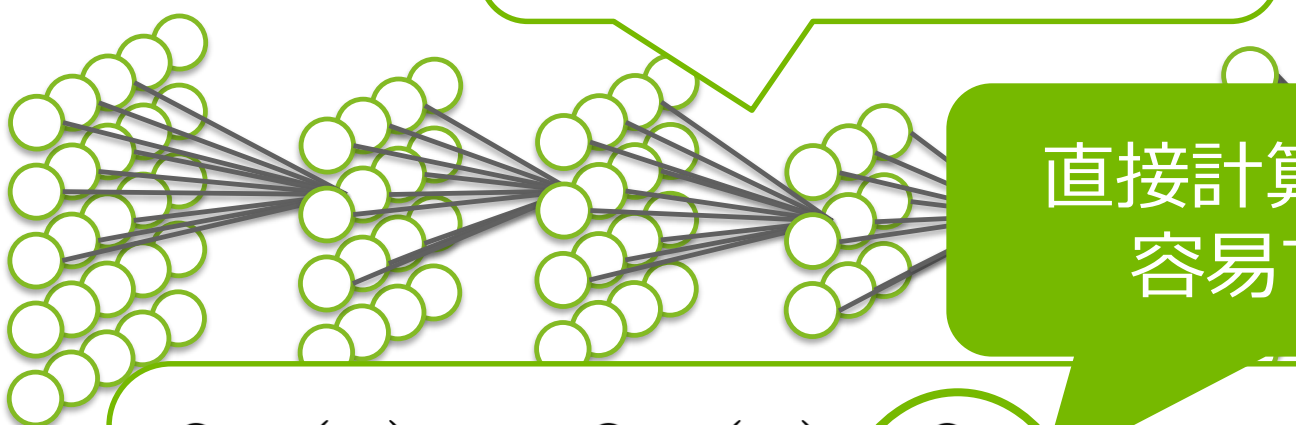

直接計算することが
容易ではない

$$\frac{\partial E(\mathbf{z})}{\partial w_{ji}^{(l)}} = \frac{\partial E(\mathbf{z})}{\partial \mathbf{z}} \frac{\partial \mathbf{z}}{\partial w_{ji}^{(l)}}$$ が必要

誤差逆伝播法

$$\frac{\partial E(\mathbf{z})}{\partial w_{ji}^{(l)}} = \frac{\partial E(\mathbf{z})}{\partial \mathbf{z}} \frac{\partial \mathbf{z}}{\partial w_{ji}^{(l)}}$$ を直接考えるのではなく、

$$\frac{\partial E}{\partial w_{ji}^{(l)}} = \frac{\partial E}{\partial y_j^{(l)}} \frac{\partial y_j^{(l)}}{\partial w_{ji}^{(l)}}$$ を考える

誤差逆伝播法

$w_{ji}^{(l)}$ は $y_j^{(l)} = \sum_i w_{ji}^{(l)} z_i^{(l-1)}$ としてのみ出現するので

$$\frac{\partial E}{\partial w_{ji}^{(l)}} = \frac{\partial E}{\partial y_j^{(l)}} \frac{\partial y_j^{(l)}}{\partial w_{ji}^{(l)}} = \frac{\partial E}{\partial y_j^{(l)}} z_i^{(l-1)}$$

とできる

誤差逆伝播法

$w_{ji}^{(l)}$ を更新したい

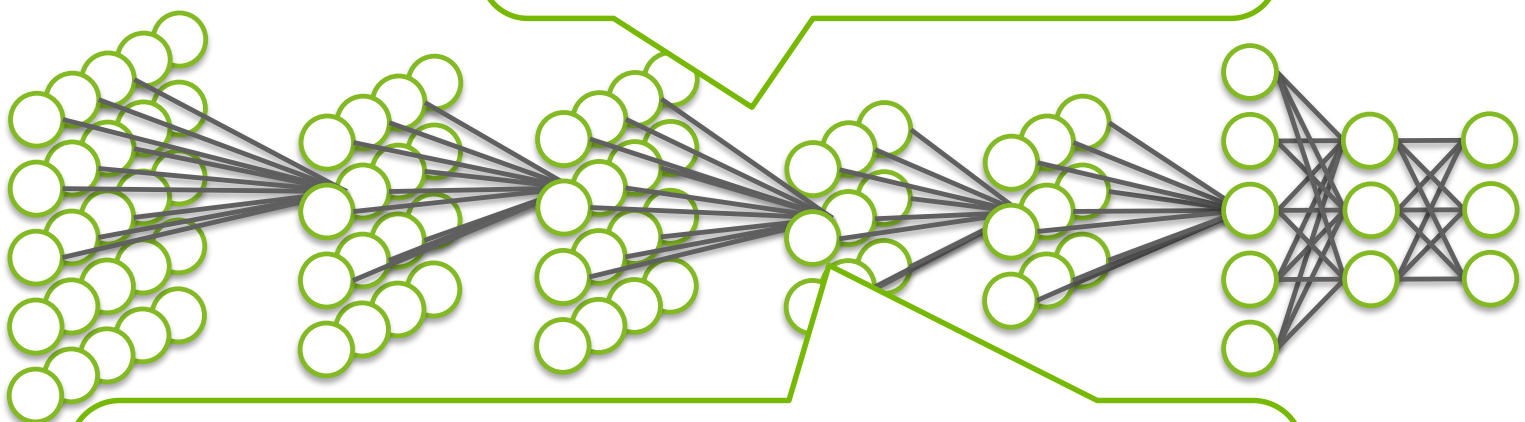

$y_j^{(l)}$ は次の層の複数要素に影響

誤差逆伝播法

いろいろ計算すると、

$$\frac{\partial E}{\partial y_j^{(l)}} = \sum_k \frac{\partial E}{\partial y_k^{(l+1)}} \frac{\partial y_k^{(l+1)}}{\partial y_j^{(l)}}$$

$$= \sum_k \frac{\partial E}{\partial y_k^{(l+1)}} \left(w_{kj}^{(l+1)} F'(y_j^{(l)}) \right)$$ となる。

