教材の利用について：このPDFは、利用者本人の個人学習目的で保存・印刷して利用できます。法令上認められる場合を除き、PDFまたは印刷物の第三者への配布・販売、問題・選択肢・解説の転載・流用、塾・講座・研修等での無断利用はできません。詳細は利用規約をご確認ください。https://shikaku-bootcamp.com/terms/

0001 ニューラルネットワーク > ニューラルネットワーク・多層ネットワーク ｜ 難易度：基礎

研修資料に「複数の入力を重み付きで合成し、バイアスを加えた値に活性化関数を適用して出力する。」と記載されている。この記述を最も直接的に裏付ける説明はどれか。

ア. 人工ニューロンは入力の線形結合に非線形変換を組み合わせる基本単位として表現される。

イ. 重みや活性化関数による変換を行うため、単なる複製ではない。

ウ. 推論時に正解ラベルを入力することを前提としない。

エ. 一般には複数入力を重み付きで統合する。

答え・解説 **正答：ア**

ア：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『複数の入力を重み付きで合成し、バイアスを加えた値に活性化関数を適用して出力する。』である。

イ：この説明は別の論点『入力を重みと無関係にそのまま複製し、常に同じ値を出力する。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『正解ラベルを入力として受け取り、そのラベルだけを次層へ転送する。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『入力特徴量を必ず一つだけ選び、残りを永久に削除する。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『複数の入力を重み付きで合成し、バイアスを加えた値に活性化関数を適用して出力する。』である。人工ニューロンは入力の線形結合に非線形変換を組み合わせる基本単位として表現される。 背景となる論点は次のとおりである。ニューラルネットワークでは、各ニューロンの重み・バイアスと非線形性を層状に組み合わせて複雑な写像を表現する。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0002 ニューラルネットワーク > ニューラルネットワーク・多層ネットワーク ｜ 難易度：基礎

ある受験者が「隠れ層を増やすと必ず訓練データなしで正解が得られる。」と回答した。この誤りを最も適切に指摘する説明はどれか。

ア. 層数は学習データや学習そのものを不要にしない。

イ. 隠れ層と非線形活性化を重ねることで、複雑な非線形写像を表現できる。

ウ. 隠れ層は内部表現を計算する層である。

エ. 学習では重みを調整し、異なる特徴を表現する。

答え・解説 **正答：ア**

ア：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『隠れ層を増やすと必ず訓練データなしで正解が得られる。』である。

イ：この説明は別の論点『入力から中間表現を段階的に変換し、単純な線形変換だけでは表しにくい関係を学習できるようにする。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『隠れ層は出力クラス名を人手で保存するためだけに使う。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『隠れ層を使う目的はすべての重みを同じ値に固定することである。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象となる誤った主張は『隠れ層を増やすと必ず訓練データなしで正解が得られる。』である。層数は学習データや学習そのものを不要にしない。 正しい理解の背景は次のとおりである。多層化の効果は非線形活性化と組み合わさって現れる。全層が線形なら、全体も一つの線形変換へまとめられる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0003 ニューラルネットワーク > ニューラルネットワーク・多層ネットワーク ｜ 難易度：基礎

AI関連の資料レビューで「層を重ねるほど必ず任意の非線形関数を厳密に表現できる。」という記述が見つかった。レビューコメントとして最も適切なものはどれか。

ア. 線形変換だけでは合成後も線形である。

イ. 線形層でも微分・勾配計算は可能である。

ウ. 線形写像の合成は線形写像なので、非線形性を導入しなければ多層化の表現上の利点が大きく失われる。

エ. 出力次元は重み行列の形状で決まり、1に固定されない。

答え・解説 **正答：ア**

ア：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『層を重ねるほど必ず任意の非線形関数を厳密に表現できる。』である。

イ：この説明は別の論点『線形層だけにすると勾配計算が数学的に不可能になる。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『複数の線形変換を合成しても全体は線形変換となるため、多層化だけでは非線形な表現力は得にくい。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『線形層だけなら出力次元は必ず1になる。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象となる誤った主張は『層を重ねるほど必ず任意の非線形関数を厳密に表現できる。』である。線形変換だけでは合成後も線形である。 正しい理解の背景は次のとおりである。深層ネットワークでは層の間にReLUなどの非線形活性化を入れることが重要である。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0004 ニューラルネットワーク > ニューラルネットワーク・多層ネットワーク ｜ 難易度：標準

次の主張「重みは入力の寄与度を調整し、バイアスは入力が0でも活性化の位置をずらせる学習パラメータである。」について、その理由を最も正確に説明しているものはどれか。

ア. 重みとバイアスはともに学習で更新され、層の線形変換を構成する。

イ. 通常は両方が学習対象となる。

ウ. バイアスは独立した学習パラメータとして扱われる。

エ. どちらもモデルパラメータであり評価指標そのものではない。

答え・解説 **正答：ア**

ア：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『重みは入力の寄与度を調整し、バイアスは入力が0でも活性化の位置をずらせる学習パラメータである。』である。

イ：この説明は別の論点『重みは学習中に固定され、バイアスだけが更新される。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『バイアスは必ず入力特徴量の平均値と同じでなければならない。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『重みは正解率そのもの、バイアスは損失関数そのものを表す。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『重みは入力の寄与度を調整し、バイアスは入力が0でも活性化の位置をずらせる学習パラメータである。』である。重みとバイアスはともに学習で更新され、層の線形変換を構成する。 背景となる論点は次のとおりである。線形変換 z=Wx+b のWが重み、bがバイアスに相当する。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0005 ニューラルネットワーク > ニューラルネットワーク・多層ネットワーク ｜ 難易度：標準

学習者が「出力誤差から入力側へ勾配を逆向きに伝える処理だけを指す。」と理解している。この理解を修正するための説明として最も適切なものはどれか。

ア. これは誤差逆伝播の説明である。

イ. 順伝播では現在のパラメータを用いて入力から出力までの計算グラフを前向きに評価する。

ウ. Dropout等の正則化とは別である。

エ. 順伝播は数値計算の流れを指す。

答え・解説 **正答：ア**

ア： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『出力誤差から入力側へ勾配を逆向きに伝える処理だけを指す。』である。

イ： この説明は別の論点『入力から各層の計算を順に進め、最終的な予測値や出力を求める処理である。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『訓練データをランダムに削除して正則化する処理である。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『出力層のニューロンを学習前に手作業で並べ替える処理である。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『出力誤差から入力側へ勾配を逆向きに伝える処理だけを指す。』である。これは誤差逆伝播の説明である。 正しい理解の背景は次のとおりである。学習時は順伝播で出力と損失を計算し、その後に逆伝播で勾配を求める。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0006 ニューラルネットワーク > ニューラルネットワーク・多層ネットワーク ｜ 難易度：標準

実務上の判断で「表現力が高まる可能性がある一方、データ量や正則化が不十分だと過学習しやすくなり、計算量も増える。」という考え方を採用した。その判断根拠として最も適切なものはどれか。

ア. モデル容量の増加は複雑な関係の学習に有利だが、汎化・計算コストとのトレードオフがある。

イ. 未知データ性能は保証されず過学習も起こり得る。

ウ. 一般には十分なデータや正則化がより重要になる。

エ. 多層表現では非線形性が依然重要である。

答え・解説 **正答：ア**

ア： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『表現力が高まる可能性がある一方、データ量や正則化が不十分だと過学習しやすくなり、計算量も増える。』である。

イ： この説明は別の論点『パラメータ数を増やせばテスト誤差は必ず単調に0へ近づく。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『パラメータ数が多いほど必要な訓練データは必ず少なくなる。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『パラメータ数を増やすと非線形活性化は自動的に不要になる。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『表現力が高まる可能性がある一方、データ量や正則化が不十分だと過学習しやすくなり、計算量も増える。』である。モデル容量の増加は複雑な関係の学習に有利だが、汎化・計算コストとのトレードオフがある。 背景となる論点は次のとおりである。モデル容量は大きければよいわけではなく、データ・計算資源・汎化性能を踏まえて設計する。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0007 ニューラルネットワーク > ニューラルネットワーク・多層ネットワーク ｜ 難易度：標準

教材の草案に「入力層が損失関数を最小化し、隠れ層が正解ラベルを保存し、出力層がデータを収集する。」とある。内容を訂正する際に示す説明として最も適切なものはどれか。

ア. 各層の役割を取り違えている。

イ. 層幅はタスクに応じて設計される。

ウ. 各層はデータ受け入れ、中間変換、最終出力という役割を担う。

エ. 通常、推論でも隠れ層を通して計算する。

答え・解説 **正答：ア**

ア：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『入力層が損失関数を最小化し、隠れ層が正解ラベルを保存し、出力層がデータを収集する。』である。

イ：この説明は別の論点『入力層は必ず1ニューロン、出力層は必ず1000ニューロンでなければならない。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『入力層は特徴を受け取り、隠れ層は中間表現を計算し、出力層はタスクに応じた予測形式へ変換する。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『隠れ層は推論時に削除され、出力層だけで予測する。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象となる誤った主張は『入力層が損失関数を最小化し、隠れ層が正解ラベルを保存し、出力層がデータを収集する。』である。各層の役割を取り違えている。 正しい理解の背景は次のとおりである。出力層の活性化やユニット数は、回帰・二値分類・多クラス分類などタスクによって変わる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0008 ニューラルネットワーク > ニューラルネットワーク・多層ネットワーク ｜ 難易度：標準

「クラスごとのスコアを出力し、softmaxなどでクラス確率として扱えるようにする。」という説明を正しいと判断する際、最も適切な根拠はどれか。

ア. 相互排他的な多クラス分類では、出力ユニットをクラス数に対応させsoftmaxを用いる設計が代表的である。

イ. クラス番号の距離に意味がない場合、単純回帰は不適切である。

ウ. 一般に出力層にも重み・バイアスがある。

エ. softmax出力の合計は1になる。

答え・解説 **正答：ア**

ア：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『クラスごとのスコアを出力し、softmaxなどでクラス確率として扱えるようにする。』である。

イ：この説明は別の論点『出力ユニットを必ず1つにし、各クラス名を連続値として回帰する。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『出力層には学習可能なパラメータを一切置けない。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『softmaxを使うと各クラスの出力確率の合計が必ず2になる。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『クラスごとのスコアを出力し、softmaxなどでクラス確率として扱えるようにする。』である。相互排他的な多クラス分類では、出力ユニットをクラス数に対応させsoftmaxを用いる設計が代表的である。 背景となる論点は次のとおりである。出力層は目的変数の構造と損失関数を整合させることが重要である。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0009 ニューラルネットワーク > ニューラルネットワーク・多層ネットワーク ｜ 難易度：応用

研修資料に「訓練データ全体を原則として一巡して学習に用いる単位である。」と記載されている。この記述を最も直接的に裏付ける説明はどれか。

ア. 1エポックは訓練集合を一通り処理する学習周期を表す。

イ. 重み数ではなくデータ処理の周期である。

ウ. クラス数とは無関係である。

エ. 通常は訓練データの学習周期を指す。

答え・解説 **正答：ア**

ア：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『訓練データ全体を原則として一巡して学習に用いる単位である。』である。

イ：この説明は別の論点『一つのニューロンが持つ重みの個数だけを指す。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『一回の順伝播で計算される出力クラス数を指す。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『学習終了後のテストデータだけを一巡することを必ず指す。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『訓練データ全体を原則として一巡して学習に用いる単位である。』である。1エポックは訓練集合を一通り処理する学習周期を表す。 背景となる論点は次のとおりである。ミニバッチ学習では1エポックの中に複数のパラメータ更新が含まれる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0010 ニューラルネットワーク > ニューラルネットワーク・多層ネットワーク ｜ 難易度：応用

ある受験者が「出力ラベルを暗記して入力に関係なく同じ答えを返すことを指す。」と回答した。この誤りを最も適切に指摘する説明はどれか。

ア. 暗記は汎化する表現学習とは異なる。

イ. これは表現を学習しない設計である。

ウ. 深層学習では特徴抽出と予測器を一体として学習し、中間層に階層的な表現を形成できる。

エ. 有用な中間表現を形成することと逆である。

答え・解説 **正答：ア**

ア：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『出力ラベルを暗記して入力に関係なく同じ答えを返すことを指す。』である。

イ：この説明は別の論点『すべての特徴量を人手で固定し、モデルは特徴を一切変換しないことを指す。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『生の入力からタスクに有用な特徴表現を複数層で段階的に学習できることを指す。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『隠れ層の値を常に0に固定して特徴を消去することを指す。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象となる誤った主張は『出力ラベルを暗記して入力に関係なく同じ答えを返すことを指す。』である。暗記は汎化する表現学習とは異なる。 正しい理解の背景は次のとおりである。表現学習は、画像なら低次特徴から高次概念へという階層的処理の説明にも用いられる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0011 ニューラルネットワーク > 活性化関数 ｜ 難易度：基礎

AI関連の資料レビューで「学習データの件数を自動的に増やすためである。」という記述が見つかった。レビューコメントとして最も適切なものはどれか。

ア. データ拡張とは異なる。

イ. 活性化関数はパラメータ削除のための処理ではない。

ウ. 非線形活性化がなければ線形層を何段重ねても全体は線形写像に留まる。

エ. 活性化関数は各ユニットの非線形変換である。

答え・解説 **正答：ア**

ア：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『学習データの件数を自動的に増やすためである。』である。

イ：この説明は別の論点『重み行列の要素数を必ず0にするためである。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『層の計算に非線形性を導入し、複雑な入力と出力の関係を表現できるようにするためである。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『正解ラベルを生成する教師役になるためである。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象となる誤った主張は『学習データの件数を自動的に増やすためである。』である。データ拡張とは異なる。 正しい理解の背景は次のとおりである。活性化関数はネットワークの表現力や勾配の流れに大きく影響する。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0012 ニューラルネットワーク > 活性化関数 ｜ 難易度：基礎

次の主張「入力が正ならその値を出力し、0以下なら0を出力する。」について、その理由を最も正確に説明しているものはどれか。

ア. ReLUは max(0,x) と表される単純な区分線形関数である。

イ. これはシグモイド関数の特徴である。

ウ. ReLUは二乗関数ではない。

エ. 入力に応じて出力が変化する。

答え・解説 **正答：ア**

ア：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『入力が正ならその値を出力し、0以下なら0を出力する。』である。

イ：この説明は別の論点『入力を0から1へ滑らかに圧縮するS字型関数である。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『入力の符号に関係なく必ず二乗値を返す。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『全入力に対して同じ定数1を返す。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『入力が正ならその値を出力し、0以下なら0を出力する。』である。ReLUは max(0,x) と表される単純な区分線形関数である。 背景となる論点は次のとおりである。ReLUは計算が簡単で正の領域では勾配が一定のため、深層ネットワークで広く使われてきた。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0013 ニューラルネットワーク > 活性化関数 ｜ 難易度：基礎

学習者が「出力は必ず-1か1のどちらかで連続値を取らない。」と理解している。この理解を修正するための説明として最も適切なものはどれか。

ア. シグモイドは連続関数である。

イ. シグモイドは実数を0〜1へ写像するため、二値事象の確率表現に適する。

ウ. シグモイドの値域は0〜1である。

エ. これはsoftmaxの性質であり、単一シグモイドの定義ではない。

答え・解説 **正答：ア**

ア： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『出力は必ず-1か1のどちらかで連続値を取らない。』である。

イ： この説明は別の論点『出力は0から1の範囲で、二値分類の出力確率を表す用途などに使われる。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『出力は負の無限大から正の無限大で、必ず回帰の最終出力にしか使えない。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『出力は全要素の合計が必ず1になるベクトルである。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『出力は必ず-1か1のどちらかで連続値を取らない。』である。シグモイドは連続関数である。 正しい理解の背景は次のとおりである。隠れ層でのシグモイドは飽和により勾配消失を起こしやすい点に注意する。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0014 ニューラルネットワーク > 活性化関数 ｜ 難易度：標準

実務上の判断で「tanhは出力が概ね-1から1の範囲で0中心となる一方、両端では勾配が小さくなる飽和性を持つ。」という考え方を採用した。その判断根拠として最も適切なものはどれか。

ア. tanhはS字型で0中心だが、大きな絶対値の入力で勾配が小さくなる。

イ. それはシグモイドの値域に近い説明である。

ウ. 飽和領域では勾配が小さくなる。

エ. tanhは滑らかな連続関数である。

答え・解説 **正答：ア**

ア： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『tanhは出力が概ね-1から1の範囲で0中心となる一方、両端では勾配が小さくなる飽和性を持つ。』である。

イ： この説明は別の論点『tanhは出力が0から1に限られ、0中心にはならない。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『tanhは全領域で傾きが常に1なので勾配消失しない。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『tanhは非連続な二値関数で微分できない。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『tanhは出力が概ね-1から1の範囲で0中心となる一方、両端では勾配が小さくなる飽和性を持つ。』である。tanhはS字型で0中心だが、大きな絶対値の入力で勾配が小さくなる。 背景となる論点は次のとおりである。活性化関数の値域や導関数の性質は学習安定性に影響する。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0015 ニューラルネットワーク > 活性化関数 ｜ 難易度：標準

教材の草案に「順伝播では重みを一切使わないためである。」とある。内容を訂正する際に示す説明として最も適切なものはどれか。

ア. 重みを用いて計算する。

イ. 導関数はそのように大きくなく、むしろ飽和域で小さい。

ウ. 連鎖律で導関数を連続して掛けるため、各層の微分値が小さいと勾配が急速に減衰する。

エ. 符号反転そのものが勾配消失の原因ではない。

答え・解説 **正答：ア**

ア：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『順伝播では重みを一切使わないためである。』である。

イ：この説明は別の論点『シグモイドの導関数が常に100以上になるためである。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『飽和領域では導関数が小さく、逆伝播で小さな勾配を層ごとに掛け合わせると前段へ届く勾配が極端に小さくなるためである。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『勾配を逆伝播すると必ず符号が反転するためである。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象となる誤った主張は『順伝播では重みを一切使わないためである。』である。重みを用いて計算する。 正しい理解の背景は次のとおりである。ReLU系活性化や適切な初期化、正規化などは深層学習の最適化を助ける工夫として使われる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0016 ニューラルネットワーク > 活性化関数 ｜ 難易度：標準

「あるユニットの入力が負側に偏り続け、出力も勾配も0となって更新が進みにくくなる現象である。」という説明を正しいと判断する際、最も適切な根拠はどれか。

ア. 標準ReLUは負の領域で勾配が0なので、ユニットが負側に固定されると学習に寄与しにくくなる。

イ. ReLUは正の領域では入力をそのまま出力する。

ウ. softmax出力の話ではない。

エ. データ削除ではなくユニットの不活性化である。

答え・解説 **正答：ア**

ア：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『あるユニットの入力が負側に偏り続け、出力も勾配も0となって更新が進みにくくなる現象である。』である。

イ：この説明は別の論点『正の入力が大きいほど出力が必ず0へ近づく現象である。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『出力確率の合計が1を超える現象である。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『活性化関数が訓練データを自動削除する現象である。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『あるユニットの入力が負側に偏り続け、出力も勾配も0となって更新が進みにくくなる現象である。』である。標準ReLUは負の領域で勾配が0なので、ユニットが負側に固定されると学習に寄与しにくくなる。 背景となる論点は次のとおりである。Leaky ReLUなどは負の領域にも小さな傾きを持たせ、この問題を緩和する狙いがある。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0017 ニューラルネットワーク > 活性化関数 ｜ 難易度：標準

研修資料に「負の入力に対しても小さな傾きを残し、勾配が完全に0になる領域を減らす。」と記載されている。この記述を最も直接的に裏付ける説明はどれか。

ア. Leaky ReLUは負側を0に切り捨てず小さな線形応答を残す。

イ. 正側は通常ReLUと同様に線形出力する。

ウ. 確率正規化の関数ではない。

エ. これはsoftmaxの役割である。

答え・解説 **正答：ア**

ア： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『負の入力に対しても小さな傾きを残し、勾配が完全に0になる領域を減らす。』である。

イ： この説明は別の論点『正の入力をすべて0へする。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『出力を必ず0から1へ正規化する。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『各クラスの出力を互いに依存させ合計1にする。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『負の入力に対しても小さな傾きを残し、勾配が完全に0になる領域を減らす。』である。Leaky ReLUは負側を0に切り捨てず小さな線形応答を残す。 背景となる論点は次のとおりである。ReLU系にはLeaky ReLUやPReLUなど複数の変種がある。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0018 ニューラルネットワーク > 活性化関数 ｜ 難易度：標準

ある受験者が「すべてのクラスに必ず同じ確率を与える。」と回答した。この誤りを最も適切に指摘する説明はどれか。

ア. スコアが異なれば確率も異なる。

イ. softmaxはクラス間を相対的に正規化する連続関数である。

ウ. softmaxは各スコアの指数を全指数和で正規化し、多クラス分類の出力に広く使われる。

エ. 最大スコアは通常最も高い確率を得る。

答え・解説 **正答：ア**

ア： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『すべてのクラスに必ず同じ確率を与える。』である。

イ： この説明は別の論点『各スコアを独立に0か1へ切り捨てるだけの関数である。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『複数クラスのスコアを非負の値へ変換し、全クラスの出力の合計が1になる確率分布として表せる。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『入力の最大値を常に0へ変換する関数である。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『すべてのクラスに必ず同じ確率を与える。』である。スコアが異なれば確率も異なる。 正しい理解の背景は次のとおりである。相互排他的な多クラス分類でsoftmaxと交差エントロピーの組合せが代表的である。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0019 ニューラルネットワーク > 活性化関数 ｜ 難易度：応用

AI関連の資料レビューで「恒等関数を使えば自動的に各出力が0〜1に収まる。」という記述が見つかった。レビューコメントとして最も適切なものはどれか。

ア. 恒等関数は値域を制約しない。

イ. 相互排他的でない多ラベル設定には制約が強すぎる。

ウ. ReLUには確率和を1にする性質がない。

エ. 多ラベル分類では複数ラベルが同時に真となり得るため、各ラベルへ独立シグモイドを使う設計が一般的である。

答え・解説 **正答：ア**

ア：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『恒等関数を使えば自動的に各出力が0〜1に収まる。』である。

イ：この説明は別の論点『全ラベルへsoftmaxをかけ、必ず一つのラベルだけを選ばせる。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『ReLUを使い、各ラベル確率の合計を必ず1にする。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『各出力ユニットにシグモイドを用い、ラベルごとの存在確率を独立に表す。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象となる誤った主張は『恒等関数を使えば自動的に各出力が0〜1に収まる。』である。恒等関数は値域を制約しない。 正しい理解の背景は次のとおりである。出力活性化は目的変数の構造と損失関数に合わせて選ぶ。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0020 ニューラルネットワーク > 活性化関数 ｜ 難易度：応用

次の主張「予測値を0〜1などの範囲へ不必要に制限せず、実数値をそのまま出力できるためである。」について、その理由を最も正確に説明しているものはどれか。

ア. 目的変数が広い実数範囲を取る回帰では線形出力が自然な場合が多い。

イ. 恒等関数は入力をそのまま出力する。

ウ. 導関数は1であり、それ自体が勾配消失を生むわけではない。

エ. 確率正規化は行わない。

答え・解説 **正答：ア**

ア：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『予測値を0〜1などの範囲へ不必要に制限せず、実数値をそのまま出力できるためである。』である。

イ：この説明は別の論点『恒等関数は入力を必ず0へ変えるため外れ値に強くなる。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『恒等関数を使うと勾配が必ず消失する。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『恒等関数はクラス確率の合計を1にする。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『予測値を0〜1などの範囲へ不必要に制限せず、実数値をそのまま出力できるためである。』である。目的変数が広い実数範囲を取る回帰では線形出力が自然な場合が多い。 背景となる論点は次のとおりである。ただし目的変数が非負など制約を持つ場合は、別の出力関数を選ぶこともある。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0021 ニューラルネットワーク > 誤差関数・損失関数 ｜ 難易度：基礎

学習者が「推論時に正解ラベルを生成する関数である。」と理解している。この理解を修正するための説明として最も適切なものはどれか。

ア. 正解ラベルそのものを作るものではない。

イ. 損失関数は最適化の目的を定量化し、その勾配を用いてパラメータを更新する。

ウ. データ収集ではなく予測誤差の評価に使う。

エ. 層数制約ではない。

答え・解説 **正答：ア**

ア： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『推論時に正解ラベルを生成する関数である。』である。

イ： この説明は別の論点『モデルの予測と正解の不一致を数値化し、学習でどの方向にパラメータを改善するかの基準を与える。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『訓練データを自動収集するための関数である。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『モデルの層数を必ず1に固定するための関数である。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『推論時に正解ラベルを生成する関数である。』である。正解ラベルそのものを作るものではない。 正しい理解の背景は次のとおりである。タスクに適した損失関数を選ぶことが学習目標の定義そのものに関わる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0022 ニューラルネットワーク > 誤差関数・損失関数 ｜ 難易度：基礎

実務上の判断で「予測値と実測値の差を二乗して平均し、連続値予測のずれを滑らかな目的関数として評価できるためである。」という考え方を採用した。その判断根拠として最も適切なものはどれか。

ア. MSEは残差の二乗平均で、微分可能かつ大きな誤差を強く評価する。

イ. MSEはラベル並べ替えの手法ではない。

ウ. 二乗により誤差の大きさを反映する。

エ. 誤差の大きさに応じて値が変わる。

答え・解説 **正答：ア**

ア： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『予測値と実測値の差を二乗して平均し、連続値予測のずれを滑らかな目的関数として評価できるためである。』である。

イ： この説明は別の論点『分類ラベルの順序を必ず入れ替えるためである。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『誤差の符号だけを数え、大きさを無視するためである。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『すべての予測誤差を同じ1へ変換するためである。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『予測値と実測値の差を二乗して平均し、連続値予測のずれを滑らかな目的関数として評価できるためである。』である。MSEは残差の二乗平均で、微分可能かつ大きな誤差を強く評価する。 背景となる論点は次のとおりである。外れ値の大きな誤差が二乗で強調される性質も押さえる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0023 ニューラルネットワーク > 誤差関数・損失関数 ｜ 難易度：基礎

教材の草案に「MAEとMSEはどのデータでも必ず同じ数値になる。」とある。内容を訂正する際に示す説明として最も適切なものはどれか。

ア. 定義が異なるため一般には一致しない。

イ. MAEは絶対値を使う。

ウ. MSEは誤差を二乗して大きさを反映する。

エ. MSEは大きな残差を二乗で強調し、MAEは残差の大きさに線形に反応する。

答え・解説 **正答：ア**

ア：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『MAEとMSEはどのデータでも必ず同じ数値になる。』である。

イ：この説明は別の論点『MAEは誤差を四乗するためMSEより外れ値に敏感である。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『MSEは誤差の符号だけを使い、絶対値を無視する。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『MAEは誤差の絶対値を使うため、極端に大きい誤差を二乗するMSEより外れ値の影響を受けにくい傾向がある。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象となる誤った主張は『MAEとMSEはどのデータでも必ず同じ数値になる。』である。定義が異なるため一般には一致しない。 正しい理解の背景は次のとおりである。評価指標・学習損失は誤差分布や業務上のコストに応じて選択する。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0024 ニューラルネットワーク > 誤差関数・損失関数 ｜ 難易度：標準

「正解ラベルに対応する予測確率が高いほど損失が小さく、誤ったクラスへ高い確信を持つと損失が大きくなる。」という説明を正しいと判断する際、最も適切な根拠はどれか。

ア. 交差エントロピーは確率予測の確信度も含めて誤りを評価する。

イ. 交差エントロピーは確率値の違いを反映する。

ウ. 正解クラスへ高い確率を割り当てる方向に学習する。

エ. MSEとは定義が異なる。

答え・解説 **正答：ア**

ア：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『正解ラベルに対応する予測確率が高いほど損失が小さく、誤ったクラスへ高い確信を持つと損失が大きくなる。』である。

イ：この説明は別の論点『予測クラスさえ同じなら0.51と0.99の確率を完全に同じ損失で扱う。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『すべての予測確率を0.5へ近づけることだけを目的とする。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『回帰の残差を二乗して平均する損失と完全に同じである。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『正解ラベルに対応する予測確率が高いほど損失が小さく、誤ったクラスへ高い確信を持つと損失が大きくなる。』である。交差エントロピーは確率予測の確信度も含めて誤りを評価する。 背景となる論点は次のとおりである。確率的分類では出力活性化と損失関数の組合せを整合させることが重要である。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0025 ニューラルネットワーク > 誤差関数・損失関数 ｜ 難易度：標準

研修資料に「クラス確率分布と正解のone-hot分布の不一致を評価し、正解クラスの確率を高める方向へ学習できる。」と記載されている。この記述を最も直接的に裏付ける説明はどれか。

ア. softmaxが確率分布を作り、交差エントロピーが正解分布との隔たりを損失化する。

イ. softmaxはクラス間を正規化し合計1にする。

ウ. 正解クラス確率が低いと損失は大きくなる。

エ. 通常はクラス数に対応する出力を用いる。

答え・解説 **正答：ア**

ア： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『クラス確率分布と正解のone-hot分布の不一致を評価し、正解クラスの確率を高める方向へ学習できる。』である。

イ： この説明は別の論点『各クラスを完全に独立な回帰値として扱い、確率和の制約をなくす。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『正解クラスの確率が低いほど損失を小さくする。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『クラス数に関係なく出力ユニットを必ず1つにする。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『クラス確率分布と正解のone-hot分布の不一致を評価し、正解クラスの確率を高める方向へ学習できる。』である。softmaxが確率分布を作り、交差エントロピーが正解分布との隔たりを損失化する。 背景となる論点は次のとおりである。softmaxと交差エントロピーは数値安定性を考慮して一体的に実装されることも多い。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0026 ニューラルネットワーク > 誤差関数・損失関数 ｜ 難易度：標準

ある受験者が「評価指標は学習中に一切計算できず、損失関数だけがテスト時に使える。」と回答した。この誤りを最も適切に指摘する説明はどれか。

ア. どちらも必要に応じ計算できる。

イ. 微分可能性など最適化上の都合で損失を選び、最終評価にはAccuracyやF1など別指標を使う場合がある。

ウ. 目的や性質が異なることがある。

エ. 通常の重み更新は損失の勾配に基づく。

答え・解説 **正答：ア**

ア： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『評価指標は学習中に一切計算できず、損失関数だけがテスト時に使える。』である。

イ： この説明は別の論点『損失関数は主に学習時の最適化に使い、評価指標は業務目的やモデル比較の観点から性能を測るため、両者が同じとは限らない。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『損失関数と評価指標は名称が違うだけで必ず同一式である。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『評価指標はモデルの重みを直接更新する微分値そのものである。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『評価指標は学習中に一切計算できず、損失関数だけがテスト時に使える。』である。どちらも必要に応じ計算できる。 正しい理解の背景は次のとおりである。最適化する量と最終的に重視する業務指標がずれる場合、適切な代理損失を選ぶ必要がある。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0027 ニューラルネットワーク > 誤差関数・損失関数 ｜ 難易度：標準

AI関連の資料レビューで「平均を取ると各サンプルの損失が必ず0になる。」という記述が見つかった。レビューコメントとして最も適切なものはどれか。

ア. 平均は個別損失を消去する操作ではない。

イ. 学習率は依然必要な最適化パラメータである。

ウ. 損失の平均を取ると、バッチサイズが変わっても勾配スケールを比較的扱いやすい。

エ. ラベルの必要性は変わらない。

答え・解説 **正答：ア**

ア：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『平均を取ると各サンプルの損失が必ず0になる。』である。

イ：この説明は別の論点『平均損失を使えば学習率の設定が不要になる。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『バッチサイズに応じた損失スケールの変化を抑え、サンプル当たりの平均的な誤差として扱いやすくするためである。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『平均を取ると正解ラベルがなくても教師あり学習できる。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象となる誤った主張は『平均を取ると各サンプルの損失が必ず0になる。』である。平均は個別損失を消去する操作ではない。 正しい理解の背景は次のとおりである。実装ではsumかmeanかで勾配のスケールが変わるため、学習率との関係も意識する。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0028 ニューラルネットワーク > 誤差関数・損失関数 ｜ 難易度：標準

次の主張「パラメータをどの方向へ動かせば損失が減るかを勾配として計算し、更新に利用できるためである。」について、その理由を最も正確に説明しているものはどれか。

ア. 勾配降下法は損失の局所的な傾きを利用してパラメータを改善する。

イ. 微分可能でもニューラルネットの損失は一般に非凸である。

ウ. 最適化対象のデータは必要である。

エ. 微分可能な正則化項を加えることも一般的である。

答え・解説 **正答：ア**

ア：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『パラメータをどの方向へ動かせば損失が減るかを勾配として計算し、更新に利用できるためである。』である。

イ：この説明は別の論点『微分可能なら損失は必ず凸関数になり大域最適解が保証される。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『微分可能なら訓練データが不要になる。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『微分可能なら正則化を一切使えなくなる。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『パラメータをどの方向へ動かせば損失が減るかを勾配として計算し、更新に利用できるためである。』である。勾配降下法は損失の局所的な傾きを利用してパラメータを改善する。 背景となる論点は次のとおりである。実際にはReLUの0点のような非微分点があっても、劣勾配等を用いて学習できる場合がある。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0029 ニューラルネットワーク > 誤差関数・損失関数 ｜ 難易度：応用

学習者が「少数クラスのサンプルの損失をすべて0にして無視する。」と理解している。この理解を修正するための説明として最も適切なものはどれか。

ア. 重要クラスの学習信号を失ってしまう。

イ. クラス重みを調整すると、重要なクラスの誤分類を最適化で強く penalize できる。

ウ. 分類問題そのものが成立しなくなる。

エ. 不均衡問題を悪化させる。

答え・解説 **正答：ア**

ア：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『少数クラスのサンプルの損失をすべて0にして無視する。』である。

イ：この説明は別の論点『クラス重み付き交差エントロピーなどを用いて、少数クラスの誤りが損失へより大きく寄与するようにする。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『全クラスのラベルを同じ値へ書き換える。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『予測確率を使わず常に多数クラスを正解とする。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象となる誤った主張は『少数クラスのサンプルの損失をすべて0にして無視する。』である。重要クラスの学習信号を失ってしまう。 正しい理解の背景は次のとおりである。損失重み付けのほか、サンプリングや閾値調整、評価指標の選択も重要である。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0030 ニューラルネットワーク > 誤差関数・損失関数 ｜ 難易度：応用

実務上の判断で「データへの適合誤差だけでなくモデルの複雑さにも罰則を与え、汎化性能とのバランスを取る。」という考え方を採用した。その判断根拠として最も適切なものはどれか。

ア. 目的関数を「データ損失＋正則化項」とすることで、過度に複雑なパラメータを抑える。

イ. むしろ訓練誤差を多少許容して過学習を抑える場合がある。

ウ. ラベル生成機能ではない。

エ. 正則化項の勾配も含めて最適化できる。

答え・解説 **正答：ア**

ア：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『データへの適合誤差だけでなくモデルの複雑さにも罰則を与え、汎化性能とのバランスを取る。』である。

イ：この説明は別の論点『正則化項は訓練誤差を必ず0へするために加える。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『正則化項は正解ラベルを自動生成する。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『正則化項を加えるとパラメータ更新は数学的に不可能になる。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『データへの適合誤差だけでなくモデルの複雑さにも罰則を与え、汎化性能とのバランスを取る。』である。目的関数を「データ損失＋正則化項」とすることで、過度に複雑なパラメータを抑える。 背景となる論点は次のとおりである。L1・L2正則化は代表的な重みペナルティで、係数への作用が異なる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0031 学習アルゴリズム > 正則化・過学習対策 ｜ 難易度：基礎

教材の草案に「訓練データでもテストデータでも常に同程度に高性能な状態である。」とある。内容を訂正する際に示す説明として最も適切なものはどれか。

ア. これは良好な汎化に近く、過学習ではない。

イ. これは未学習・過少適合の説明に近い。

ウ. 過学習は訓練集合の細かなノイズまで学習し、汎化性能が悪化した状態を指す。

エ. 学習過程そのものがない状態であり過学習とは異なる。

答え・解説 **正答：ア**

ア：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『訓練データでもテストデータでも常に同程度に高性能な状態である。』である。

イ：この説明は別の論点『モデルが訓練データの規則性を十分に学べず訓練誤差も大きい状態である。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『訓練データにはよく適合する一方、未知データでは性能が低下する状態である。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『訓練データを一度も見ずに推論だけ行う状態である。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象となる誤った主張は『訓練データでもテストデータでも常に同程度に高性能な状態である。』である。これは良好な汎化に近く、過学習ではない。 正しい理解の背景は次のとおりである。訓練性能と検証性能の乖離は過学習を見つける代表的な手掛かりである。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0032 学習アルゴリズム > 正則化・過学習対策 ｜ 難易度：基礎

「大きな重みを罰することでパラメータを過度に大きくしにくくし、モデルの複雑さを抑える。」という説明を正しいと判断する際、最も適切な根拠はどれか。

ア. L2正則化は重みの二乗和を罰則として加え、滑らかな縮小を促す。

イ. L2は通常、重みを縮小するが必ず0にするわけではない。

ウ. 量子化の説明でありL2正則化ではない。

エ. データ拡張とは別の手法である。

答え・解説 **正答：ア**

ア：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『大きな重みを罰することでパラメータを過度に大きくしにくくし、モデルの複雑さを抑える。』である。