処理対象層の
情報なので計算可能

繰り返し処理により
計算可能

誤差逆伝播法

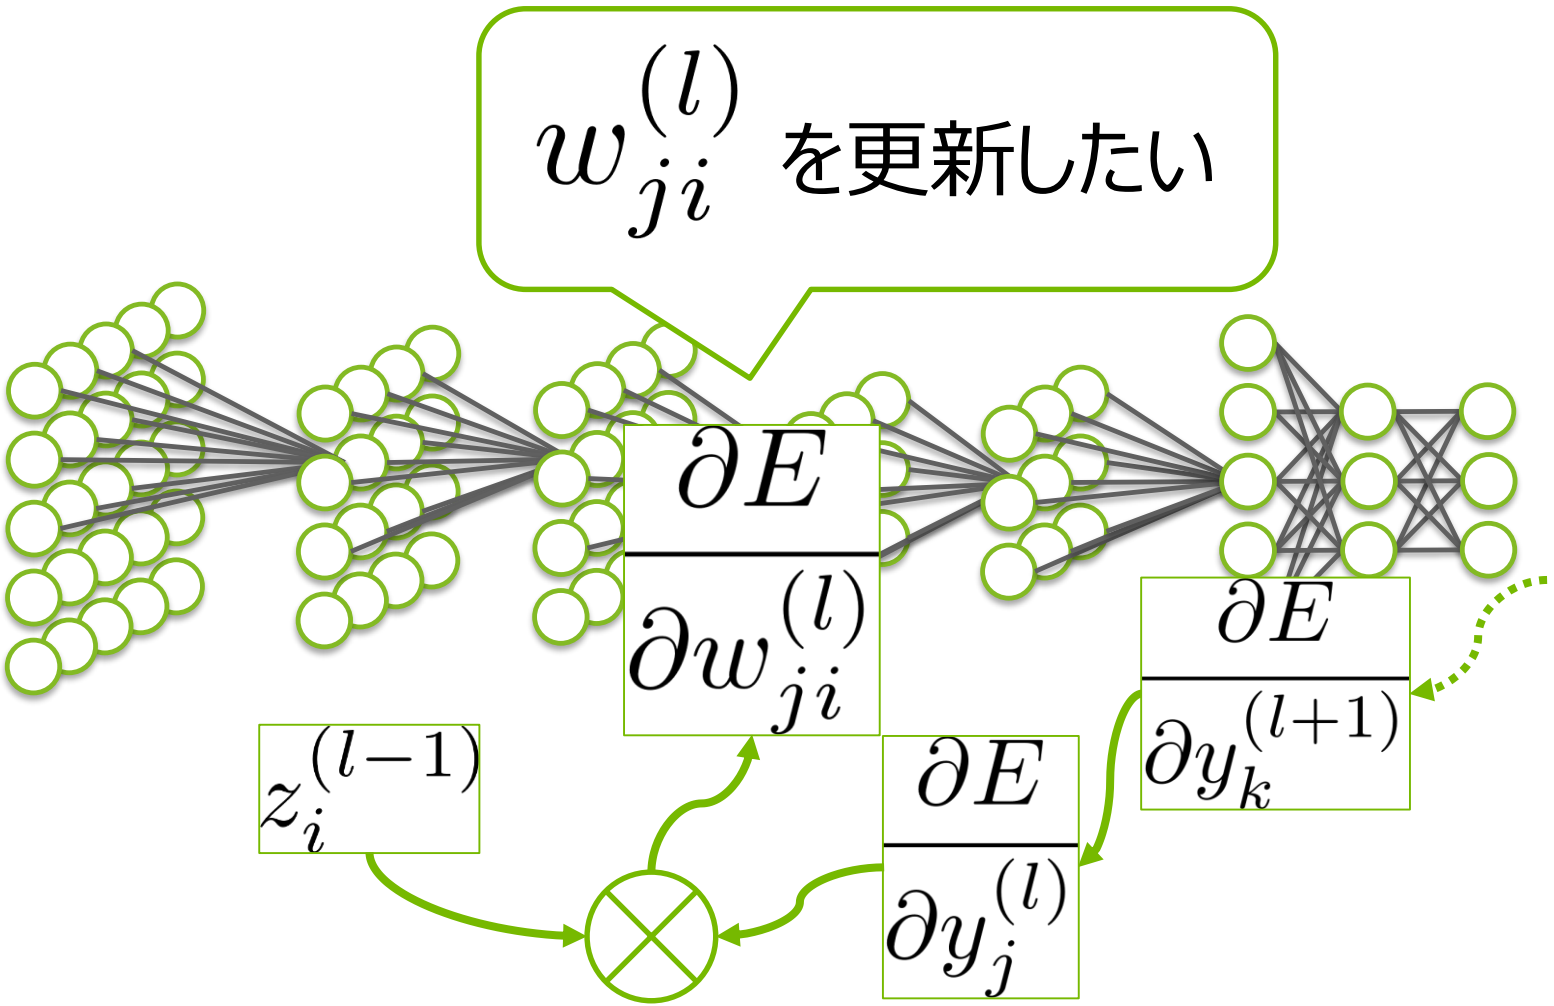

誤差逆伝播法

処理のイメージ

トレーニングデータ

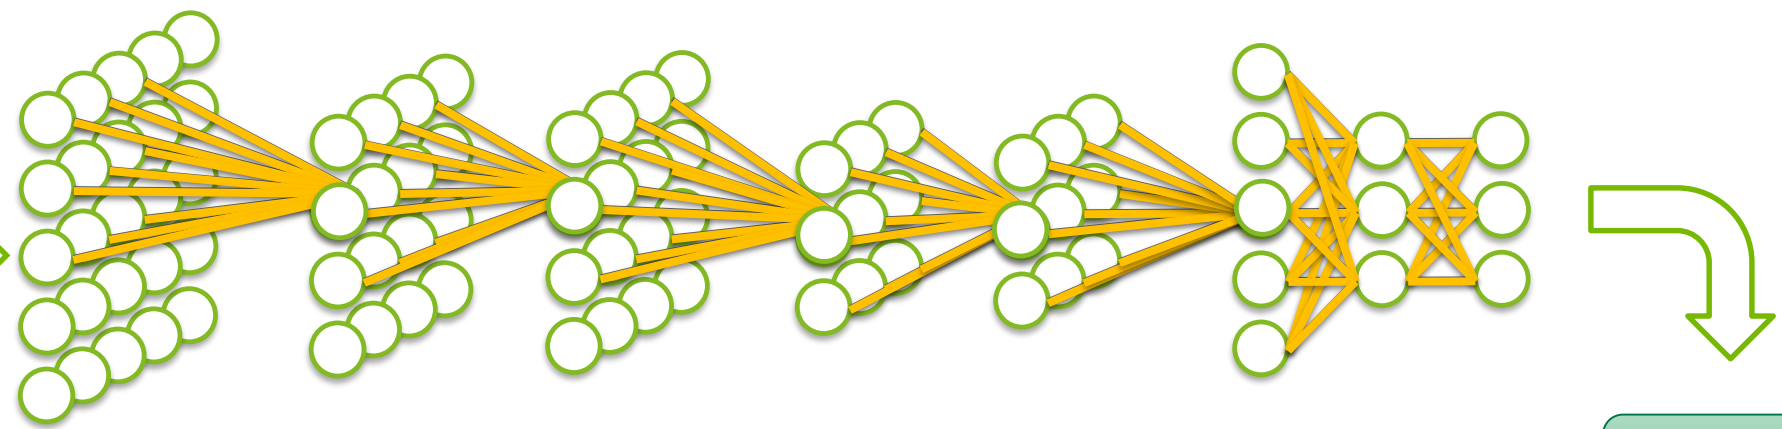

誤差

誤差を逆方向に伝えて、各層の重み行列を更新する

ディープラーニングの学習フロー

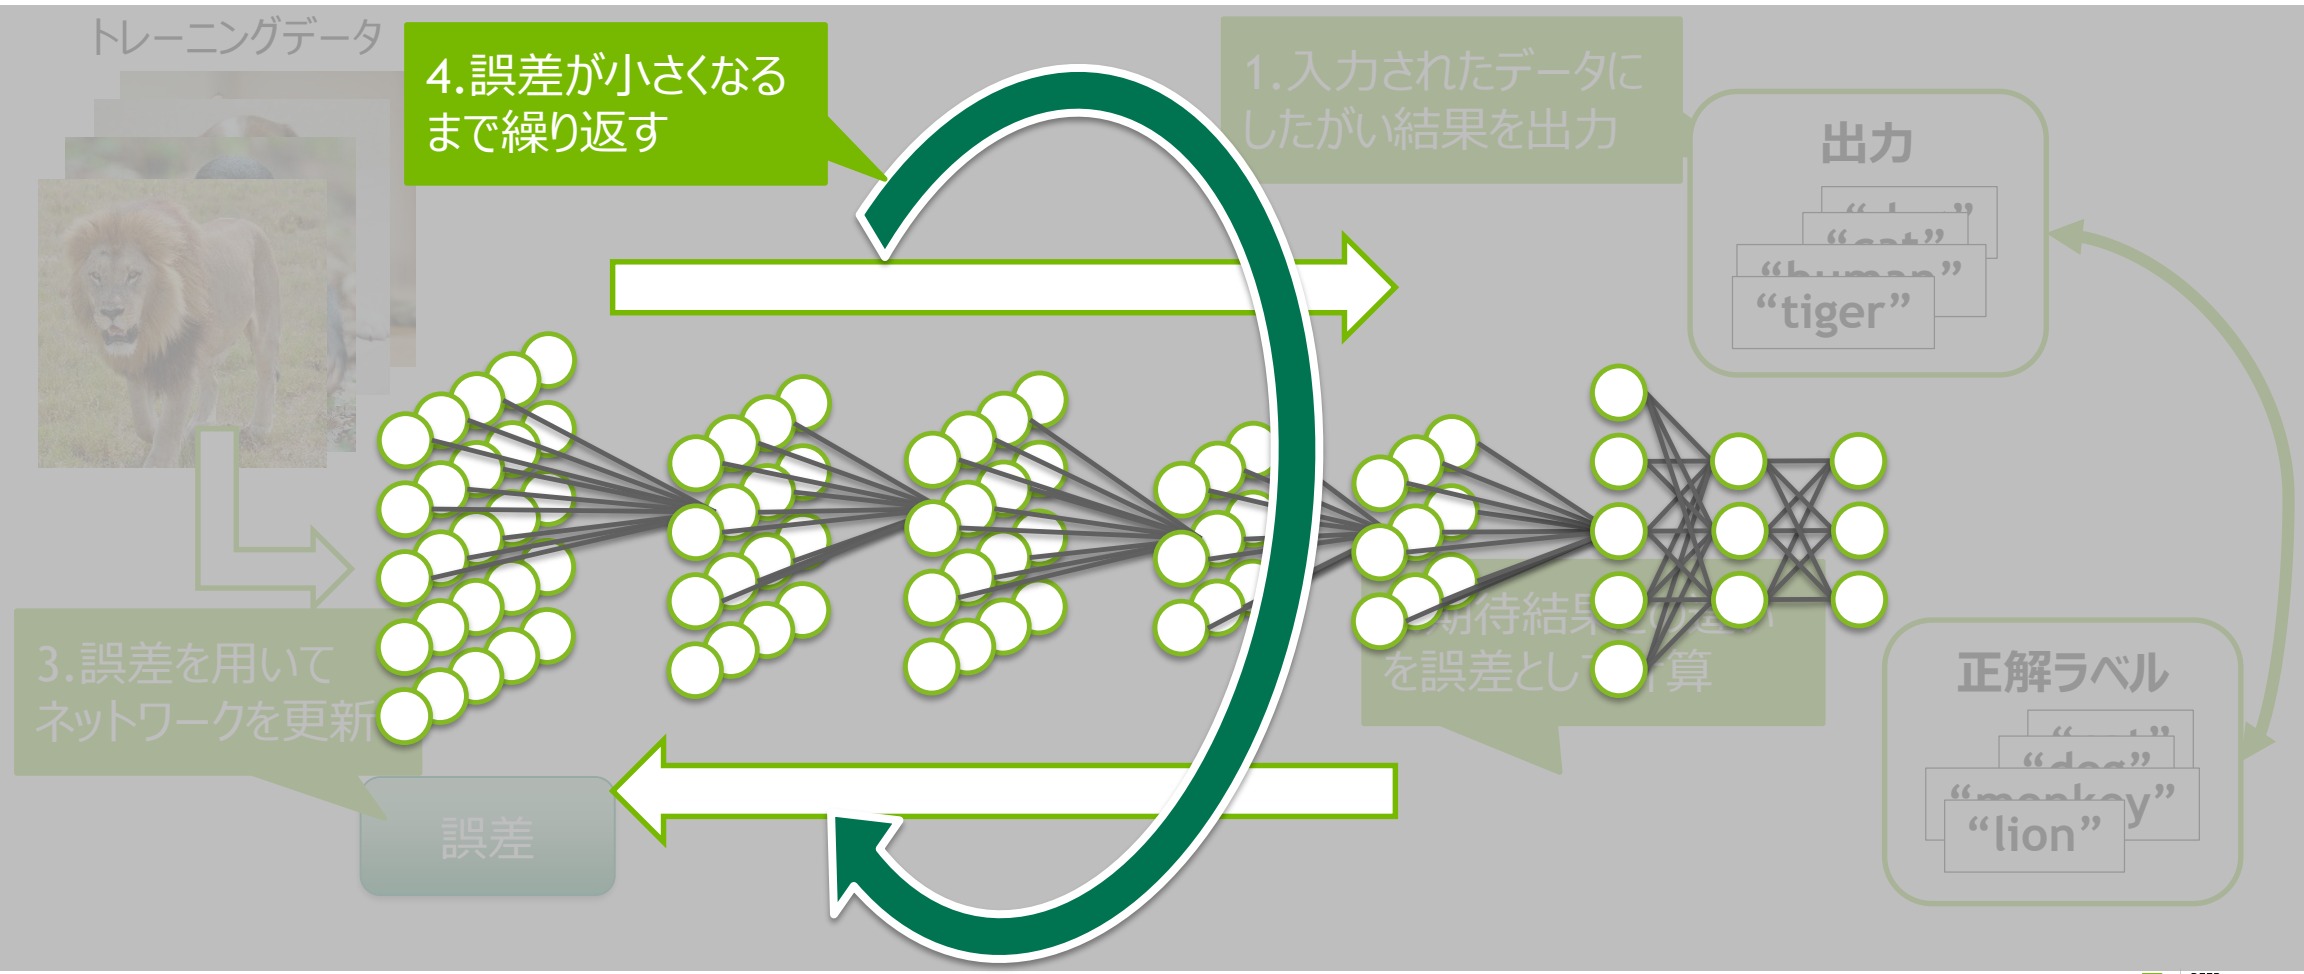

学習プロセスの単位: ミニバッチ