イ：この説明は別の論点『すべての重みを必ず厳密に0へする。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『各重みを整数へ丸めてモデルを軽量化する。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『訓練データを自動的に二倍に増やす。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『大きな重みを罰することでパラメータを過度に大きくしにくくし、モデルの複雑さを抑える。』である。L2正則化は重みの二乗和を罰則として加え、滑らかな縮小を促す。 背景となる論点は次のとおりである。L2正則化はweight decayとして実装されることも多く、過学習抑制の基本手段である。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0033 学習アルゴリズム > 正則化・過学習対策 ｜ 難易度：基礎

研修資料に「一部の重みを0にしやすく、疎なパラメータ表現を促す性質がある。」と記載されている。この記述を最も直接的に裏付ける説明はどれか。

ア. L1は重みの絶対値和を罰則にし、最適解で係数が0になりやすい。

イ. L1とL2は異なる罰則で作用も異なる。

ウ. L1正則化はそのような制約ではない。

エ. ネットワーク構造そのものを必ず変更する手法ではない。

答え・解説 **正答：ア**

ア：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『一部の重みを0にしやすく、疎なパラメータ表現を促す性質がある。』である。

イ：この説明は別の論点『重みの二乗和だけを罰するため、必ずL2と同じ解になる。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『すべての重みの絶対値を必ず1へ固定する。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『モデルの層数を自動的に1層へ減らす。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『一部の重みを0にしやすく、疎なパラメータ表現を促す性質がある。』である。L1は重みの絶対値和を罰則にし、最適解で係数が0になりやすい。 背景となる論点は次のとおりである。L1とL2は用途や望むパラメータ性質に応じて使い分ける。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0034 学習アルゴリズム > 正則化・過学習対策 ｜ 難易度：標準

ある受験者が「訓練データのラベルだけをランダムに変更する。」と回答した。この誤りを最も適切に指摘する説明はどれか。

ア. ユニットを無効化する手法でありラベルノイズを入れるものではない。

イ. 標準的には訓練時にランダム無効化し、推論時は対応するスケーリングで全体を使う。

ウ. Dropoutは訓練中にランダムなサブネットワークを使うことで過学習を抑える正則化法である。

エ. 重み共有とは別の考え方である。

答え・解説 **正答：ア**

ア：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『訓練データのラベルだけをランダムに変更する。』である。

イ：この説明は別の論点『推論時に必ず全ユニットをランダム削除して出力を不安定にする。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『訓練時に一部のユニットをランダムに無効化し、特定ユニット同士の過度な共適応を抑える。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『各層の重みを同じ値へ強制する。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象となる誤った主張は『訓練データのラベルだけをランダムに変更する。』である。ユニットを無効化する手法でありラベルノイズを入れるものではない。 正しい理解の背景は次のとおりである。Dropoutはモデルアンサンブルに近い効果を低コストで近似すると説明されることがある。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0035 学習アルゴリズム > 正則化・過学習対策 ｜ 難易度：標準

AI関連の資料レビューで「テストデータを毎更新で使い、テスト性能が最大になるまで調整する。」という記述が見つかった。レビューコメントとして最も適切なものはどれか。

ア. テストデータをモデル選択に使うと評価汚染につながる。

イ. 検証性能を見て停止時点を判断する。

ウ. 訓練を続けるほど訓練誤差は下がっても検証誤差が悪化する場合があり、その前に停止する。

エ. これは学習を停止しているだけでEarly Stoppingの運用とは異なる。

答え・解説 **正答：ア**

ア：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『テストデータを毎更新で使い、テスト性能が最大になるまで調整する。』である。

イ：この説明は別の論点『訓練開始前に必ず1エポックで終了すると決める。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『検証データの性能が改善しなくなった、または悪化し始めた時点で学習を止め、過学習を抑える。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『学習率を0に固定し、最初から重みを更新しない。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象となる誤った主張は『テストデータを毎更新で使い、テスト性能が最大になるまで調整する。』である。テストデータをモデル選択に使うと評価汚染につながる。 正しい理解の背景は次のとおりである。Early Stoppingでは独立した検証データを用いることが重要である。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0036 学習アルゴリズム > 正則化・過学習対策 ｜ 難易度：標準

次の主張「ラベルを保つ変換で入力の多様性を増やし、限られた訓練例への単純な記憶を減らせるためである。」について、その理由を最も正確に説明しているものはどれか。

ア. 画像の反転・切り出しなど、タスクに妥当な変換で実質的な訓練分布を広げる。

イ. 多様性を増やすのが狙いであり逆である。

ウ. ラベル整合性を壊すと学習が困難になる。

エ. データ拡張はパラメータ削減法ではない。

答え・解説 **正答：ア**

ア：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『ラベルを保つ変換で入力の多様性を増やし、限られた訓練例への単純な記憶を減らせるためである。』である。

イ：この説明は別の論点『すべての訓練例を同一画像へ変換してばらつきを消すためである。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『正解ラベルをランダム化し暗記しにくくするためである。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『モデルのパラメータ数を必ず半分に削減するためである。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『ラベルを保つ変換で入力の多様性を増やし、限られた訓練例への単純な記憶を減らせるためである。』である。画像の反転・切り出しなど、タスクに妥当な変換で実質的な訓練分布を広げる。 背景となる論点は次のとおりである。拡張は問題設定の不変性に沿って設計し、不自然な変換でラベル意味を変えないことが重要である。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0037 学習アルゴリズム > 正則化・過学習対策 ｜ 難易度：標準

学習者が「正則化強度は学習結果に一切影響しない。」と理解している。この理解を修正するための説明として最も適切なものはどれか。

ア. モデル容量やパラメータに直接影響する。

イ. 正則化は強すぎても弱すぎても問題で、バイアスとバリアンスのバランスが必要である。

ウ. 過度な制約で訓練誤差が増えることもある。

エ. データ数とは無関係である。

答え・解説 **正答：ア**

ア： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『正則化強度は学習結果に一切影響しない。』である。

イ： この説明は別の論点『モデルの自由度を抑えすぎて必要なパターンまで学べず、未学習が強まる可能性がある。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『正則化が強いほど訓練誤差もテスト誤差も必ず0になる。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『正則化を強くすると入力データの件数が自動的に増える。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『正則化強度は学習結果に一切影響しない。』である。モデル容量やパラメータに直接影響する。 正しい理解の背景は次のとおりである。正則化係数は検証データなどを用いて調整するハイパーパラメータである。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0038 学習アルゴリズム > 正則化・過学習対策 ｜ 難易度：標準

実務上の判断で「過学習が進み始めている可能性があり、Early Stoppingや正則化強化を検討する。」という考え方を採用した。その判断根拠として最も適切なものはどれか。

ア. 訓練と検証の乖離は汎化性能悪化の典型的シグナルである。

イ. 訓練損失が下がっているのに検証だけ悪化するのは過学習に近い。

ウ. 汎化評価の重要な指標である。

エ. 情報漏洩を起こし評価が不正確になる。

答え・解説 **正答：ア**

ア： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『過学習が進み始めている可能性があり、Early Stoppingや正則化強化を検討する。』である。

イ： この説明は別の論点『未学習が進んでいる証拠なのでモデル容量を必ず小さくする。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『検証損失は学習と無関係なので無視するのが正しい。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『テストデータを訓練へ混ぜれば評価が安定する。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『過学習が進み始めている可能性があり、Early Stoppingや正則化強化を検討する。』である。訓練と検証の乖離は汎化性能悪化の典型的シグナルである。 背景となる論点は次のとおりである。学習曲線を監視して、訓練・検証の両方の挙動を確認する。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0039 学習アルゴリズム > 正則化・過学習対策 ｜ 難易度：応用

教材の草案に「容量を減らすと訓練データのラベルが不要になるためである。」とある。内容を訂正する際に示す説明として最も適切なものはどれか。

ア. 減らしすぎれば未学習になる。

イ. 教師あり学習ではラベルは依然必要である。

ウ. ユニット数・層数・パラメータ数の削減は容量制御の一種である。

エ. 構造削減と活性化関数の自動変更は無関係である。

答え・解説 **正答：イ**

ア：この説明は別の論点『容量を減らすと必ず最適なモデルになるためである。』に対応するもので、今回示された主張を直接説明するものではない。

イ：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『容量を減らすと訓練データのラベルが不要になるためである。』である。

ウ：この説明は別の論点『訓練データ固有の細かなパターンまで表現する自由度を減らし、より単純な規則を学びやすくするためである。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『容量を減らすとすべての活性化関数がsoftmaxへ変わるためである。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象となる誤った主張は『容量を減らすと訓練データのラベルが不要になるためである。』である。教師あり学習ではラベルは依然必要である。 正しい理解の背景は次のとおりである。正則化はペナルティ・データ拡張・Early Stopping・容量制御など複数の方法を組み合わせる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0040 学習アルゴリズム > 正則化・過学習対策 ｜ 難易度：応用

「より多様な例を観測することで、限られた標本の偶然のパターンに依存しにくくなるためである。」という説明を正しいと判断する際、最も適切な根拠はどれか。

ア. データ増加は重みを0へ固定しない。

イ. データ量と多様性が増えると、モデルは一般的な規則を学びやすくなる。

ウ. 学習目標として損失は依然必要である。

エ. 量だけでなく質・代表性も重要である。

答え・解説 **正答：イ**

ア：この説明は別の論点『データを増やすとモデルの重みが自動的にすべて0になるためである。』に対応するもので、今回示された主張を直接説明するものではない。

イ：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『より多様な例を観測することで、限られた標本の偶然のパターンに依存しにくくなるためである。』である。

ウ：この説明は別の論点『データを増やすと損失関数が不要になるためである。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『データを増やせばデータ品質や分布の偏りを一切考えなくてよい。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『より多様な例を観測することで、限られた標本の偶然のパターンに依存しにくくなるためである。』である。データ量と多様性が増えると、モデルは一般的な規則を学びやすくなる。 背景となる論点は次のとおりである。追加データが対象分布を適切に代表しているかも汎化には重要である。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0041 学習アルゴリズム > 誤差逆伝播法 ｜ 難易度：基礎

研修資料に「出力側の損失から各パラメータが損失へ与える影響を効率的に計算し、勾配を求める。」と記載されている。この記述を最も直接的に裏付ける説明はどれか。

ア. 教師なし前処理の説明であり逆伝播ではない。

イ. 逆伝播は連鎖律を計算グラフへ適用し、多数の重みの偏微分を効率よく求める。

ウ. 勾配計算とは無関係である。

エ. データ順序ではなく微分情報を逆向きに伝える。

答え・解説 **正答：イ**

ア：この説明は別の論点『入力データを学習前にクラスタリングする。』に対応するもので、今回示された主張を直接説明するものではない。

イ：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『出力側の損失から各パラメータが損失へ与える影響を効率的に計算し、勾配を求める。』である。

ウ：この説明は別の論点『モデルの出力を必ず0か1へ丸める。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『訓練データを逆順に並べ替える。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『出力側の損失から各パラメータが損失へ与える影響を効率的に計算し、勾配を求める。』である。逆伝播は連鎖律を計算グラフへ適用し、多数の重みの偏微分を効率よく求める。 背景となる論点は次のとおりである。順伝播で中間値と損失を計算し、逆伝播で勾配を求めるのが基本的な学習サイクルである。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0042 学習アルゴリズム > 誤差逆伝播法 ｜ 難易度：基礎

ある受験者が「中心極限定理だけである。」と回答した。この誤りを最も適切に指摘する説明はどれか。

ア. 確率推論の基本則であり逆伝播の中心原理ではない。

イ. 統計的極限定理であり逆伝播の計算原理ではない。

ウ. 各層を合成関数とみなし、出力から入力側へ偏微分を掛け合わせて勾配を伝える。

エ. 幾何学の定理であり勾配伝播の原理ではない。

答え・解説 **正答：イ**

ア：この説明は別の論点『ベイズの定理だけである。』に対応するもので、今回示された主張を直接説明するものではない。

イ：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『中心極限定理だけである。』である。

ウ：この説明は別の論点『合成関数の微分に関する連鎖律である。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『ピタゴラスの定理だけである。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象となる誤った主張は『中心極限定理だけである。』である。統計的極限定理であり逆伝播の計算原理ではない。 正しい理解の背景は次のとおりである。自動微分ライブラリも計算グラフ上で連鎖律を効率的に適用している。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0043 学習アルゴリズム > 誤差逆伝播法 ｜ 難易度：基礎

AI関連の資料レビューで「中間値を保存するとモデルのパラメータ数が半分になるからである。」という記述が見つかった。レビューコメントとして最も適切なものはどれか。

ア. 保存自体は損失を変えない。

イ. メモリ使用量はむしろ増える場合がある。

ウ. ラベル読み込みとは別である。

エ. 活性化関数の導関数などは順伝播時の中間値を利用して効率よく計算される。

答え・解説 **正答：イ**

ア：この説明は別の論点『中間値を保存すると損失関数が自動的に0になるからである。』に対応するもので、今回示された主張を直接説明するものではない。

イ：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『中間値を保存するとモデルのパラメータ数が半分になるからである。』である。

ウ：この説明は別の論点『中間値がなければ正解ラベルを読み込めないからである。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『各演算の局所微分を評価するために、その演算時の入力や出力が必要になることが多いからである。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象となる誤った主張は『中間値を保存するとモデルのパラメータ数が半分になるからである。』である。メモリ使用量はむしろ増える場合がある。 正しい理解の背景は次のとおりである。逆伝播では計算量とメモリ使用量のトレードオフもあり、再計算を使う技法もある。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0044 学習アルゴリズム > 誤差逆伝播法 ｜ 難易度：標準

次の主張「wを小さくする方向へ更新する。」について、その理由を最も正確に説明しているものはどれか。

ア. これは勾配上昇方向である。

イ. 勾配降下法は $w \leftarrow w - \eta \partial L/\partial w$ と更新するため、正の勾配ならwは減少する。

ウ. 勾配の大きさに応じて更新するので必ず0ではない。

エ. 通常の勾配降下法では勾配を利用して決定的に更新する。

答え・解説 **正答：イ**

ア：この説明は別の論点『wを大きくする方向へ必ず更新する。』に対応するもので、今回示された主張を直接説明するものではない。

イ：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『wを小さくする方向へ更新する。』である。

ウ：この説明は別の論点『wを必ず0へ固定して以後更新しない。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『勾配の符号に関係なくwをランダム値へ置換する。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『wを小さくする方向へ更新する。』である。勾配降下法は $w \leftarrow w - \eta \partial L/\partial w$ と更新するため、正の勾配ならwは減少する。 背景となる論点は次のとおりである。勾配は損失が最も増える局所方向を示すため、その逆方向へ動かす。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0045 学習アルゴリズム > 誤差逆伝播法 ｜ 難易度：標準

学習者が「入力側へ進むほど勾配が必ず正確に1へ近づく。」と理解している。この理解を修正するための説明として最も適切なものはどれか。

ア. 深いネットワークでは連鎖律による積のため、導関数の値域が勾配の大きさに大きく影響する。

イ. 一般にはその保証はない。

ウ. これは勾配爆発に近い。

エ. 勾配消失の説明ではない。

答え・解説 **正答：イ**

ア： この説明は別の論点『多くの層で小さな導関数を連続して掛け合わせ、入力側へ届く勾配が極端に小さくなる。』に対応するもので、今回示された主張を直接説明するものではない。

イ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『入力側へ進むほど勾配が必ず正確に1へ近づく。』である。

ウ： この説明は別の論点『各層の導関数が常に非常に大きく、勾配が急増する。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『損失関数を一度も計算しなくても重みが自動更新される。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『入力側へ進むほど勾配が必ず正確に1へ近づく。』である。一般にはその保証はない。 正しい理解の背景は次のとおりである。活性化関数・初期化・正規化・スキップ結合などが勾配問題の緩和に使われる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0046 学習アルゴリズム > 誤差逆伝播法 ｜ 難易度：標準

実務上の判断で「逆伝播で大きな導関数や重みの積が繰り返され、勾配が非常に大きくなって更新が不安定になる現象である。」という考え方を採用した。その判断根拠として最も適切なものはどれか。

ア. これは勾配消失の説明である。

イ. 勾配が巨大になるとパラメータ更新が発散したり数値不安定を起こしたりする。

ウ. 学習手続きの省略とは異なる。

エ. 性能指標ではなく数値的な勾配問題である。

答え・解説 **正答：イ**

ア： この説明は別の論点『勾配がすべて0に近づき更新できなくなる現象である。』に対応するもので、今回示された主張を直接説明するものではない。

イ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『逆伝播で大きな導関数や重みの積が繰り返され、勾配が非常に大きくなって更新が不安定になる現象である。』である。

ウ： この説明は別の論点『勾配の計算を省略して推論だけ行う現象である。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『正解率が100%になったため学習を停止する現象である。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『逆伝播で大きな導関数や重みの積が繰り返され、勾配が非常に大きくなって更新が不安定になる現象である。』である。勾配が巨大になるとパラメータ更新が発散したり数値不安定を起こしたりする。 背景となる論点は次のとおりである。勾配クリッピングなどは勾配爆発への代表的対策である。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0047 学習アルゴリズム > 誤差逆伝播法 ｜ 難易度：標準

教材の草案に「損失関数を必ず凸関数へ変換する。」とある。内容を訂正する際に示す説明として最も適切なものはどれか。

ア. 自動微分は勾配計算でありNASではない。

イ. 非凸性を消す機能ではない。

ウ. ラベル生成機能ではない。

エ. 現代の深層学習フレームワークでは自動微分が逆伝播を実装する中核機能である。

答え・解説 **正答：イ**

ア：この説明は別の論点『モデルのアーキテクチャを必ず最適なものへ自動設計する。』に対応するもので、今回示された主張を直接説明するものではない。

イ：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『損失関数を必ず凸関数へ変換する。』である。

ウ：この説明は別の論点『正解ラベルを自動生成する。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『計算グラフを追跡して連鎖律を自動適用し、多数のパラメータに対する勾配を手計算せず求められる。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象となる誤った主張は『損失関数を必ず凸関数へ変換する。』である。非凸性を消す機能ではない。 正しい理解の背景は次のとおりである。自動微分は記号微分や数値微分とは異なり、計算過程を利用して正確な導関数を効率的に求める。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0048 学習アルゴリズム > 誤差逆伝播法 ｜ 難易度：標準

「数値微分はパラメータを少し変えて損失差から近似するため確認には使えるが、多数パラメータの学習には逆伝播の方がはるかに効率的である。」という説明を正しいと判断する際、最も適切な根拠はどれか。