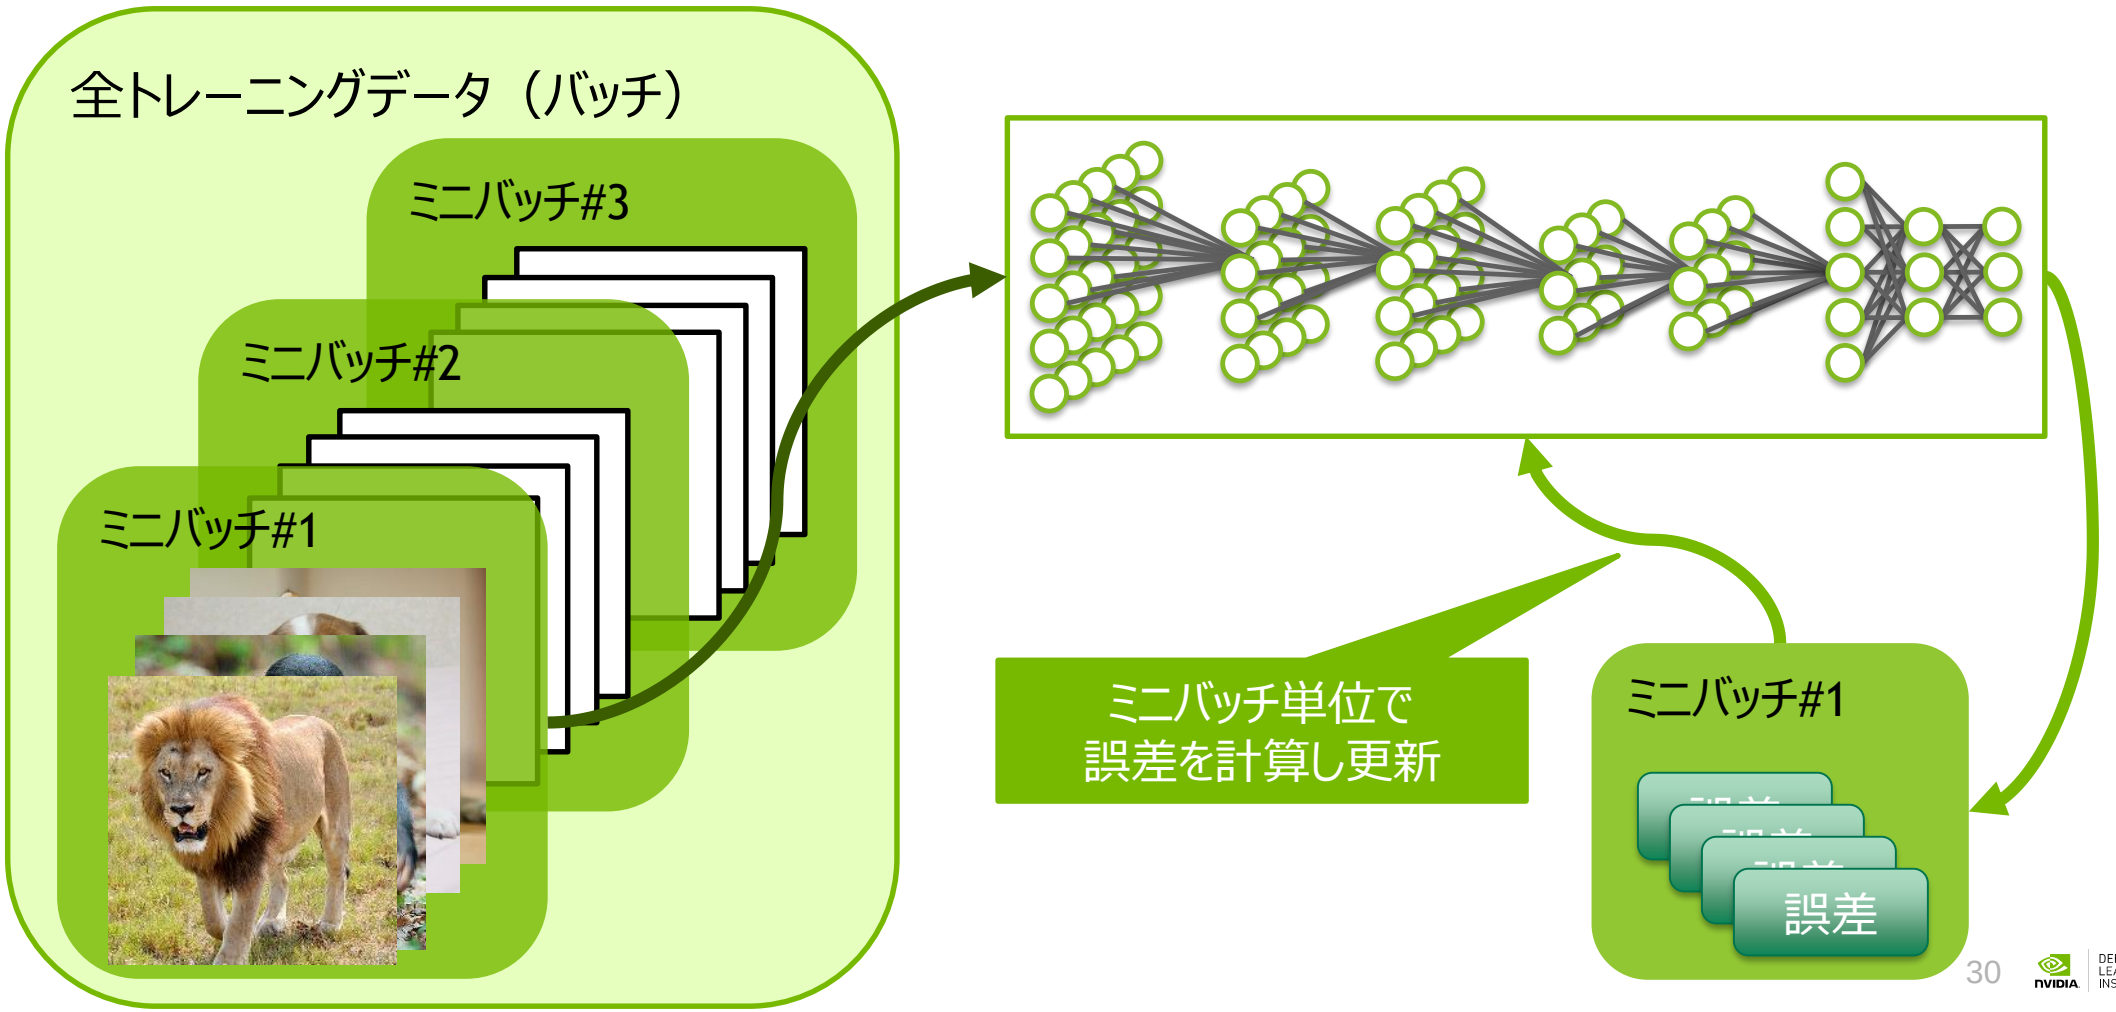

学習プロセスの単位: エポック

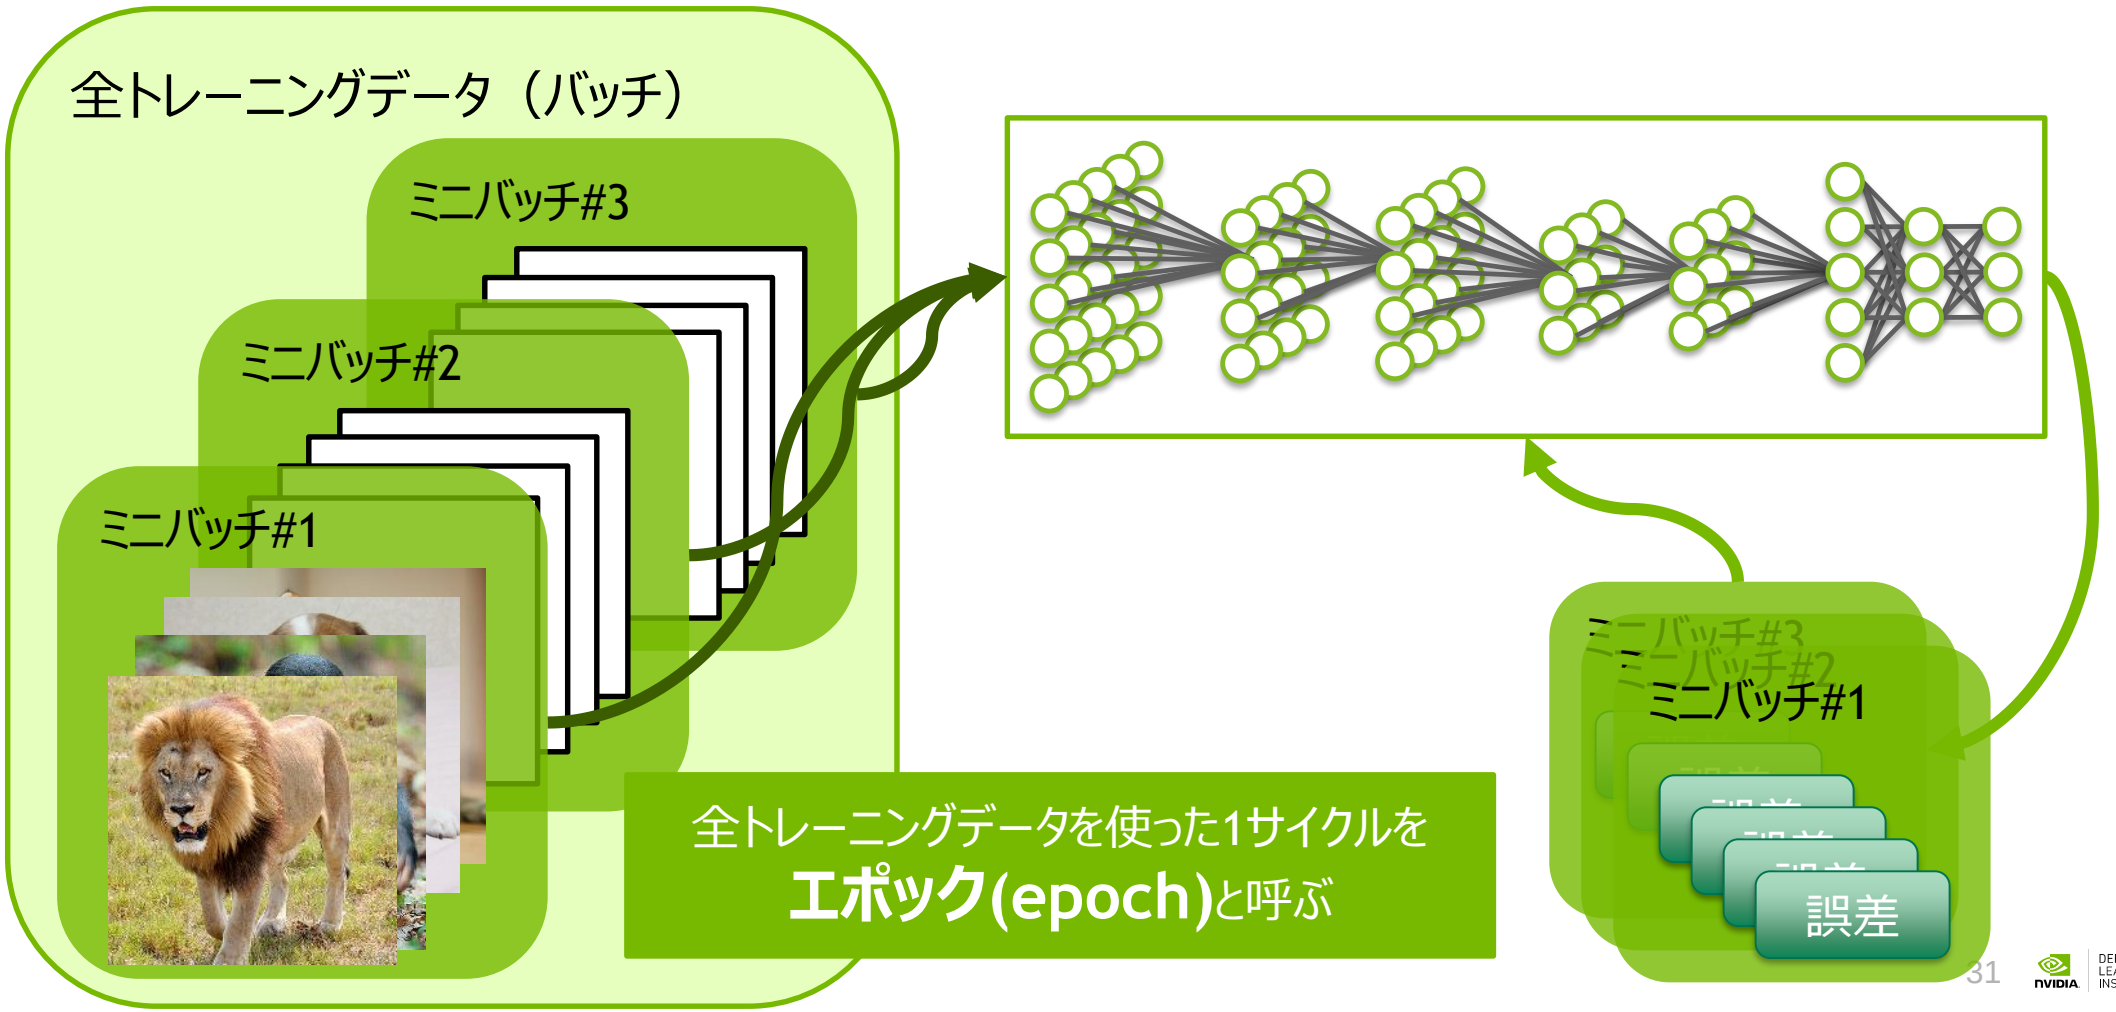

ディープラーニングを支えるソフトウェア

ディープラーニング フレームワーク

GPUで高速化されたディープラーニング フレームワークが多数存在

ディープラーニング フレームワーク

https://developer.nvidia.com/deep-learning-frameworks

NVIDIA DEEP LEARNING プラットフォーム