ア. 多数パラメータでは非常に非効率である。

イ. 数値微分は勾配チェックには便利だが、パラメータごとに順伝播を繰り返すため計算負荷が高い。

ウ. 逆伝播は解析的な局所微分と連鎖律に基づく。

エ. 大きく異なる。

答え・解説 **正答：イ**

ア：この説明は別の論点『数値微分は常に逆伝播より高速で、深層学習の標準学習法である。』に対応するもので、今回示された主張を直接説明するものではない。

イ：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『数値微分はパラメータを少し変えて損失差から近似するため確認には使えるが、多数パラメータの学習には逆伝播の方がはるかに効率的である。』である。

ウ：この説明は別の論点『逆伝播は導関数を近似するだけで、数値微分だけが厳密な連鎖律を使う。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『両者は計算手順も計算量も完全に同じである。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『数値微分はパラメータを少し変えて損失差から近似するため確認には使えるが、多数パラメータの学習には逆伝播の方がはるかに効率的である。』である。数値微分は勾配チェックには便利だが、パラメータごとに順伝播を繰り返すため計算負荷が高い。 背景となる論点は次のとおりである。実装検証では小規模な数値微分との比較で勾配計算をチェックすることがある。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0049 学習アルゴリズム > 誤差逆伝播法 ｜ 難易度：応用

研修資料に「後段で求めた損失に対する勾配を再利用しながら、連鎖律で前段へ伝播すると計算を効率化できるためである。」と記載されている。この記述を最も直接的に裏付ける説明はどれか。

ア. 入力側の重みも最終損失へ影響する。

イ. 同じ部分微分を繰り返し計算せず、動的計画法のように後段の結果を共有できる。

ウ. 活性化関数は順伝播でも使用する。

エ. 勾配が0とは限らない。

答え・解説 **正答：イ**

ア： この説明は別の論点『入力層の重みは損失と一切関係しないからである。』に対応するもので、今回示された主張を直接説明するものではない。

イ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『後段で求めた損失に対する勾配を再利用しながら、連鎖律で前段へ伝播すると計算を効率化できるためである。』である。

ウ： この説明は別の論点『逆向きでなければ活性化関数を使えないからである。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『後段の勾配は必ず0なので簡単だからである。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『後段で求めた損失に対する勾配を再利用しながら、連鎖律で前段へ伝播すると計算を効率化できるためである。』である。同じ部分微分を繰り返し計算せず、動的計画法のように後段の結果を共有できる。 背景となる論点は次のとおりである。backpropagationの効率性は、計算グラフ上で中間勾配を再利用する点にある。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0050 学習アルゴリズム > 誤差逆伝播法 ｜ 難易度：応用

ある受験者が「本番学習中の全パラメータを毎回数値微分し、逆伝播を使わない。」と回答した。この誤りを最も適切に指摘する説明はどれか。

ア. 勾配チェックは学習前のデバッグ手段として使われる。

イ. 計算負荷が非常に大きく実用的でない。

ウ. 一致することが期待される。

エ. ラベルランダム化は目的ではない。

答え・解説 **正答：イ**

ア： この説明は別の論点『小さなモデルで逆伝播の解析的勾配と有限差分による数値勾配を比較し、実装ミスを検出する。』に対応するもので、今回示された主張を直接説明するものではない。

イ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『本番学習中の全パラメータを毎回数値微分し、逆伝播を使わない。』である。

ウ： この説明は別の論点『数値勾配と解析勾配が違うほど実装が正しいと判断する。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『勾配チェックでは正解ラベルを必ずランダム化する。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『本番学習中の全パラメータを毎回数値微分し、逆伝播を使わない。』である。計算負荷が非常に大きく実用的でない。 正しい理解の背景は次のとおりである。正則化やDropoutなど確率的要素を一時的に無効化して比較する場合もある。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0051 学習アルゴリズム > 勾配降下法・最適化手法 ｜ 難易度：基礎

AI関連の資料レビューで「勾配と同じ方向へ動かし損失を最大化する。」という記述が見つかった。レビューコメントとして最も適切なものはどれか。

ア. 最適化情報を使っていない。

イ. これは勾配上昇に相当する。

ウ. 勾配は損失が増加する局所方向を示すため、その負方向へ更新する。

エ. 通常は勾配と学習率に基づいて更新する。

答え・解説 **正答：イ**

ア： この説明は別の論点『勾配を無視して毎回すべてのパラメータを0へ戻す。』に対応するもので、今回示された主張を直接説明するものではない。

イ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『勾配と同じ方向へ動かし損失を最大化する。』である。

ウ： この説明は別の論点『損失関数の勾配と反対方向へパラメータを少しずつ動かす。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『学習率に関係なく常に同じ幅だけランダムに更新する。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『勾配と同じ方向へ動かし損失を最大化する。』である。これは勾配上昇に相当する。 正しい理解の背景は次のとおりである。更新幅は学習率と勾配の大きさで決まる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0052 学習アルゴリズム > 勾配降下法・最適化手法 ｜ 難易度：基礎

次の主張「最小値付近を飛び越えたり更新が発散したりして、損失が安定して下がらないことがある。」について、その理由を最も正確に説明しているものはどれか。

ア. これは学習率が小さすぎる場合の典型である。

イ. 学習率は一回の更新幅を制御し、大きすぎると不安定化しやすい。

ウ. 学習率はモデル構造を変えない。

エ. 損失の種類とは無関係である。

答え・解説 **正答：イ**

ア： この説明は別の論点『更新幅が小さくなりすぎて学習が極端に遅くなる。』に対応するもので、今回示された主張を直接説明するものではない。

イ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『最小値付近を飛び越えたり更新が発散したりして、損失が安定して下がらないことがある。』である。

ウ： この説明は別の論点『モデルのパラメータ数が自動的に減る。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『損失関数が自動的に交差エントロピーへ変わる。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『最小値付近を飛び越えたり更新が発散したりして、損失が安定して下がらないことがある。』である。学習率は一回の更新幅を制御し、大きすぎると不安定化しやすい。 背景となる論点は次のとおりである。学習率は最適化性能を左右する重要なハイパーパラメータである。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0053 学習アルゴリズム > 勾配降下法・最適化手法 ｜ 難易度：基礎

学習者が「必ず一回の更新で大域最適解へ到達する。」と理解している。この理解を修正するための説明として最も適切なものはどれか。

ア. 小さすぎる学習率は安定でも収束を遅くする。

イ. 更新幅が小さいためそのような保証はない。

ウ. 学習率が小さいこと自体は発散方向ではない。

エ. データ件数には影響しない。

答え・解説 **正答：イ**

ア： この説明は別の論点『更新が非常に小さくなり、良い解へ到達するまで多くの反復を要する可能性がある。』に対応するもので、今回示された主張を直接説明するものではない。

イ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『必ず一回の更新で大域最適解へ到達する。』である。

ウ： この説明は別の論点『勾配が自動的に巨大化し発散する。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『訓練データが自動的に増える。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『必ず一回の更新で大域最適解へ到達する。』である。更新幅が小さいためそのような保証はない。 正しい理解の背景は次のとおりである。学習率スケジューリングで学習初期と後期の更新幅を変える方法も広く使われる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0054 学習アルゴリズム > 勾配降下法・最適化手法 ｜ 難易度：標準

実務上の判断で「バッチ法は全訓練データから勾配を計算し、SGDは少数サンプルに基づくノイズを含む勾配で頻繁に更新する。」という考え方を採用した。その判断根拠として最も適切なものはどれか。

ア. SGDも勾配に基づいて更新する。

イ. SGDは一回の更新コストが小さく、大規模データで扱いやすい。

ウ. 説明が逆である。

エ. 更新単位が異なる。

答え・解説 **正答：イ**

ア： この説明は別の論点『SGDは勾配を一切計算しない。』に対応するもので、今回示された主張を直接説明するものではない。

イ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『バッチ法は全訓練データから勾配を計算し、SGDは少数サンプルに基づくノイズを含む勾配で頻繁に更新する。』である。

ウ： この説明は別の論点『バッチ法は必ず1サンプルだけ、SGDは必ず全サンプルを使う。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『両者はデータの使い方も更新頻度も完全に同じである。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『バッチ法は全訓練データから勾配を計算し、SGDは少数サンプルに基づくノイズを含む勾配で頻繁に更新する。』である。SGDは一回の更新コストが小さく、大規模データで扱いやすい。 背景となる論点は次のとおりである。実務では複数サンプルをまとめるミニバッチSGDが標準的に使われる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0055 学習アルゴリズム > 勾配降下法・最適化手法 ｜ 難易度：標準

教材の草案に「必ず全訓練データを一度の行列演算に収める必要がある。」とある。内容を訂正する際に示す説明として最も適切なものはどれか。

ア. 教師あり学習ではミニバッチ内のラベルを使う。

イ. 全バッチではなく一部データを使う。

ウ. ミニバッチは計算効率と勾配ノイズのバランスがよい。

エ. 一般には大きいほどメモリを多く使う。

答え・解説 **正答：イ**

ア：この説明は別の論点『各更新で正解ラベルを使わない。』に対応するもので、今回示された主張を直接説明するものではない。

イ：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『必ず全訓練データを一度の行列演算に収める必要がある。』である。

ウ：この説明は別の論点『計算資源を並列利用しやすく、全データ勾配より更新頻度を上げつつ、単一サンプルより安定した勾配を得やすい。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『バッチサイズを大きくするほどメモリ使用量は必ず減る。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象となる誤った主張は『必ず全訓練データを一度の行列演算に収める必要がある。』である。全バッチではなく一部データを使う。 正しい理解の背景は次のとおりである。バッチサイズは収束挙動・計算効率・メモリ量に影響する。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0056 学習アルゴリズム > 勾配降下法・最適化手法 ｜ 難易度：標準

「過去の更新方向を蓄積し、一貫した方向には加速しつつ細かな振動を抑える。」という説明を正しいと判断する際、最も適切な根拠はどれか。

ア. 過去情報を利用する手法である。

イ. Momentumは速度変数を持ち、谷方向への進行を滑らかにする。

ウ. そのような目的はない。

エ. 勾配と過去更新に依存して変化する。

答え・解説 **正答：イ**

ア：この説明は別の論点『過去の勾配をすべて無視して毎回初期化する。』に対応するもので、今回示された主張を直接説明するものではない。

イ：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『過去の更新方向を蓄積し、一貫した方向には加速しつつ細かな振動を抑える。』である。

ウ：この説明は別の論点『損失関数を非微分可能にする。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『全パラメータへ同じ固定値を加えるだけである。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『過去の更新方向を蓄積し、一貫した方向には加速しつつ細かな振動を抑える。』である。Momentumは速度変数を持ち、谷方向への進行を滑らかにする。 背景となる論点は次のとおりである。細長い損失地形でのジグザグを減らし、収束を速める効果が期待される。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0057 学習アルゴリズム > 勾配降下法・最適化手法 ｜ 難易度：標準

研修資料に「勾配の一次モーメントと二次モーメントを移動平均で推定し、パラメータごとに適応的な更新幅を調整する。」と記載されている。この記述を最も直接的に裏付ける説明はどれか。

ア. Adamは勾配統計に応じて更新量が変わる。

イ. AdamはMomentum的な一次モーメントとRMSProp的な二次モーメントの考え方を組み合わせる。

ウ. 一階勾配ベースの手法である。

エ. Adamは一階勾配ベースで、完全Hessianを必要としない。

答え・解説 **正答：イ**

ア： この説明は別の論点『全パラメータに常に同じ固定更新量を与える。』に対応するもので、今回示された主張を直接説明するものではない。

イ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『勾配の一次モーメントと二次モーメントを移動平均で推定し、パラメータごとに適応的な更新幅を調整する。』である。

ウ： この説明は別の論点『勾配を使わずランダム探索だけで最適化する。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『必ず二階微分の完全なHessian行列を計算する。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『勾配の一次モーメントと二次モーメントを移動平均で推定し、パラメータごとに適応的な更新幅を調整する。』である。AdamはMomentum的な一次モーメントとRMSProp的な二次モーメントの考え方を組み合わせる。 背景となる論点は次のとおりである。Adamは実装が容易で多くの深層学習で使われるが、常に最良とは限らずSGD系との比較も重要である。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0058 学習アルゴリズム > 勾配降下法・最適化手法 ｜ 難易度：標準

ある受験者が「訓練データのラベルを周期的に変更する。」と回答した。この誤りを最も適切に指摘する説明はどれか。

ア. 学習率制御であり構造変更ではない。

イ. ラベル編集とは無関係である。

ウ. 固定学習率では難しい探索と収束の両立を図る。

エ. 損失値はモデル予測に応じて変化する。

答え・解説 **正答：イ**

ア： この説明は別の論点『各エポックでモデルの層数を変更する。』に対応するもので、今回示された主張を直接説明するものではない。

イ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『訓練データのラベルを周期的に変更する。』である。

ウ： この説明は別の論点『学習初期は大きめに進み、後半は更新幅を小さくするなど、訓練段階に応じて学習率を調整する。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『損失関数の値を常に1へ固定する。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『訓練データのラベルを周期的に変更する。』である。ラベル編集とは無関係である。 正しい理解の背景は次のとおりである。step decay、cosine decay、warmupなど多様なスケジュールがある。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0059 学習アルゴリズム > 勾配降下法・最適化手法 ｜ 難易度：応用

AI関連の資料レビューで「勾配が0なら必ずテスト性能も最良になる。」という記述が見つかった。レビューコメントとして最も適切なものはどれか。

ア. 一般に非凸である。

イ. 勾配0は汎化性能を保証しない。

ウ. 深層ネットワークの最適化では鞍点や平坦領域など複雑な地形を扱う。

エ. 多次元で複雑な形状を持つ。

答え・解説 **正答：イ**

ア：この説明は別の論点『ニューラルネットの損失は常に厳密な凸関数なので局所性を考える必要はない。』に対応するもので、今回示された主張を直接説明するものではない。

イ：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『勾配が0なら必ずテスト性能も最良になる。』である。

ウ：この説明は別の論点『損失面は一般に非凸で、勾配が小さい点が必ずしも大域最小とは限らない。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『損失面はパラメータ数に関係なく常に一直線である。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象となる誤った主張は『勾配が0なら必ずテスト性能も最良になる。』である。勾配0は汎化性能を保証しない。 正しい理解の背景は次のとおりである。最適化で低損失点へ到達することと、未知データへの汎化は別の問題でもある。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0060 学習アルゴリズム > 勾配降下法・最適化手法 ｜ 難易度：応用

次の主張「勾配ノルムが過大になったとき上限を設け、更新の発散を抑えたい場合である。」について、その理由を最も正確に説明しているものはどれか。

ア. 勾配消失を改善する方法ではない。

イ. 勾配爆発への代表的な安定化手段である。

ウ. 重み量子化とは異なる。

エ. ラベル操作ではない。

答え・解説 **正答：イ**

ア：この説明は別の論点『勾配が小さすぎるとき必ず0へ切り捨てる。』に対応するもので、今回示された主張を直接説明するものではない。

イ：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『勾配ノルムが過大になったとき上限を設け、更新の発散を抑えたい場合である。』である。

ウ：この説明は別の論点『すべての重みを一定範囲へ量子化する。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『正解ラベルを一定範囲へ切り詰める。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『勾配ノルムが過大になったとき上限を設け、更新の発散を抑えたい場合である。』である。勾配爆発への代表的な安定化手段である。 背景となる論点は次のとおりである。特に再帰型ネットワークなどで勾配爆発対策としてよく使われる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0061 基本レイヤー > 全結合層 ｜ 難易度：基礎

学習者が「画像の局所領域だけに同じフィルタを適用する層である。」と理解している。この理解を修正するための説明として最も適切なものはどれか。

ア. 全結合層は入力ベクトルに重み行列を掛け、各出力が全入力の組合せを利用する。

イ. これは畳み込み層の説明である。

ウ. 全結合層では原則として全入力と接続する。

エ. これはプーリング層に近い説明である。

答え・解説 **正答：イ**

ア： この説明は別の論点『各出力ユニットが前の層のすべての入力ユニットと重みで接続される層である。』に対応するもので、今回示された主張を直接説明するものではない。

イ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『画像の局所領域だけに同じフィルタを適用する層である。』である。

ウ： この説明は別の論点『各出力ユニットが入力の一つとだけ固定的に接続される層である。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『空間サイズだけを縮小し、学習パラメータを持たない層である。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『画像の局所領域だけに同じフィルタを適用する層である。』である。これは畳み込み層の説明である。 正しい理解の背景は次のとおりである。全結合層は位置ごとの局所構造を仮定せず、入力全体を混合する。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0062 基本レイヤー > 全結合層 ｜ 難易度：基礎

実務上の判断で「重み2000個とバイアス20個の合計2020個である。」という考え方を採用した。その判断根拠として最も適切なものはどれか。

ア. 入力次元だけでは全結合層の重み数を表せない。

イ. 重み行列は20×100で2000要素、バイアスは出力ごとに20要素ある。

ウ. 入力数と出力数を単純加算した値ではない。

エ. バイアスも通常は学習パラメータに含まれる。

答え・解説 **正答：イ**

ア： この説明は別の論点『100個だけである。』に対応するもので、今回示された主張を直接説明するものではない。

イ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『重み2000個とバイアス20個の合計2020個である。』である。

ウ： この説明は別の論点『120個である。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『2000個だけで、バイアスはパラメータとして数えない。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『重み2000個とバイアス20個の合計2020個である。』である。重み行列は20×100で2000要素、バイアスは出力ごとに20要素ある。 背景となる論点は次のとおりである。全結合層のパラメータ数は入力次元×出力次元＋出力次元で求める。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0063 基本レイヤー > 全結合層 ｜ 難易度：基礎

教材の草案に「学習パラメータを半分に削除する。」とある。内容を訂正する際に示す説明として最も適切なものはどれか。

ア. Flattenは要素を並べ替えるだけで平均化ではない。

イ. Flatten自体はパラメータを持たないが削除処理でもない。

ウ. 従来のCNNでは畳み込み特徴を一次元化して全結合分類器へ接続する構成がよく使われた。

エ. 一次元化しても要素数は維持される。

答え・解説 **正答：イ**

ア： この説明は別の論点『画素値をすべて同じ値へ平均化して情報を一つにする。』に対応するもので、今回示された主張を直接説明するものではない。

イ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『学習パラメータを半分に削除する。』である。

ウ： この説明は別の論点『高さ・幅・チャネルを持つ多次元テンソルを、一つのベクトルへ並べ替えて全結合層へ渡せる形にする。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『特徴マップのチャネル数を必ず1へする。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『学習パラメータを半分に削除する。』である。Flatten自体はパラメータを持たないが削除処理でもない。 正しい理解の背景は次のとおりである。Flattenは空間的な配置情報をベクトル位置へ展開するため、後段の全結合層では局所構造を直接利用しにくくなる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0064 基本レイヤー > 全結合層 ｜ 難易度：標準

「特徴マップをFlattenすると入力次元が大きくなり、その全要素と各出力ユニットの間に個別重みが必要になるためである。」という説明を正しいと判断する際、最も適切な根拠はどれか。