アプリケーション

本日使用する
フレームワーク

Image Cl
C
ce Recognition
Translation
SPEECH AND AUDIO
Recommendation Engines
Sentiment Analysis
BEHAVIOR

フレームワーク

Caffe
Chainer
DL4J
Deeplearning4j
Mocha.jl
julia
KERAS
Microsoft CNTK
MatConvNet
mxnet
MINERVA
Purine
OpenDeep
TensorFlow
Pylearn2
torch
theano

ディープラーニング SDK

cuDNN
TensorRT
DEEP LEARNING
cuBLAS
cuSPARSE
cuFFT
MATH LIBRARIES
GPU0
GPU1
GPU3
GPU2
NCCL
MULTI-GPU

GPU プラットフォーム

amazon web services™
IBM SOFTLAYER
Microsoft Azure
阿里云计算 Alibaba Cloud Computing
CLOUD
Tesla V100
Tesla P40/P4
Jetson TX2
DRIVEPX2
GPU
DGX-1
SERVER

本日使用するフレームワーク:
CHAINER&CHAINERMN

CHAINER

Pythonベースのディープラーニング フレームワーク

- Preferred Networks社によって開発
  - 最新はv3.2.0 (2018/01/13時点)
- NumPyインターフェース互換のGPU用数値計算ライブラリCuPyで計算を高速化
- 柔軟に記述でき、デバッグしやすく、直感的
- Define-by-Run方式(後述)の先駆者

https://chainer.org/
https://github.com/chainer/chainer

CHAINER

ソフトウェアスタックのイメージ

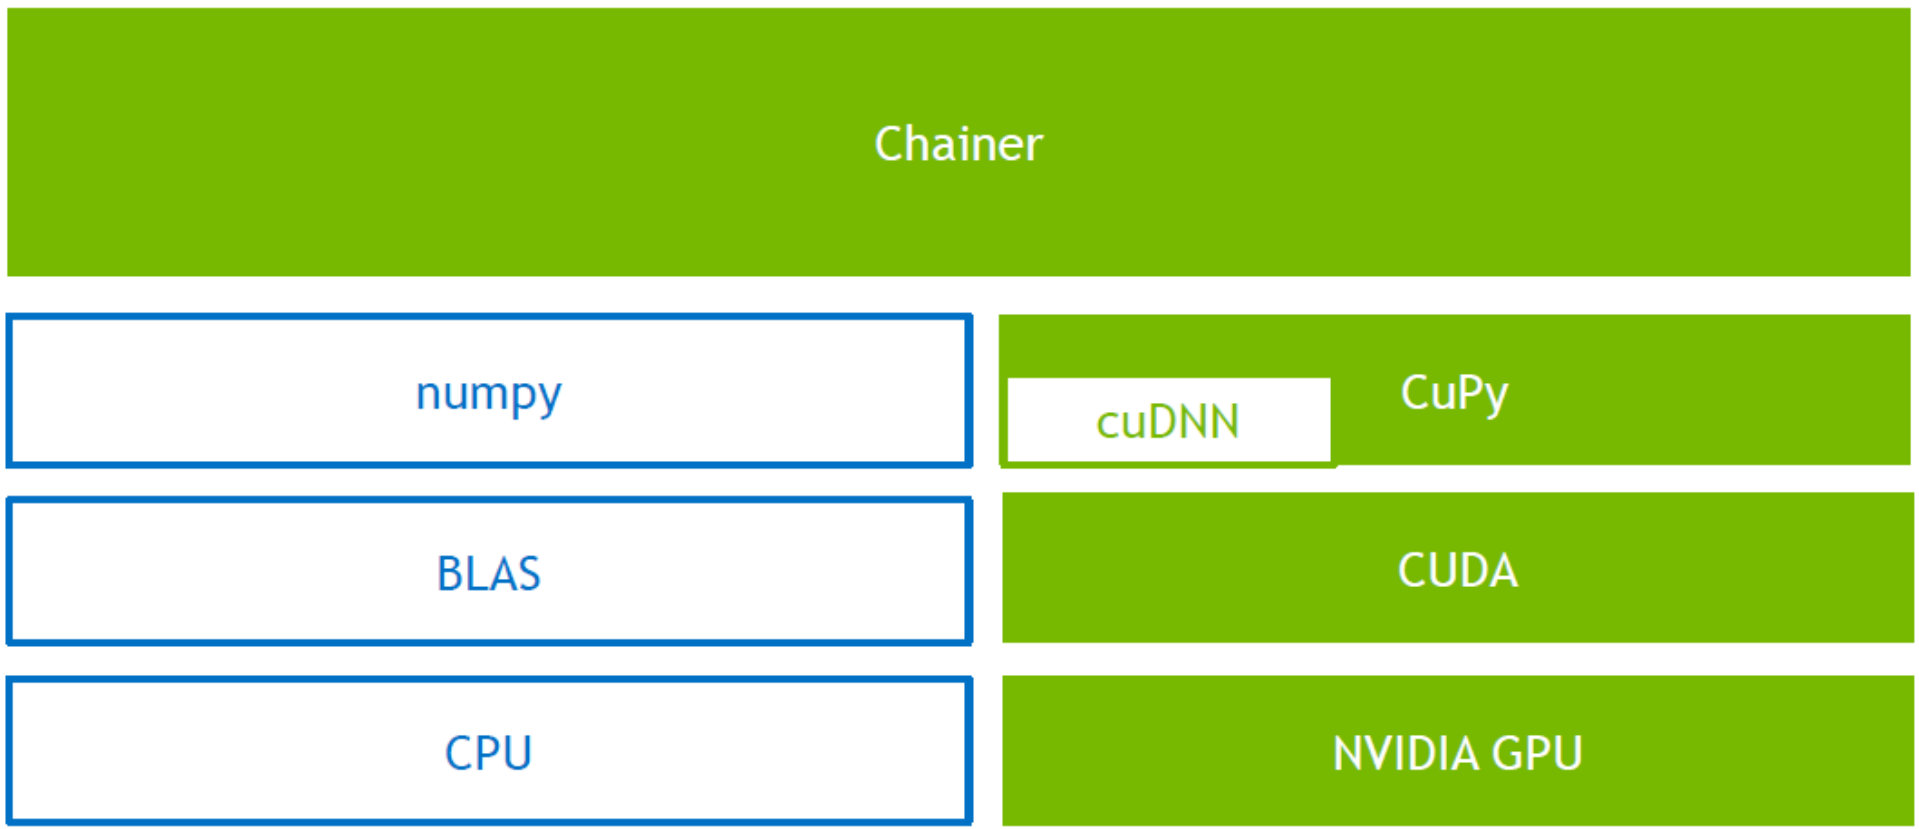

http://www.slideshare.net/unnonouno/chainer-59664785から引用

CHAINER

特徴的な実行方式: Define-by-Run

```
# Define-and-Run
# 計算グラフを構築後に、計算を実行

x = Variable('x')
w = Variable('w')
y = x * w

for xi, wi in data:
    eval(y, (xi, wi))
```

```
# Define-by-Run
# 計算グラフの構築と実行が同時

for xi, wi in data:
    x = Variable(xi)
    w = Variable(wi)
    y = x * w
```

データに応じて処理を
分岐することが容易

CHAINER

特徴的な実行方式: Define-by-Run

```
# Define-and-Run
# 計算グラフを構築後に、計算を実行

x = Variable('x')
w = Variable('w')
y = x * w

for xi, wi in data:
    eval(y, (xi, wi))
```

```
# Define-by-Run
# 計算グラフの構築と実行が同時

for i, (xi, wi) in enumerate(data):
    x = Variable(xi)
    w = Variable(wi)
    if i % 2 == 0:
        y = x * w
    else:
        y = x + w
```

CUPY

GPUで動作するNumPy互換の数値計算ライブラリ