ア. 重み共有は畳み込み層の特徴である。

イ. 全結合では入力次元と出力次元の積に比例して重み数が増える。

ウ. 多数の重み・バイアスを持つ。

エ. 有限だが大きくなり得る。

答え・解説 **正答：イ**

ア： この説明は別の論点『全結合層では各重みを画像の全位置で共有するためである。』に対応するもので、今回示された主張を直接説明するものではない。

イ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『特徴マップをFlattenすると入力次元が大きくなり、その全要素と各出力ユニットの間に個別重みが必要になるためである。』である。

ウ： この説明は別の論点『全結合層は学習パラメータを一切持たないためである。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『Flattenすると必ず入力要素数が無限大になるためである。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『特徴マップをFlattenすると入力次元が大きくなり、その全要素と各出力ユニットの間に個別重みが必要になるためである。』である。全結合では入力次元と出力次元の積に比例して重み数が増える。 背景となる論点は次のとおりである。GAPなどを使って大規模全結合層を減らす設計は、パラメータ削減や解釈性の面で利用される。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0065 基本レイヤー > 全結合層 ｜ 難易度：標準

研修資料に「全結合層は各出力が全入力へ接続する一方、畳み込み層は局所接続と重み共有を利用して空間構造を処理する。」と記載されている。この記述を最も直接的に裏付ける説明はどれか。

ア. 畳み込みフィルタも学習パラメータである。

イ. 画像では畳み込みの局所性と共有がパラメータ効率を高める。

ウ. 局所フィルタを位置ごとに共有する。

エ. 構造上の重要な違いがある。

答え・解説 **正答：イ**

ア：この説明は別の論点『全結合層だけが学習可能な重みを持ち、畳み込み層は重みを持たない。』に対応するもので、今回示された主張を直接説明するものではない。

イ：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『全結合層は各出力が全入力へ接続する一方、畳み込み層は局所接続と重み共有を利用して空間構造を処理する。』である。

ウ：この説明は別の論点『畳み込み層は入力全体へ異なる独立重みを一度だけ掛ける。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『両者は接続構造もパラメータ共有も完全に同じで名称だけ異なる。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『全結合層は各出力が全入力へ接続する一方、畳み込み層は局所接続と重み共有を利用して空間構造を処理する。』である。画像では畳み込みの局所性と共有がパラメータ効率を高める。 背景となる論点は次のとおりである。タスクの構造に応じて、局所性を利用する層と全体混合する層を使い分ける。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0066 基本レイヤー > 全結合層 ｜ 難易度：標準

ある受験者が「全結合層が直接正解ラベルを保存して推論時に検索する。」と回答した。この誤りを最も適切に指摘する説明はどれか。

ア. 入力次元に応じた重みを持つ。

イ. 重み付き特徴からスコアを計算する。

ウ. 全結合層がスコアを作り、シグモイドが二値確率へ写像する。

エ. 1出力シグモイドは二値分類で代表的である。

答え・解説 **正答：イ**

ア：この説明は別の論点『1ユニットなので学習可能な重みは存在しない。』に対応するもので、今回示された主張を直接説明するものではない。

イ：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『全結合層が直接正解ラベルを保存して推論時に検索する。』である。

ウ：この説明は別の論点『入力特徴を一つのロジットへ線形結合し、それを0〜1の確率へ変換する。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『シグモイドを使うと必ず多クラス分類になる。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象となる誤った主張は『全結合層が直接正解ラベルを保存して推論時に検索する。』である。重み付き特徴からスコアを計算する。 正しい理解の背景は次のとおりである。出力層のユニット数・活性化・損失をタスクに合わせることが重要である。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0067 基本レイヤー > 全結合層 ｜ 難易度：標準

AI関連の資料レビューで「10ユニットにすると損失関数が不要になる。」という記述が見つかった。レビューコメントとして最も適切なものはどれか。

ア. 入力次元は前段の出力に依存し、10に固定されない。

イ. 分類学習には損失が必要である。

ウ. 学習率とは無関係である。

エ. クラスごとのスコアを一つずつ持つ構成が自然である。

答え・解説 **正答：イ**

ア： この説明は別の論点『10ユニットにすると入力特徴量も必ず10個に制限される。』に対応するもので、今回示された主張を直接説明するものではない。

イ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『10ユニットにすると損失関数が不要になる。』である。

ウ： この説明は別の論点『10ユニットにすると学習率が自動で0.1になる。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『各ユニットが各クラスのロジットを出力し、softmaxで10クラスの相対確率を計算できるためである。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『10ユニットにすると損失関数が不要になる。』である。分類学習には損失が必要である。 正しい理解の背景は次のとおりである。最終層の形状は予測対象の形式に合わせて設計する。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0068 基本レイヤー > 全結合層 ｜ 難易度：標準

次の主張「線形変換だけの積み重ねでは得られない非線形な特徴変換を実現する。」について、その理由を最も正確に説明しているものはどれか。

ア. 重み共有を強制しない。

イ. Dense層の後にReLU等を置くことで複雑な関数近似が可能になる。

ウ. 次元削減は活性化の本質ではない。

エ. 微分可能または劣微分可能な関数なら逆伝播できる。

答え・解説 **正答：イ**

ア： この説明は別の論点『活性化関数を置くと全結合の重みがすべて同じになる。』に対応するもので、今回示された主張を直接説明するものではない。

イ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『線形変換だけの積み重ねでは得られない非線形な特徴変換を実現する。』である。

ウ： この説明は別の論点『活性化関数は入力次元を必ず半分にする。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『非線形活性化を使うと逆伝播が不可能になる。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『線形変換だけの積み重ねでは得られない非線形な特徴変換を実現する。』である。Dense層の後にReLU等を置くことで複雑な関数近似が可能になる。 背景となる論点は次のとおりである。全結合層＋活性化関数は多層パーセプトロンの基本ブロックである。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0069 基本レイヤー > 全結合層 ｜ 難易度：応用

学習者が「高次元入力にすると過学習は数学的に不可能になる。」と理解している。この理解を修正するための説明として最も適切なものはどれか。

ア. パラメータ数が入力次元×出力次元に比例するため、高次元入力ではコストが大きい。

イ. 容量増加で過学習しやすくなることもある。

ウ. 逆に増える。

エ. 多数のパラメータを持つ。

答え・解説 **正答：イ**

ア： この説明は別の論点『重み行列が巨大になり、メモリ・計算量・過学習リスクが増える。』に対応するもので、今回示された主張を直接説明するものではない。

イ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『高次元入力にすると過学習は数学的に不可能になる。』である。

ウ： この説明は別の論点『入力次元が増えるほどパラメータ数が自動的に減る。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『高次元入力では全結合層は必ずパラメータ0になる。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『高次元入力にすると過学習は数学的に不可能になる。』である。容量増加で過学習しやすくなることもある。 正しい理解の背景は次のとおりである。CNNでは局所接続・重み共有やGAPなどにより全結合の巨大化を抑える設計が使われる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0070 基本レイヤー > 全結合層 ｜ 難易度：応用

実務上の判断で「各特徴マップの空間方向を平均してチャネルごとの値に集約し、大規模全結合層のパラメータを減らせる。」という考え方を採用した。その判断根拠として最も適切なものはどれか。

ア. GAP自体は通常学習パラメータを持たない。

イ. GAPは空間平均により固定長のチャネルベクトルを作り、分類へ接続できる。

ウ. 空間方向を平均し縮約する。

エ. ランダム化手法ではない。

答え・解説 **正答：イ**

ア： この説明は別の論点『各画素に独立の重みを追加するため、全結合層より必ずパラメータが増える。』に対応するもので、今回示された主張を直接説明するものではない。

イ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『各特徴マップの空間方向を平均してチャネルごとの値に集約し、大規模全結合層のパラメータを減らせる。』である。

ウ： この説明は別の論点『すべてのチャネルを一つの画素へ結合して画像サイズを大きくする。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『出力を必ずランダム値にして正則化する。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『各特徴マップの空間方向を平均してチャネルごとの値に集約し、大規模全結合層のパラメータを減らせる。』である。GAPは空間平均により固定長のチャネルベクトルを作り、分類へ接続できる。 背景となる論点は次のとおりである。JDLA公式過去問題でもGAPがCNN出力部の要素技術として扱われている。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0071 基本レイヤー > 畳み込み層 ｜ 難易度：基礎

教材の草案に「画像を必ず一次元ベクトルへFlattenしてから局所処理する。」とある。内容を訂正する際に示す説明として最も適切なものはどれか。

ア. これは全結合層に近い。

イ. 畳み込みは通常空間構造を保ったまま行う。

ウ. 入力局所領域を用いて計算する。

エ. 畳み込みは局所受容野に同じカーネルを適用して空間特徴を抽出する。

答え・解説 **正答：イ**

ア：この説明は別の論点『画像全体の全画素と各出力を独立重みで完全接続する。』に対応するもので、今回示された主張を直接説明するものではない。

イ：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『画像を必ず一次元ベクトルへFlattenしてから局所処理する。』である。

ウ：この説明は別の論点『画素値を一切参照せずランダムな特徴マップを生成する。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『小さなフィルタを画像上で移動させ、局所領域との積和を計算して特徴マップを作る。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象となる誤った主張は『画像を必ず一次元ベクトルへFlattenしてから局所処理する。』である。畳み込みは通常空間構造を保ったまま行う。 正しい理解の背景は次のとおりである。局所接続と重み共有がCNNの重要な構造的特徴である。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0072 基本レイヤー > 畳み込み層 ｜ 難易度：基礎

「同じフィルタの重みを画像内の異なる位置へ繰り返し適用する。」という説明を正しいと判断する際、最も適切な根拠はどれか。

ア. これは共有と逆でパラメータ数も増える。

イ. 一つの特徴検出器を全位置で共有することでパラメータ数を抑え、位置に依存しない特徴検出を行う。

ウ. フィルタ内部には複数の学習可能な重みがある。

エ. ラベル共有ではない。

答え・解説 **正答：イ**

ア：この説明は別の論点『画像の各位置ごとに完全に異なるフィルタ重みを必ず用意する。』に対応するもので、今回示された主張を直接説明するものではない。

イ：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『同じフィルタの重みを画像内の異なる位置へ繰り返し適用する。』である。

ウ：この説明は別の論点『全チャネルの重みを必ず同じ一つの数値へ固定する。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『訓練データ間で正解ラベルを共有する。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『同じフィルタの重みを画像内の異なる位置へ繰り返し適用する。』である。一つの特徴検出器を全位置で共有することでパラメータ数を抑え、位置に依存しない特徴検出を行う。 背景となる論点は次のとおりである。重み共有はCNNのパラメータ効率と平行移動に対する特徴抽出の性質に寄与する。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0073 基本レイヤー > 畳み込み層 ｜ 難易度：基礎

研修資料に「近接画素の局所パターンを捉えつつ、全結合より少ないパラメータで画像の空間構造を利用できる。」と記載されている。この記述を最も直接的に裏付ける説明はどれか。

ア. 局所受容野では参照領域を限定する。

イ. エッジやテクスチャなど局所特徴は小さな領域から抽出できる。

ウ. 層を重ねると実効受容野は広がる。

エ. 共有と局所接続で一般に大幅に減らせる。

答え・解説 **正答：イ**

ア： この説明は別の論点『各出力が必ず画像全体の全画素を一度に参照する。』に対応するもので、今回示された主張を直接説明するものではない。

イ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『近接画素の局所パターンを捉えつつ、全結合より少ないパラメータで画像の空間構造を利用できる。』である。

ウ： この説明は別の論点『局所受容野を使うと深い層でも受容野が広がらない。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『局所受容野はパラメータ数を全結合より必ず増やす。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『近接画素の局所パターンを捉えつつ、全結合より少ないパラメータで画像の空間構造を利用できる。』である。エッジやテクスチャなど局所特徴は小さな領域から抽出できる。 背景となる論点は次のとおりである。深いCNNでは局所特徴を積み重ねてより広域・高次の特徴を表現する。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0074 基本レイヤー > 畳み込み層 ｜ 難易度：標準

ある受験者が「フィルタのチャネル数を必ず2倍にする。」と回答した。この誤りを最も適切に指摘する説明はどれか。

ア. strideはカーネルの移動幅であり、2にすれば1より出力位置数が少なくなる。

イ. ストライドは移動間隔でチャネル数を直接決めない。

ウ. 画素変換規則ではない。

エ. 一般には小さくなる。

答え・解説 **正答：イ**

ア： この説明は別の論点『フィルタを移動させる間隔が広がり、出力特徴マップの空間サイズが小さくなりやすい。』に対応するもので、今回示された主張を直接説明するものではない。

イ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『フィルタのチャネル数を必ず2倍にする。』である。

ウ： この説明は別の論点『入力画像の画素値を自動的に二乗する。』に対応するもので、今回示された主張を直接説明するものではない。

エ： この説明は別の論点『ストライドを大きくすると出力空間サイズは必ず大きくなる。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『フィルタのチャネル数を必ず2倍にする。』である。ストライドは移動間隔でチャネル数を直接決めない。 正しい理解の背景は次のとおりである。ストライド付き畳み込みはダウンサンプリングにも利用される。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0075 基本レイヤー > 畳み込み層 ｜ 難易度：標準

AI関連の資料レビューで「フィルタの学習率を自動調整する。」という記述が見つかった。レビューコメントとして最も適切なものはどれか。

ア. 出力チャネル数はフィルタ数で決まる。

イ. パディングは入力境界処理である。

ウ. 適切なpaddingによりstride=1で入出力の高さ・幅を保つsame convolutionが可能になる。

エ. 周囲へ値を追加するだけで内部画素を同一化しない。

答え・解説 **正答：イ**

ア：この説明は別の論点『出力チャネル数を必ず1へ減らす。』に対応するもので、今回示された主張を直接説明するものではない。

イ：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『フィルタの学習率を自動調整する。』である。

ウ：この説明は別の論点『入力の周囲に値を追加し、出力サイズを調整したり端付近の特徴を扱いやすくしたりする。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『すべての入力画素を同じ値へ置き換える。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象となる誤った主張は『フィルタの学習率を自動調整する。』である。パディングは入力境界処理である。 正しい理解の背景は次のとおりである。JDLA公式過去問題でも、パディングの効果として出力サイズ調整が問われている。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0076 基本レイヤー > 畳み込み層 ｜ 難易度：標準

次の主張「32チャネルになる。」について、その理由を最も正確に説明しているものはどれか。

ア. 出力チャネル数は入力チャネル数に固定されず、使用するフィルタ数で決まる。

イ. 各フィルタが1枚の特徴マップを生成するため、フィルタ数が出力チャネル数になる。

ウ. カーネルの空間サイズと出力チャネル数は別の概念である。

エ. カーネル内部の要素数ではなく、フィルタ1枚につき1つの出力特徴マップが生成される。

答え・解説 **正答：イ**

ア：この説明は別の論点『入力が1チャネルなので、フィルタ枚数に関係なく出力も1チャネルへ固定される。』に対応するもので、今回示された主張を直接説明するものではない。

イ：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『32チャネルになる。』である。

ウ：この説明は別の論点『カーネルの横幅3を出力チャネル数とみなし、3チャネルになる。』に対応するもので、今回示された主張を直接説明するものではない。

エ：この説明は別の論点『3×3カーネルの9要素がそれぞれ特徴マップを作るため、9チャネルになる。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『32チャネルになる。』である。各フィルタが1枚の特徴マップを生成するため、フィルタ数が出力チャネル数になる。 背景となる論点は次のとおりである。複数入力チャネルの場合、各フィルタは通常すべての入力チャネル方向に深さを持つ。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0077 基本レイヤー > 畳み込み層 ｜ 難易度：標準

学習者が「各層でフィルタサイズが自動的に無限大になるためである。」と理解している。この理解を修正するための説明として最も適切なものはどれか。

ア. 局所演算を階層的に合成すると、深い層ほど元入力の広い範囲の影響を受ける。

イ. 畳み込みのままでも広がる。

ウ. フィルタサイズが3×3のままでも受容野は広がる。

エ. 画像拡大ではなく依存範囲が広がる。

答え・解説 **正答：ウ**

ア： この説明は別の論点『後段の1ユニットが前段の複数ユニットを参照し、その前段ユニットがさらに元画像の周辺領域を参照するためである。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『重み共有をやめて全結合へ変わるためである。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『各層でフィルタサイズが自動的に無限大になるためである。』である。

エ： この説明は別の論点『各層で入力画像そのものを物理的に拡大するためである。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『各層でフィルタサイズが自動的に無限大になるためである。』である。フィルタサイズが3×3のままでも受容野は広がる。 正しい理解の背景は次のとおりである。小さなカーネルの積み重ねで非線形性を増やしつつ広い受容野を得る設計が多い。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0078 基本レイヤー > 畳み込み層 ｜ 難易度：標準

実務上の判断で「各空間位置でチャネル方向の線形結合を行い、チャネル数の変換や特徴混合に使える。」という考え方を採用した。その判断根拠として最も適切なものはどれか。

ア. カーネルサイズが1×1でも空間サイズはstride等に依存する。

イ. これはmax poolingに近い。

ウ. 1×1カーネルは空間近傍を広げず、同一位置のチャネル情報を混合する。

エ. 1×1畳み込みにも重みがある。

答え・解説 **正答：ウ**

ア： この説明は別の論点『必ず画像の高さと幅を1×1へ縮小する。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『近傍3×3領域の最大値を取る。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『各空間位置でチャネル方向の線形結合を行い、チャネル数の変換や特徴混合に使える。』である。

エ： この説明は別の論点『学習パラメータを一切持たない。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『各空間位置でチャネル方向の線形結合を行い、チャネル数の変換や特徴混合に使える。』である。1×1カーネルは空間近傍を広げず、同一位置のチャネル情報を混合する。 背景となる論点は次のとおりである。ボトルネック構造などでチャネル圧縮・拡張に使われる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0079 基本レイヤー > 畳み込み層 ｜ 難易度：応用

教材の草案に「画像ではすべての画素が独立なので局所構造を無視するためである。」とある。内容を訂正する際に示す説明として最も適切なものはどれか。

ア. フィルタはデータから学習される。

イ. 画像の空間構造に合わせた仮定をモデル構造へ組み込んでいる。

ウ. 画像には局所的な相関があることが多い。

エ. 空間配置を活用する。

答え・解説 **正答：ウ**

ア： この説明は別の論点『CNNは学習せず固定フィルタだけを使うためである。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『画像の局所相関と、同じパターンが異なる位置に現れ得る性質を局所接続・重み共有で取り込むためである。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『画像ではすべての画素が独立なので局所構造を無視するためである。』である。

エ： この説明は別の論点『CNNでは入力画像の位置情報を完全に削除してから処理するためである。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『画像ではすべての画素が独立なので局所構造を無視するためである。』である。画像には局所的な相関があることが多い。 正しい理解の背景は次のとおりである。帰納バイアスにより必要データ量やパラメータ効率が改善することがある。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0080 基本レイヤー > 畳み込み層 ｜ 難易度：応用