- CUDAで高速化された数値計算ライブラリ
  - 最新はv2.2.0 (2018/01/13時点)
- NumPy互換のI/Fを持つ
  - CPUで実装したコードをシームレスにGPU化
- もとはChainerの内部モジュールとして開発
  - 現在は単独でも提供されている
  - インストールコマンドは pip install cupy

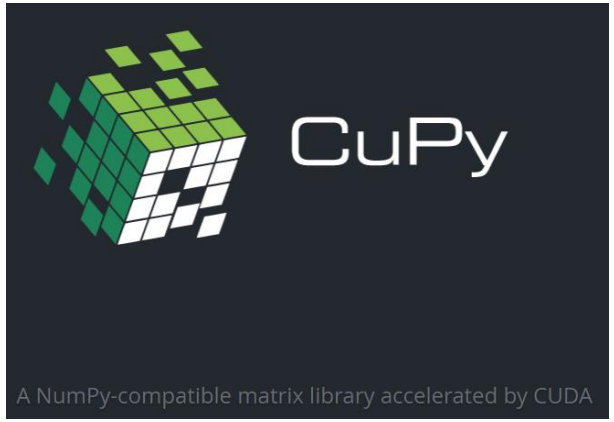

https://cupy.chainer.org/
https://github.com/cupy/cupy

CUPY

GPUで動作するNumPy互換の数値計算ライブラリ

NumPyコード

```
import numpy

x = numpy.array([1,2,3], numpy.float32)
y = x * x
s = numpy.sum(y)
print(s)
```

CuPyコード

```
import cupy

x = cupy.array([1,2,3], cupy.float32)
y = x * x
s = cupy.sum(y)
print(s)
```

CHAINERMN

Chainerをベースとした分散学習用ライブラリ

- マルチノードでの分散学習を
  サポートするための追加パッケージ
  - 最新はv1.1.0 (2018/01/13時点)
- CUDA-aware MPIやNCCLなどのライブラリを利用して実装
- 大規模なクラスタでも非常によくスケールする

https://github.com/chainer/chainermn

まとめ

- ディープラーニングはニューラルネットワークを基本としている
- 学習では、勾配法や誤差逆伝播法を用いて、パラメータを更新
- さまざまなフレームワークがあり、用途に応じて使い分けることも重要

NVIDIA | DEEP LEARNING INSTITUTE

www.nvidia.com/dli