「同じフィルタ重みを全空間位置で共有するため、画像が広くてもフィルタ自体の重み数は増えない。」という説明を正しいと判断する際、最も適切な根拠はどれか。

ア. 位置ごとに独立重みを持たないのが理由である。

イ. フィルタ重みを学習する。

ウ. パラメータ数は主にカーネルサイズ・入力チャネル数・出力チャネル数で決まる。

エ. そのような前処理は必須でない。

答え・解説 **正答：ウ**

ア： この説明は別の論点『画像サイズが大きくなると各位置の重みを削除するためである。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『畳み込み層にはそもそも学習可能な重みが存在しないためである。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『同じフィルタ重みを全空間位置で共有するため、画像が広くてもフィルタ自体の重み数は増えない。』である。

エ： この説明は別の論点『高さと幅を必ず1に縮小してから重みを持つためである。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『同じフィルタ重みを全空間位置で共有するため、画像が広くてもフィルタ自体の重み数は増えない。』である。パラメータ数は主にカーネルサイズ・入力チャネル数・出力チャネル数で決まる。 背景となる論点は次のとおりである。重み共有は大きな画像でもパラメータ効率を保つ重要な仕組みである。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0081 基本レイヤー > プーリング層 ｜ 難易度：基礎

研修資料に「局所領域内の最大値を代表値として取り出し、特徴マップを縮小する。」と記載されている。この記述を最も直接的に裏付ける説明はどれか。

ア. 通常のpoolingはそのような重みを持たない。

イ. 最大値を選ぶ。

ウ. Max Poolingは各窓内の最大応答を残すダウンサンプリング手法である。

エ. 局所窓ごとの集約である。

答え・解説 **正答：ウ**

ア： この説明は別の論点『局所領域内のすべての値を学習可能な重みで全結合する。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『局所領域内の値を必ず合計して出力する。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『局所領域内の最大値を代表値として取り出し、特徴マップを縮小する。』である。

エ： この説明は別の論点『画像全体を一つのベクトルへFlattenする処理である。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『局所領域内の最大値を代表値として取り出し、特徴マップを縮小する。』である。Max Poolingは各窓内の最大応答を残すダウンサンプリング手法である。 背景となる論点は次のとおりである。Poolingは空間解像度を下げ、計算量や位置変化への感度を調整する。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0082 基本レイヤー > プーリング層 ｜ 難易度：基礎

ある受験者が「局所領域の最小値だけを残すことが定義である。」と回答した。この誤りを最も適切に指摘する説明はどれか。

ア. これはMax Poolingである。

イ. Average Poolingは窓内の応答を平均化してダウンサンプリングする。

ウ. 平均を用いる。

エ. 通常の平均プーリングは固定集約である。

答え・解説 **正答：ウ**

ア： この説明は別の論点『局所領域の最大値だけを残す。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『局所領域の値の平均を計算して代表値とする。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『局所領域の最小値だけを残すことが定義である。』である。

エ： この説明は別の論点『学習可能な3×3フィルタで必ず畳み込む。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『局所領域の最小値だけを残すことが定義である。』である。平均を用いる。 正しい理解の背景は次のとおりである。最大値と平均値では残す情報の性質が異なる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0083 基本レイヤー > プーリング層 ｜ 難易度：基礎

AI関連の資料レビューで「学習可能パラメータを大量追加して容量を増やす。」という記述が見つかった。レビューコメントとして最も適切なものはどれか。

ア. チャネル数は通常そのまま保つ。

イ. ダウンサンプリングにより表現を圧縮し、ある程度の位置変化に対する頑健性も得やすい。

ウ. 一般的なpoolingはパラメータを持たない。

エ. ラベル操作ではない。

答え・解説 **正答：ウ**

ア： この説明は別の論点『出力チャネルを必ずクラス数と同じにする。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『特徴マップの空間サイズを小さくし、後段の計算量を減らしつつ局所的な特徴を集約する。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『学習可能パラメータを大量追加して容量を増やす。』である。

エ： この説明は別の論点『正解ラベルを特徴マップへ埋め込む。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『学習可能パラメータを大量追加して容量を増やす。』である。一般的なpoolingはパラメータを持たない。 正しい理解の背景は次のとおりである。Poolingは情報を捨てるため、使いすぎると細かな空間情報が失われる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0084 基本レイヤー > プーリング層 ｜ 難易度：標準

次の主張「高さと幅を概ね半分にし、各2×2領域の最大応答を残す。」について、その理由を最も正確に説明しているものはどれか。

ア. ダウンサンプリングなので逆である。

イ. 通常チャネル数は変えない。

ウ. 重なりなしの2×2 stride 2なら空間解像度を約1/2ずつに縮小する。

エ. 代表値1つに集約する。

答え・解説 **正答：ウ**

ア： この説明は別の論点『高さと幅を必ず2倍に拡大する。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『チャネル数を必ず4倍にする。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『高さと幅を概ね半分にし、各2×2領域の最大応答を残す。』である。

エ： この説明は別の論点『各領域の4値をすべて保存するため要素数は変わらない。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『高さと幅を概ね半分にし、各2×2領域の最大応答を残す。』である。重なりなしの2×2 stride 2なら空間解像度を約1/2ずつに縮小する。 背景となる論点は次のとおりである。空間サイズ減少により後段の計算コストも下げられる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0085 基本レイヤー > プーリング層 ｜ 難易度：標準

学習者が「Maxだけが学習可能重みを持ち、Averageは持たない。」と理解している。この理解を修正するための説明として最も適切なものはどれか。

ア. Maxは顕著な特徴、Averageは平均的な存在量を反映しやすい。

イ. 入力値が特別な場合を除き一般には異なる。

ウ. 通常どちらも学習可能重みを持たない。

エ. 同じ窓とstrideならどちらも同様に縮小できる。

答え・解説 **正答：ウ**

ア：この説明は別の論点『Maxは領域内の強い応答を選び、Averageは領域内の応答を平均化するため、保持する情報の性質が異なる。』に対応するもので、今回示された主張を直接説明するものではない。

イ：この説明は別の論点『両者は数式も出力も常に完全に同じである。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『Maxだけが学習可能重みを持ち、Averageは持たない。』である。

エ：この説明は別の論点『Averageは空間サイズを大きくし、Maxだけが縮小する。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象となる誤った主張は『Maxだけが学習可能重みを持ち、Averageは持たない。』である。通常どちらも学習可能重みを持たない。 正しい理解の背景は次のとおりである。どの集約が適切かはネットワーク設計やタスクに依存する。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0086 基本レイヤー > プーリング層 ｜ 難易度：標準

実務上の判断で「各チャネルの特徴マップ全体を平均し、チャネルごとに1つの値へ集約する。」という考え方を採用した。その判断根拠として最も適切なものはどれか。

ア. 通常はチャネルごとに値を残す。

イ. それはGlobal Max Poolingである。

ウ. GAPはH×Wの空間次元を1×1へ平均集約する。

エ. GAP自体は固定平均である。

答え・解説 **正答：ウ**

ア：この説明は別の論点『すべてのチャネルをまとめて一つの値だけにすることが必須である。』に対応するもので、今回示された主張を直接説明するものではない。

イ：この説明は別の論点『各チャネルの最大値を取る処理だけを指す。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『各チャネルの特徴マップ全体を平均し、チャネルごとに1つの値へ集約する。』である。

エ：この説明は別の論点『画像の各位置に独立の学習重みを追加する。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『各チャネルの特徴マップ全体を平均し、チャネルごとに1つの値へ集約する。』である。GAPはH×Wの空間次元を1×1へ平均集約する。 背景となる論点は次のとおりである。GAPは大規模全結合層を減らし、特徴マップとクラス出力の対応を持たせやすい。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0087 基本レイヤー > プーリング層 ｜ 難易度：標準

教材の草案に「プーリングが特徴の位置を正確に保存するためである。」とある。内容を訂正する際に示す説明として最も適切なものはどれか。

ア. 全情報を同一化するわけではない。

イ. 局所集約により位置の微小変化に対する感度を下げる効果が得られる場合がある。

ウ. むしろ細かな位置情報を一部失う。

エ. 畳み込みの重み共有とは別である。

答え・解説 **正答：ウ**

ア：この説明は別の論点『プーリングが入力画像を常に同じ画像へ変換するためである。』に対応するもので、今回示された主張を直接説明するものではない。

イ：この説明は別の論点『近接領域の応答を一つの代表値へ集約するため、特徴の位置が窓内で少し動いても同じような値が残ることがある。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『プーリングが特徴の位置を正確に保存するためである。』である。

エ：この説明は別の論点『プーリングが重み共有を禁止するためである。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象となる誤った主張は『プーリングが特徴の位置を正確に保存するためである。』である。むしろ細かな位置情報を一部失う。 正しい理解の背景は次のとおりである。完全な平行移動不変性を保証するわけではなく、設計や境界処理にも依存する。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0088 基本レイヤー > プーリング層 ｜ 難易度：標準

「空間解像度が下がりすぎ、物体位置や細かな構造に必要な情報を失う可能性がある。」という説明を正しいと判断する際、最も適切な根拠はどれか。

ア. 通常は縮小する。

イ. pooling自体は通常パラメータを持たない。

ウ. ダウンサンプリングは計算量を減らす一方で情報損失を伴う。

エ. 情報損失により逆に難しくなることがある。

答え・解説 **正答：ウ**

ア：この説明は別の論点『空間解像度が毎回増え、メモリ使用量が必ず発散する。』に対応するもので、今回示された主張を直接説明するものではない。

イ：この説明は別の論点『学習パラメータ数が必ず指数的に増える。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『空間解像度が下がりすぎ、物体位置や細かな構造に必要な情報を失う可能性がある。』である。

エ：この説明は別の論点『プーリングを増やすほど元画像を完全に再構成しやすくなる。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『空間解像度が下がりすぎ、物体位置や細かな構造に必要な情報を失う可能性がある。』である。ダウンサンプリングは計算量を減らす一方で情報損失を伴う。 背景となる論点は次のとおりである。セグメンテーションや検出など位置情報が重要なタスクでは、解像度維持やアップサンプリング設計が重要になる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0089 基本レイヤー > プーリング層 ｜ 難易度：応用

研修資料に「どちらも空間サイズを縮小できるが、stride付き畳み込みは学習可能なフィルタでダウンサンプリングできる。」と記載されている。この記述を最も直接的に裏付ける説明はどれか。

ア. 畳み込みフィルタを学習する。

イ. stride>1の畳み込みでも縮小できる。

ウ. 固定集約のpoolingに対し、stride convolutionは縮小方法そのものを学習できる。

エ. 演算が異なるため一般には異なる。

答え・解説 **正答：ウ**

ア： この説明は別の論点『stride付き畳み込みは学習パラメータを一切持たない。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『Poolingだけが空間サイズを変更でき、畳み込みでは不可能である。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『どちらも空間サイズを縮小できるが、stride付き畳み込みは学習可能なフィルタでダウンサンプリングできる。』である。

エ： この説明は別の論点『両者は常に同じ数値を出力する。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『どちらも空間サイズを縮小できるが、stride付き畳み込みは学習可能なフィルタでダウンサンプリングできる。』である。固定集約のpoolingに対し、stride convolutionは縮小方法そのものを学習できる。 背景となる論点は次のとおりである。近年のCNNではpoolingを減らしstride convolutionで縮小する構成も多い。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0090 基本レイヤー > プーリング層 ｜ 難易度：応用

ある受験者が「GAPを使うと出力チャネル数が必ず1になる。」と回答した。この誤りを最も適切に指摘する説明はどれか。

ア. GAP自体には通常学習重みがない。

イ. GAPは固定集約で、後段の全結合パラメータ爆発を避けやすい。

ウ. チャネルごとに平均するためチャネル数は残る。

エ. 平均により細かな位置情報は失われる。

答え・解説 **正答：ウ**

ア： この説明は別の論点『GAPは各画素に個別重みを置くためパラメータが必ず増える。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『空間を平均集約するため学習パラメータを大幅に減らせ、特徴マップと出力の対応も保ちやすい。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『GAPを使うと出力チャネル数が必ず1になる。』である。

エ： この説明は別の論点『Flattenより必ず多くの空間位置情報を保持する。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『GAPを使うと出力チャネル数が必ず1になる。』である。チャネルごとに平均するためチャネル数は残る。 正しい理解の背景は次のとおりである。公式過去問題でも、GAPの導入により特徴マップと出力結果の関連が強くなり解釈しやすくなる点が扱われている。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0091 ネットワーク構造 > 正規化層 ｜ 難易度：基礎

AI関連の資料レビューで「出力層のクラス確率だけを正規化する。」という記述が見つかった。レビューコメントとして最も適切なものはどれか。

ア. BatchNormは平均・分散で正規化した後、学習可能な係数で表現力を保つ。

イ. 二値化を目的とする処理ではない。

ウ. 中間層にも用いられ、クラス確率の正規化に限定されない。

エ. これはDropoutに近い説明で、BatchNormの定義ではない。

答え・解説 **正答：ウ**

ア： この説明は別の論点『ミニバッチ内の統計量で活性を正規化し、その後に学習可能なスケールとシフトを適用する。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『各サンプルを必ず0か1の二値へ変換する。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『出力層のクラス確率だけを正規化する。』である。

エ： この説明は別の論点『重みをランダムに0へすることで過学習だけを防ぐ。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『出力層のクラス確率だけを正規化する。』である。中間層にも用いられ、クラス確率の正規化に限定されない。 正しい理解の背景は次のとおりである。BatchNormは層の活性を正規化して学習を安定化しつつ、gammaとbetaに相当する学習可能パラメータで適切なスケールと位置を再学習できる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0092 ネットワーク構造 > 正規化層 ｜ 難易度：基礎

次の主張「学習時は主にミニバッチ統計を用い、推論時は学習中に蓄積した移動平均などの統計量を用いる。」について、その理由を最も正確に説明しているものはどれか。

ア. 推論データを固定ミニバッチとして保存する必要はない。

イ. 推論時も学習済み統計量とスケール・シフトを用いて変換する。

ウ. 一般的なBatchNormでは学習時と推論時で参照する統計量の扱いが異なる。

エ. 推論に正解ラベルは不要である。

答え・解説 **正答：ウ**

ア： この説明は別の論点『学習時も推論時も必ず同じ一つのミニバッチを保持して使う。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『推論時には正規化を完全に取り除き、常に恒等写像にする。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『学習時は主にミニバッチ統計を用い、推論時は学習中に蓄積した移動平均などの統計量を用いる。』である。

エ： この説明は別の論点『推論時だけラベル情報を使って平均と分散を計算する。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『学習時は主にミニバッチ統計を用い、推論時は学習中に蓄積した移動平均などの統計量を用いる。』である。一般的なBatchNormでは学習時と推論時で参照する統計量の扱いが異なる。 背景となる論点は次のとおりである。BatchNormを含むモデルではtrain/evalモードの切替が重要で、推論時にその場の小さなバッチ統計へ依存させない実装が一般的である。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0093 ネットワーク構造 > 正規化層 ｜ 難易度：基礎

学習者が「分類問題を教師なし学習へ変換する。」と理解している。この理解を修正するための説明として最も適切なものはどれか。

ア. データ拡張とは異なる。

イ. 重みを固定する手法ではない。

ウ. 学習方式そのものを教師なしへ変えるものではない。

エ. 正規化は活性の分布やスケールを調整し、学習の安定化に寄与する。

答え・解説 **正答：ウ**

ア：この説明は別の論点『訓練データを自動的に増やして標本数を2倍にする。』に対応するもので、今回示された主張を直接説明するものではない。

イ：この説明は別の論点『全ての重みを同じ値へ固定してモデルを単純化する。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『分類問題を教師なし学習へ変換する。』である。

エ：この説明は別の論点『活性のスケールを整えて最適化を安定させ、より大きな学習率を使いやすくするなど学習を容易にする。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象となる誤った主張は『分類問題を教師なし学習へ変換する。』である。学習方式そのものを教師なしへ変えるものではない。 正しい理解の背景は次のとおりである。正規化層は最適化を助ける要素技術であり、入力データの追加生成やタスク形式の変更とは役割が異なる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0094 ネットワーク構造 > 正規化層 ｜ 難易度：標準

実務上の判断で「正規化で一律に固定された表現にせず、タスクに必要なスケールや平均位置をネットワークが再調整できるようにするため。」という考え方を採用した。その判断根拠として最も適切なものはどれか。

ア. サンプル数はこれらの係数では変化しない。

イ. BatchNormの係数も勾配法で学習される。

ウ. 学習可能なアフィン変換により、正規化後も必要な表現を選べる。

エ. クラス分布を直接変更するパラメータではない。

答え・解説 **正答：ウ**

ア：この説明は別の論点『入力サンプル数そのものを学習で変更するため。』に対応するもので、今回示された主張を直接説明するものではない。

イ：この説明は別の論点『勾配計算を不要にして解析解だけで学習するため。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『正規化で一律に固定された表現にせず、タスクに必要なスケールや平均位置をネットワークが再調整できるようにするため。』である。

エ：この説明は別の論点『正解ラベルの個数をクラスごとに均等化するため。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『正規化で一律に固定された表現にせず、タスクに必要なスケールや平均位置をネットワークが再調整できるようにするため。』である。学習可能なアフィン変換により、正規化後も必要な表現を選べる。 背景となる論点は次のとおりである。正規化だけでは表現を制約し過ぎる場合があるため、学習可能なスケール・シフトを組み合わせる設計になっている。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0095 ネットワーク構造 > 正規化層 ｜ 難易度：標準

教材の草案に「全てのパラメータが自動的に共有重みへ変換される。」とある。内容を訂正する際に示す説明として最も適切なものはどれか。

ア. BatchNormはバッチ統計に依存するため、極小バッチでは統計推定が不安定になりやすい。

イ. 活性化関数の種類はBatchNormが強制変更しない。

ウ. 重み共有の構造を変更する機構ではない。

エ. 畳み込みはBatchNormの有無にかかわらず実行できる。

答え・解説 **正答：ウ**

ア： この説明は別の論点『ミニバッチから推定する平均や分散が不安定になり、正規化の挙動がばらつきやすい。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『活性化関数が必ず線形関数に変わる。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『全てのパラメータが自動的に共有重みへ変換される。』である。

エ： この説明は別の論点『畳み込み演算そのものが実行できなくなる。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『全てのパラメータが自動的に共有重みへ変換される。』である。重み共有の構造を変更する機構ではない。 正しい理解の背景は次のとおりである。小バッチ環境ではLayer NormalizationやGroup Normalization等、バッチサイズへの依存が小さい手法が検討されることがある。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0096 ネットワーク構造 > 正規化層 ｜ 難易度：標準

「BatchNormは一般にバッチ方向の統計に依存し、LayerNormは各サンプル内の特徴方向などで正規化するためバッチサイズへの依存が小さい。」という説明を正しいと判断する際、最も適切な根拠はどれか。

ア. 正規化軸が異なるため同一手法ではない。

イ. LayerNormもラベルを必要としない。

ウ. 代表的な違いは、どの軸について統計量を計算するかにある。

エ. BatchNormにも学習可能なスケール・シフトがある。

答え・解説 **正答：ウ**

ア： この説明は別の論点『両者は名称だけが異なり、常に同じ軸・同じ統計量で正規化する。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『LayerNormは推論時に必ず正解ラベルを必要とする。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『BatchNormは一般にバッチ方向の統計に依存し、LayerNormは各サンプル内の特徴方向などで正規化するためバッチサイズへの依存が小さい。』である。

エ： この説明は別の論点『BatchNormは学習可能パラメータを一切持てないが、LayerNormだけが持てる。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『BatchNormは一般にバッチ方向の統計に依存し、LayerNormは各サンプル内の特徴方向などで正規化するためバッチサイズへの依存が小さい。』である。代表的な違いは、どの軸について統計量を計算するかにある。 背景となる論点は次のとおりである。正規化層を選ぶ際は、データ構造やバッチサイズ、モデル構造に応じて統計量をどこから計算するかを考える。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0097 ネットワーク構造 > 正規化層 ｜ 難易度：標準

研修資料に「入力前処理と内部活性の正規化は対象が異なるため、両方を組み合わせることはあり得る。」と記載されている。この記述を最も直接的に裏付ける説明はどれか。

ア. 入力標準化をしても内部活性の分布は層ごとに変化し得る。

イ. 入力標準化は重み学習を妨げない。

ウ. 入力データのスケーリングとネットワーク内部の正規化は役割・位置が異なる。

エ. BatchNormは空間解像度を縮小する層ではない。

答え・解説 **正答：ウ**

ア： この説明は別の論点『同じ処理なので、内部BatchNormは数学的に必ず無効になる。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『入力標準化をするとCNNの畳み込み重みは学習できなくなる。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『入力前処理と内部活性の正規化は対象が異なるため、両方を組み合わせることはあり得る。』である。

エ： この説明は別の論点『BatchNormを入れると入力画像の画素数が減少する。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『入力前処理と内部活性の正規化は対象が異なるため、両方を組み合わせることはあり得る。』である。入力データのスケーリングとネットワーク内部の正規化は役割・位置が異なる。 背景となる論点は次のとおりである。前処理と正規化層を混同せず、どの量をどの段階で正規化しているかを区別することが重要である。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0098 ネットワーク構造 > 正規化層 ｜ 難易度：標準

ある受験者が「BatchNormを1層入れるだけで訓練誤差とテスト誤差は必ず一致する。」と回答した。この誤りを最も適切に指摘する説明はどれか。

ア. BatchNorm自体にも学習可能パラメータがあり、モデル全体のパラメータは残る。

イ. 誤ラベルを訂正する機能ではない。

ウ. 汎化ギャップが必ず消える保証はない。

エ. 原論文でも正則化的効果が述べられるが、一般化性能はデータや構成に依存する。

答え・解説 **正答：ウ**

ア： この説明は別の論点『BatchNormはパラメータ数を必ず0にするため過学習が起こらない。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『BatchNormはデータセットのラベルノイズを自動的に修正する。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『BatchNormを1層入れるだけで訓練誤差とテスト誤差は必ず一致する。』である。

エ： この説明は別の論点『BatchNormには正則化的な効果が観察されることがあるが、どの状況でもDropoutや他の正則化を不要にするとは限らない。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『BatchNormを1層入れるだけで訓練誤差とテスト誤差は必ず一致する。』である。汎化ギャップが必ず消える保証はない。 正しい理解の背景は次のとおりである。正規化層の効果を『万能な過学習防止』とみなさず、最適化と一般化の両面から評価する必要がある。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0099 ネットワーク構造 > 正規化層 ｜ 難易度：応用

AI関連の資料レビューで「正規化層は必ず入力層の前にしか置けない。」という記述が見つかった。レビューコメントとして最も適切なものはどれか。

ア. 正規化層の前後関係は計算グラフと学習挙動に影響する。

イ. 正規化と活性化は組み合わせて使われる。

ウ. 中間層で広く用いられる。

エ. 演算順序が変われば一般に同じ関数にはならない。

答え・解説 **正答：ウ**

ア： この説明は別の論点『正規化する対象の活性と後続の非線形変換との関係を踏まえ、アーキテクチャの設計として位置を決める。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『正規化層を置くと、その後には活性化関数を一切使えない。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『正規化層は必ず入力層の前にしか置けない。』である。

エ： この説明は別の論点『位置はモデルの挙動に影響しないため、どこに置いても完全に同一である。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『正規化層は必ず入力層の前にしか置けない。』である。中間層で広く用いられる。 正しい理解の背景は次のとおりである。試験では『正規化＝前処理だけ』と誤認せず、ネットワーク内部の要素技術として理解することが重要である。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0100 ネットワーク構造 > 正規化層 ｜ 難易度：応用

次の主張「BatchNormだけに固執せず、LayerNormなどサンプル内部の特徴に基づく正規化を候補にする。」について、その理由を最も正確に説明しているものはどれか。

ア. 正規化に固定の最低バッチ数はない。

イ. 系列モデルでも正規化は利用される。

ウ. バッチ依存を避けたい系列モデルではLayerNorm系が有力な候補になる。

エ. クラス数変更は正規化の代替ではない。

答え・解説 **正答：ウ**

ア： この説明は別の論点『正規化を行うには必ず100サンプル以上の固定バッチが必要である。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『正規化は画像以外では定義できないため使用しない。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『BatchNormだけに固執せず、LayerNormなどサンプル内部の特徴に基づく正規化を候補にする。』である。

エ： この説明は別の論点『正規化層の代わりに常に出力クラス数を増やせばよい。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『BatchNormだけに固執せず、LayerNormなどサンプル内部の特徴に基づく正規化を候補にする。』である。バッチ依存を避けたい系列モデルではLayerNorm系が有力な候補になる。 背景となる論点は次のとおりである。正規化手法は一種類ではなく、統計量を取る軸やモデル特性に応じて選択する。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0101 ネットワーク構造 > スキップ結合 ｜ 難易度：基礎

学習者が「すべての層を順番に通さず入力を直接最終予測に置き換える仕組みである。」と理解している。この理解を修正するための説明として最も適切なものはどれか。

ア. これはDropoutの説明である。

イ. スキップ結合は通常の逐次経路に加えて短い情報経路を設ける。

ウ. 主経路を完全に無視するとは限らない。

エ. 空間縮小を目的とする演算ではない。

答え・解説 **正答：ウ**

ア： この説明は別の論点『学習中だけ重みをランダムに削除する仕組みである。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『ある層の入力や中間表現を、複数層を飛び越えて後段の表現へ加算・連結などで伝える接続である。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『すべての層を順番に通さず入力を直接最終予測に置き換える仕組みである。』である。

エ： この説明は別の論点『画像の空間サイズを必ず半分にする演算である。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『すべての層を順番に通さず入力を直接最終予測に置き換える仕組みである。』である。主経路を完全に無視するとは限らない。 正しい理解の背景は次のとおりである。スキップ結合は深いネットワークの情報・勾配伝播を助ける重要な構造で、ResNetの残差接続が代表例である。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0102 ネットワーク構造 > スキップ結合 ｜ 難易度：基礎

実務上の判断で「入力xに対してブロックが学習する残差変換である。」という考え方を採用した。その判断根拠として最も適切なものはどれか。

ア. 教師ラベルではない。

イ. 学習される関数であり常に0とは限らない。

ウ. F(x)は主経路が学習する変換で、入力xがshortcutとして加わる。

エ. クラス数とは無関係である。

答え・解説 **正答：ウ**

ア： この説明は別の論点『ネットワーク全体の教師ラベルそのものである。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『常に0に固定される正規化係数である。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『入力xに対してブロックが学習する残差変換である。』である。

エ： この説明は別の論点『入力画像のクラス数を表す整数である。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『入力xに対してブロックが学習する残差変換である。』である。F(x)は主経路が学習する変換で、入力xがshortcutとして加わる。 背景となる論点は次のとおりである。残差学習では目的の写像H(x)を直接学ぶ代わりにF(x)=H(x)-xを学ぶ見方ができる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0103 ネットワーク構造 > スキップ結合 ｜ 難易度：基礎

教材の草案に「すべての層のパラメータを同じ値へ固定するため。」とある。内容を訂正する際に示す説明として最も適切なものはどれか。

ア. shortcutにより深い経路だけに依存しない伝播経路ができる。

イ. ResNetも勾配に基づき学習する。

ウ. パラメータ共有を強制する仕組みではない。

エ. スキップ結合はデータ生成手法ではない。

答え・解説 **正答：ウ**

ア： この説明は別の論点『恒等経路を通じて情報や勾配が伝わる経路を確保し、深い残差関数の最適化を容易にする。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『誤差逆伝播を使わずに正答を計算できるため。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『すべての層のパラメータを同じ値へ固定するため。』である。

エ： この説明は別の論点『データ拡張を自動的に無限回行うため。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『すべての層のパラメータを同じ値へ固定するため。』である。パラメータ共有を強制する仕組みではない。 正しい理解の背景は次のとおりである。Residual learningは深さを増した際の最適化困難を緩和し、非常に深いネットワークの学習を実用化した。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0104 ネットワーク構造 > スキップ結合 ｜ 難易度：標準

「1×1畳み込みなどの射影をshortcut側に用いて次元を合わせてから加算する方法がある。」という説明を正しいと判断する際、最も適切な根拠はどれか。

ア. ブロードキャストで意図どおりになるとは限らず、ResNetの設計として形状整合が必要である。

イ. 0にしても形状自体は揃わない。

ウ. 加算には対応する形状が必要で、projection shortcutが用いられることがある。

エ. 全結合のみへの置換は不要である。

答え・解説 **正答：ウ**

ア： この説明は別の論点『形状が違っていても要素ごとの加算は常に自動で成立する。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『主経路の出力を全て0にすれば形状不一致を無視できる。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『1×1畳み込みなどの射影をshortcut側に用いて次元を合わせてから加算する方法がある。』である。

エ： この説明は別の論点『必ずネットワーク全体を全結合層だけへ置き換える必要がある。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『1×1畳み込みなどの射影をshortcut側に用いて次元を合わせてから加算する方法がある。』である。加算には対応する形状が必要で、projection shortcutが用いられることがある。 背景となる論点は次のとおりである。shortcutは常に恒等写像とは限らず、チャネル数や空間サイズ変更時には射影を用いる設計がある。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0105 ネットワーク構造 > スキップ結合 ｜ 難易度：標準

研修資料に「スキップ結合は別経路で情報を後段へ伝える構造であり、Dropoutは訓練中にユニット等を確率的に無効化する正則化手法である。」と記載されている。この記述を最も直接的に裏付ける説明はどれか。

ア. 同一手法ではない。

イ. 説明が逆である。

ウ. 目的と機構が異なる二つの技術である。

エ. 推論時に全ユニットを削除するわけではない。

答え・解説 **正答：ウ**

ア： この説明は別の論点『両者とも同じ演算であり呼び方だけが違う。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『Dropoutは入力を恒等写像として加算するが、スキップ結合はランダムに削除する。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『スキップ結合は別経路で情報を後段へ伝える構造であり、Dropoutは訓練中にユニット等を確率的に無効化する正則化手法である。』である。

エ： この説明は別の論点『どちらも推論時に必ず全ユニットを削除する。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『スキップ結合は別経路で情報を後段へ伝える構造であり、Dropoutは訓練中にユニット等を確率的に無効化する正則化手法である。』である。目的と機構が異なる二つの技術である。 背景となる論点は次のとおりである。G検定では要素技術の名称だけでなく、情報経路を追加する構造と確率的正則化を区別する必要がある。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0106 ネットワーク構造 > スキップ結合 ｜ 難易度：標準

ある受験者が「画像圧縮により解像度が下がる現象だけを指す。」と回答した。この誤りを最も適切に指摘する説明はどれか。

ア. 過学習だけでは説明できない点が重要である。

イ. ハードウェア故障の概念ではない。

ウ. 画像品質の劣化を意味しない。

エ. degradationは深層化による最適化困難として訓練誤差にも現れる。

答え・解説 **正答：ウ**

ア： この説明は別の論点『訓練誤差は下がるがテスト誤差だけが悪化する典型的な過学習と同義である。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『GPUの計算精度が時間とともに物理的に劣化する現象である。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『画像圧縮により解像度が下がる現象だけを指す。』である。

エ： この説明は別の論点『単に層を深くしたplain networkで、深いモデルの訓練誤差まで浅いモデルより悪化することがある現象である。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『画像圧縮により解像度が下がる現象だけを指す。』である。画像品質の劣化を意味しない。 正しい理解の背景は次のとおりである。残差学習は『深くすれば表現力が増えるはずなのに最適化できない』問題を緩和するため提案された。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0107 ネットワーク構造 > スキップ結合 ｜ 難易度：標準

AI関連の資料レビューで「VGGNet」という記述が見つかった。レビューコメントとして最も適切なものはどれか。

ア. ResNetはresidual blockとshortcut connectionを中心にしたモデルである。

イ. AlexNetは2012年の深層CNNとして重要だが、ResNet型スキップ結合が中心ではない。

ウ. VGGNetは小さな畳み込みを積み重ねた深いCNNで、代表的なresidual architectureではない。

エ. LeNetは初期のCNNでありResNetより古い。

答え・解説 **正答：ウ**

ア： この説明は別の論点『ResNet』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『AlexNet』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『VGGNet』である。

エ： この説明は別の論点『LeNet』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『VGGNet』である。VGGNetは小さな畳み込みを積み重ねた深いCNNで、代表的なresidual architectureではない。 正しい理解の背景は次のとおりである。JDLA公式過去問題でも、ILSVRC 2015とスキップ結合からResNetを識別する問題が出題されている。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0108 ネットワーク構造 > スキップ結合 ｜ 難易度：標準

次の主張「出力はおおむねxに近くなり、ブロックが恒等写像に近い振る舞いをしやすい。」について、その理由を最も正確に説明しているものはどれか。

ア. 加算だけで無限大にはならない。

イ. xが残るため0とは限らない。

ウ. F(x)が0に近ければshortcutのxがそのまま出力へ寄与する。

エ. 教師ラベルを加える式ではない。

答え・解説 **正答：ウ**

ア： この説明は別の論点『出力は必ず無限大になる。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『出力は必ず0になり入力情報が完全に失われる。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『出力はおおむねxに近くなり、ブロックが恒等写像に近い振る舞いをしやすい。』である。

エ： この説明は別の論点『ラベルが自動的にxへ加算される。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『出力はおおむねxに近くなり、ブロックが恒等写像に近い振る舞いをしやすい。』である。F(x)が0に近ければshortcutのxがそのまま出力へ寄与する。 背景となる論点は次のとおりである。恒等写像に近い関数を表現しやすいことも、残差構造が深いネットワークを最適化しやすくする直感の一つである。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0109 ネットワーク構造 > スキップ結合 ｜ 難易度：応用

学習者が「連結を使うと元の特徴は必ず削除される。」と理解している。この理解を修正するための説明として最も適切なものはどれか。

ア. 数学的に異なる演算である。

イ. 結合方法により出力形状や情報の混ぜ方が異なる。

ウ. 連結は特徴を並べて保持する操作である。

エ. 加算自体には学習パラメータを持たない場合も多い。

答え・解説 **正答：ウ**

ア： この説明は別の論点『加算と連結はどの形状でも常に同じテンソルを生成する。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『加算では通常形状をそろえる必要があり、連結では特徴量のチャネル数などが増えるため後段の設計が変わる。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『連結を使うと元の特徴は必ず削除される。』である。

エ： この説明は別の論点『加算するとパラメータ数が必ず入力次元の二乗だけ増える。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『連結を使うと元の特徴は必ず削除される。』である。連結は特徴を並べて保持する操作である。 正しい理解の背景は次のとおりである。『skip connection』は一種類の演算名ではなく、飛び越し経路をどう統合するかまで含めて理解するとよい。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0110 ネットワーク構造 > スキップ結合 ｜ 難易度：応用

実務上の判断で「勾配伝播や最適化を助ける構造だが、データ品質や損失設計が不適切でも必ず高精度になるという保証はない。」という考え方を採用した。その判断根拠として最も適切なものはどれか。

ア. 教師あり学習では通常データが必要である。

イ. モデル選択問題を自動解決する機能ではない。

ウ. 構造上の利点はあるが学習成功を無条件に保証するものではない。

エ. ラベルクリーニング機能ではない。

答え・解説 **正答：ウ**

ア： この説明は別の論点『スキップ結合があれば学習データは一切不要になる。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『スキップ結合だけでどのタスクでも最適なモデルサイズが自動決定される。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『勾配伝播や最適化を助ける構造だが、データ品質や損失設計が不適切でも必ず高精度になるという保証はない。』である。

エ： この説明は別の論点『スキップ結合は正解ラベルの誤りを自動修正する。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『勾配伝播や最適化を助ける構造だが、データ品質や損失設計が不適切でも必ず高精度になるという保証はない。』である。構造上の利点はあるが学習成功を無条件に保証するものではない。 背景となる論点は次のとおりである。要素技術の効果は目的・条件の範囲で理解し、『導入すれば必ず解決』という誤った一般化を避ける。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0111 ネットワーク構造 > 回帰結合層・RNN ｜ 難易度：基礎

教材の草案に「入力系列を学習前に必ず画像へ変換する。」とある。内容を訂正する際に示す説明として最も適切なものはどれか。

ア. RNNは回帰結合によって時間方向に状態を受け渡す。

イ. これは独立なフィードフォワード処理の説明である。

ウ. 画像化はRNNの必須条件ではない。

エ. 系列長はクラス数と一致する必要はない。

答え・解説 **正答：ウ**

ア： この説明は別の論点『過去時点の隠れ状態を次の時点の計算へ利用し、系列の文脈を内部状態として伝える。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『各時点を必ず完全に独立して処理し、過去情報を使わない。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『入力系列を学習前に必ず画像へ変換する。』である。

エ： この説明は別の論点『出力クラス数と同じ長さの系列しか扱えない。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象となる誤った主張は『入力系列を学習前に必ず画像へ変換する。』である。画像化はRNNの必須条件ではない。 正しい理解の背景は次のとおりである。RNNは時系列・文章・音声など順序を持つデータを扱うための代表的構造である。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0112 ネットワーク構造 > 回帰結合層・RNN ｜ 難易度：基礎

「時刻tまでの入力に関する情報を圧縮した内部表現として、次時刻の計算へ引き継ぐ。」という説明を正しいと判断する際、最も適切な根拠はどれか。

ア. ラベル専用の記憶ではない。

イ. パラメータと状態は区別される。

ウ. 隠れ状態は過去の文脈を要約して次時刻へ渡す。

エ. 有限次元の状態が全情報を完全保存する保証はない。

答え・解説 **正答：ウ**

ア： この説明は別の論点『時刻tの正解ラベルだけを永久保存する。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『ネットワークの全パラメータを毎時刻コピーしたものになる。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『時刻tまでの入力に関する情報を圧縮した内部表現として、次時刻の計算へ引き継ぐ。』である。

エ： この説明は別の論点『必ず入力系列全体を損失なく完全復元できる記憶である。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説： 対象の主張は『時刻tまでの入力に関する情報を圧縮した内部表現として、次時刻の計算へ引き継ぐ。』である。隠れ状態は過去の文脈を要約して次時刻へ渡す。 背景となる論点は次のとおりである。RNNでは同じ遷移パラメータを時間方向に共有しながら、隠れ状態が時刻ごとに変化する。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0113 ネットワーク構造 > 回帰結合層・RNN ｜ 難易度：基礎

研修資料に「系列位置ごとに別モデルを持たず、同じ状態遷移規則を時間方向へ適用できる。」と記載されている。この記述を最も直接的に裏付ける説明はどれか。

ア. クラス数変更が目的ではない。

イ. 重みを時間とともに0へする規則ではない。

ウ. 時間方向の重み共有により可変長系列へ同じ遷移を適用できる。

エ. 入力と前状態の双方から状態を更新する。

答え・解説 **正答：ウ**

ア：この説明は別の論点『系列長が変わるたびにクラス数を変更するため。』に対応するもので、今回示された主張を直接説明するものではない。

イ：この説明は別の論点『時間が進むほど重みを必ず0へ減衰させるため。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『系列位置ごとに別モデルを持たず、同じ状態遷移規則を時間方向へ適用できる。』である。

エ：この説明は別の論点『各時刻の入力を無視して隠れ状態だけを固定するため。』に対応するもので、今回示された主張を直接説明するものではない。

総合解説：対象の主張は『系列位置ごとに別モデルを持たず、同じ状態遷移規則を時間方向へ適用できる。』である。時間方向の重み共有により可変長系列へ同じ遷移を適用できる。 背景となる論点は次のとおりである。RNNではフィードフォワード層の深さ方向とは異なり、同じセルを時間方向に展開して考える。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0114 ネットワーク構造 > 回帰結合層・RNN ｜ 難易度：標準

ある受験者が「出力時刻だけに独立したモデルを新規作成する。」と回答した。この誤りを最も適切に指摘する説明はどれか。

ア. 時系列構造を捨てる手法ではない。

イ. 通常は勾配に基づく学習である。

ウ. BPTTは時間展開されたRNNに対する誤差逆伝播である。

エ. 時刻ごとに別モデルを作る方式ではない。

答え・解説 **正答：エ**

ア：この説明は別の論点『時系列データを時間順に並べ替えずランダムな画像として学習する。』に対応するもので、今回示された主張を直接説明するものではない。

イ：この説明は別の論点『勾配を計算せず、各時刻の重みを総当たりで探索する。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『RNNを時間方向に展開した計算グラフとして捉え、各時刻を通じて勾配を逆伝播する。』に対応するもので、今回示された主張を直接説明するものではない。

エ：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『出力時刻だけに独立したモデルを新規作成する。』である。

総合解説：対象となる誤った主張は『出力時刻だけに独立したモデルを新規作成する。』である。時刻ごとに別モデルを作る方式ではない。 正しい理解の背景は次のとおりである。系列が長いほど時間方向の計算グラフも長くなり、勾配消失・爆発や計算コストが問題になり得る。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0115 ネットワーク構造 > 回帰結合層・RNN ｜ 難易度：標準

AI関連の資料レビューで「隠れ状態は必ず整数値しか取れないため。」という記述が見つかった。レビューコメントとして最も適切なものはどれか。

ア. 長い時間展開で勾配の積が続き、消失・爆発が起こり得る。

イ. BPTTとして定義できる。

ウ. 系列学習でも損失関数を設定できる。

エ. 隠れ状態は通常連続値である。

答え・解説 **正答：エ**

ア： この説明は別の論点『時間方向にヤコビアン等の積が繰り返され、勾配が極端に小さくなる、または大きくなることがあるため。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『RNNは誤差逆伝播を数学的に定義できないため。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『系列データには損失関数を設定できないため。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『隠れ状態は必ず整数値しか取れないため。』である。

総合解説： 対象となる誤った主張は『隠れ状態は必ず整数値しか取れないため。』である。隠れ状態は通常連続値である。 正しい理解の背景は次のとおりである。長期依存問題はLSTMなどゲート付きRNNが発展した主要な背景の一つである。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0116 ネットワーク構造 > 回帰結合層・RNN ｜ 難易度：標準

次の主張「情報を保持・更新・出力する流れを調整するゲート機構とセル状態である。」について、その理由を最も正確に説明しているものはどれか。

ア. 学習済み重みを乱数化する手法ではない。

イ. 画像変換は必須でない。

ウ. 勾配学習を行うニューラルネットワークである。

エ. LSTMはゲートで情報流を制御し、長い時間差での誤差信号伝播を助ける。

答え・解説 **正答：エ**

ア： この説明は別の論点『全ての重みを各時刻で乱数に置き換える機構である。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『系列を必ず固定長の画像に変換する機構である。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『損失関数を使わず正解だけを記憶する表である。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『情報を保持・更新・出力する流れを調整するゲート機構とセル状態である。』である。

総合解説： 対象の主張は『情報を保持・更新・出力する流れを調整するゲート機構とセル状態である。』である。LSTMはゲートで情報流を制御し、長い時間差での誤差信号伝播を助ける。 背景となる論点は次のとおりである。LSTMは入力・忘却・出力に関するゲートを用いる代表的な回帰型ネットワークである。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0117 ネットワーク構造 > 回帰結合層・RNN ｜ 難易度：標準

学習者が「系列順序を完全に削除して平均値だけを入力することがRNNの定義である。」と理解している。この理解を修正するための説明として最も適切なものはどれか。

ア. 必要な出力形態と一致しない。

イ. これは系列生成の一部に近いが条件が極端である。

ウ. 系列分類ではmany-to-one構成が代表的である。

エ. 順序を活用することがRNNの特徴である。

答え・解説 **正答：エ**

ア： この説明は別の論点『各入力時刻に必ず互いに無関係な100個の出力を返す構成。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『入力を1つだけ受け取り無限長系列を必ず生成する構成。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『複数時刻の入力を受け取り、系列全体を表す状態から1つの出力を得るmany-to-one構成。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『系列順序を完全に削除して平均値だけを入力することがRNNの定義である。』である。

総合解説： 対象となる誤った主張は『系列順序を完全に削除して平均値だけを入力することがRNNの定義である。』である。順序を活用することがRNNの特徴である。 正しい理解の背景は次のとおりである。RNNはmany-to-one、one-to-many、many-to-manyなどタスクに応じて入出力の取り方を変えられる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0118 ネットワーク構造 > 回帰結合層・RNN ｜ 難易度：標準

実務上の判断で「系列を順方向と逆方向から処理し、ある位置の表現に前後の文脈を利用できる。」という考え方を採用した。その判断根拠として最も適切なものはどれか。

ア. 未来入力を参照できないオンライン予測ではそのまま使えない場合がある。

イ. 通常は逆方向経路も持つためパラメータが増えることがある。

ウ. 順序を利用する。

エ. 前後両方向の情報を使えることが特徴である。

答え・解説 **正答：エ**

ア： この説明は別の論点『未来情報が得られないリアルタイム予測でも必ず因果制約を満たす。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『一方向RNNより必ずパラメータ数が少なくなる。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『入力系列の順序を無視するためのネットワークである。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『系列を順方向と逆方向から処理し、ある位置の表現に前後の文脈を利用できる。』である。

総合解説： 対象の主張は『系列を順方向と逆方向から処理し、ある位置の表現に前後の文脈を利用できる。』である。前後両方向の情報を使えることが特徴である。 背景となる論点は次のとおりである。双方向化は全系列を参照できるタスクで有効だが、未来を見てはいけない因果的推論では制約に注意する。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0119 ネットワーク構造 > 回帰結合層・RNN ｜ 難易度：応用

教材の草案に「RNNは系列順序を扱えず、Transformerだけが順序を扱える。」とある。内容を訂正する際に示す説明として最も適切なものはどれか。

ア. 回帰結合の依存関係によりRNNは時間方向の逐次性を持つ。

イ. 関係が逆である。

ウ. 計算構造が異なる。

エ. RNNも本質的に順序情報を扱うモデルである。

答え・解説 **正答：エ**

ア： この説明は別の論点『RNNは隠れ状態の時間依存により逐次計算が生じやすく、Transformerは系列位置をより並列に処理しやすい。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『Transformerは必ず1トークンずつ逐次処理し、RNNは全時刻を完全並列にしか処理できない。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『両者は内部計算が同一なので並列性に差はない。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『RNNは系列順序を扱えず、Transformerだけが順序を扱える。』である。

総合解説： 対象となる誤った主張は『RNNは系列順序を扱えず、Transformerだけが順序を扱える。』である。RNNも本質的に順序情報を扱うモデルである。 正しい理解の背景は次のとおりである。AttentionベースのTransformerが広がった理由の一つに、長距離依存の扱いやすさと学習時の高い並列性がある。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0120 ネットワーク構造 > 回帰結合層・RNN ｜ 難易度：応用

「順序依存を扱える利点がある一方、長系列での勾配や逐次計算の課題も踏まえてLSTMやAttention等との比較が必要である。」という説明を正しいと判断する際、最も適切な根拠はどれか。

ア. 常に優越するモデルはない。

イ. データ品質問題を自動解決しない。

ウ. 分類にも広く利用される。

エ. モデル選択は系列長・計算資源・タスク特性などを考慮する。

答え・解説 **正答：エ**

ア： この説明は別の論点『RNNはどの時系列でも必ずTransformerより高精度なので比較不要である。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『RNNを用いれば欠損値や誤ラベルが自動的に完全修復される。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『RNNは教師なし学習専用で分類には利用できない。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『順序依存を扱える利点がある一方、長系列での勾配や逐次計算の課題も踏まえてLSTMやAttention等との比較が必要である。』である。

総合解説： 対象の主張は『順序依存を扱える利点がある一方、長系列での勾配や逐次計算の課題も踏まえてLSTMやAttention等との比較が必要である。』である。モデル選択は系列長・計算資源・タスク特性などを考慮する。 背景となる論点は次のとおりである。回帰結合層は重要な基礎技術だが、長期依存や並列性などの性質を含めて理解する必要がある。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0121 発展的要素技術 > Attention ｜ 難易度：基礎

研修資料に「入力中の各要素に重要度を割り当て、タスクや文脈に応じて情報を重み付きで集約する。」と記載されている。この記述を最も直接的に裏付ける説明はどれか。

ア. 重みは通常入力関係に応じて変わる。

イ. ラベルシャッフルではない。

ウ. プーリングとは別の機構である。

エ. Attentionは関連度に応じた重み付けで必要な情報を選択的に集約する。

答え・解説 **正答：エ**

ア： この説明は別の論点『入力要素を必ず等しい重みで平均するだけの処理である。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『訓練データのラベルをランダムに入れ替える正則化である。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『画像解像度を固定比率で縮小するプーリングだけを指す。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『入力中の各要素に重要度を割り当て、タスクや文脈に応じて情報を重み付きで集約する。』である。

総合解説： 対象の主張は『入力中の各要素に重要度を割り当て、タスクや文脈に応じて情報を重み付きで集約する。』である。Attentionは関連度に応じた重み付けで必要な情報を選択的に集約する。 背景となる論点は次のとおりである。Attentionは系列内または異なる系列間の関係を直接評価し、重要な情報へ重点を置く仕組みである。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0122 発展的要素技術 > Attention ｜ 難易度：基礎

ある受験者が「Value同士だけを比較してQueryを削除する。」と回答した。この誤りを最も適切に指摘する説明はどれか。

ア. 教師ラベルや損失値そのものではない。

イ. ベクトル・行列として扱うのが一般的である。

ウ. 代表的なAttentionではQとKから関連度を作りVを集約する。

エ. 重み計算にQuery-Key関係を用いる。

答え・解説 **正答：エ**

ア： この説明は別の論点『Keyは正解ラベル、Queryは損失値として固定される。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『Query・Key・Valueは必ず同じ1個のスカラーでなければならない。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『QueryとKeyの類似度などから重みを計算し、その重みでValueを加重和する。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『Value同士だけを比較してQueryを削除する。』である。

総合解説： 対象となる誤った主張は『Value同士だけを比較してQueryを削除する。』である。重み計算にQuery-Key関係を用いる。 正しい理解の背景は次のとおりである。Q-K-Vの役割分担を理解するとself-attentionやcross-attentionの違いも整理しやすい。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0123 発展的要素技術 > Attention ｜ 難易度：基礎

AI関連の資料レビューで「Valueの要素数を必ず1個に減らすため。」という記述が見つかった。レビューコメントとして最も適切なものはどれか。

ア. スケーリングは大きな内積値によるsoftmax飽和を緩和する。

イ. 系列長を削減する処理ではない。

ウ. 重みを一様に固定するのではない。

エ. Value次元を1にする操作ではない。

答え・解説 **正答：エ**

ア： この説明は別の論点『次元が大きいと内積の大きさが増えてsoftmaxが極端になりやすいため、スケールを抑えて学習を安定させる。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『系列長を平方根まで短縮するため。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『Attention重みを常に完全な一様分布にするため。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『Valueの要素数を必ず1個に減らすため。』である。

総合解説： 対象となる誤った主張は『Valueの要素数を必ず1個に減らすため。』である。Value次元を1にする操作ではない。 正しい理解の背景は次のとおりである。TransformerではQK^Tをsqrt(d_k)でスケールしてからsoftmaxする設計が採用された。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0124 発展的要素技術 > Attention ｜ 難易度：標準

次の主張「同じ系列からQuery・Key・Valueを作り、系列内の要素同士の関係を計算する。」について、その理由を最も正確に説明しているものはどれか。

ア. 異なるモダリティは必須でない。

イ. マスク条件がなければ他位置も参照できる。

ウ. 相互作用を計算する点が本質である。

エ. self-attentionでは単一系列内で相互関係を計算する。

答え・解説 **正答：エ**

ア： この説明は別の論点『Queryは画像、Keyは音声、Valueは必ずラベルから作らなければならない。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『各位置は自分自身以外の要素を一切参照できない。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『系列内関係を使わず各トークンを独立に線形変換するだけである。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『同じ系列からQuery・Key・Valueを作り、系列内の要素同士の関係を計算する。』である。

総合解説： 対象の主張は『同じ系列からQuery・Key・Valueを作り、系列内の要素同士の関係を計算する。』である。self-attentionでは単一系列内で相互関係を計算する。 背景となる論点は次のとおりである。Self-AttentionはTransformerの中心機構で、長距離の位置同士も直接関連付けられる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0125 発展的要素技術 > Attention ｜ 難易度：標準

学習者が「Query・Key・Valueを全て無関係な乱数から固定生成する。」と理解している。この理解を修正するための説明として最も適切なものはどれか。

ア. エンコーダ情報を参照するのが目的である。

イ. 異なる表現集合間の参照がcross-attentionの代表例である。

ウ. 推論時に正解ラベルは使えない。

エ. 学習可能な表現間関係を使う。

答え・解説 **正答：エ**

ア： この説明は別の論点『デコーダがエンコーダを参照せず自分の直前出力だけをコピーする。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『Queryをデコーダ表現から、KeyとValueをエンコーダ表現から作るcross-attention。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『KeyとValueを正解ラベルそのものから作り推論時にも利用する。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『Query・Key・Valueを全て無関係な乱数から固定生成する。』である。

総合解説： 対象となる誤った主張は『Query・Key・Valueを全て無関係な乱数から固定生成する。』である。学習可能な表現間関係を使う。 正しい理解の背景は次のとおりである。Self-Attentionは同一系列内部、Cross-Attentionは異なる系列・表現間の関連付けとして整理できる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0126 発展的要素技術 > Attention ｜ 難易度：標準

実務上の判断で「複数の異なる射影空間でAttentionを並列計算し、異なる種類の関係を捉えやすくする。」という考え方を採用した。その判断根拠として最も適切なものはどれか。

ア. ヘッドごとに射影や重みが異なり得る。

イ. 系列長を縮める目的ではない。

ウ. 教師ラベルをヘッドごとに用意しない。

エ. 複数ヘッドは異なる表現部分空間の関係を捉える機会を与える。

答え・解説 **正答：エ**

ア： この説明は別の論点『Attention重みを全ヘッドで必ず同じ値に固定する。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『ヘッド数を増やすほど系列長を必ずゼロに近づける。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『各ヘッドが別々の正解ラベルを必要とする。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『複数の異なる射影空間でAttentionを並列計算し、異なる種類の関係を捉えやすくする。』である。

総合解説： 対象の主張は『複数の異なる射影空間でAttentionを並列計算し、異なる種類の関係を捉えやすくする。』である。複数ヘッドは異なる表現部分空間の関係を捉える機会を与える。 背景となる論点は次のとおりである。Transformerでは複数ヘッドの出力を結合して変換し、多面的な依存関係を表現する。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0127 発展的要素技術 > Attention ｜ 難易度：標準

教材の草案に「入力文をランダムに並べ替えて語順情報を消すため。」とある。内容を訂正する際に示す説明として最も適切なものはどれか。

ア. 未来情報の漏洩を防ぐため上三角側などをマスクする。

イ. 参照可能な過去位置へのAttentionは残る。

ウ. 正解のコピーではなく参照制約である。

エ. 語順破壊が目的ではない。

答え・解説 **正答：エ**

ア： この説明は別の論点『ある位置の予測時に未来側のトークンを参照できないようにし、自己回帰の因果条件を保つため。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『Attention重みを全て0にして計算を省略するため。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『訓練時だけ正解ラベルを未来位置へコピーするため。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『入力文をランダムに並べ替えて語順情報を消すため。』である。

総合解説： 対象となる誤った主張は『入力文をランダムに並べ替えて語順情報を消すため。』である。語順破壊が目的ではない。 正しい理解の背景は次のとおりである。マスクはAttentionの参照範囲を制御する仕組みで、自己回帰モデルでは未来情報リーク防止に重要である。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0128 発展的要素技術 > Attention ｜ 難易度：標準

「離れた位置同士をAttentionで直接関連付けられ、RNNのように多数の時間ステップを順に経由せず情報を結び付けられる。」という説明を正しいと判断する際、最も適切な根拠はどれか。

ア. 通常は全位置参照も可能である。

イ. RNNは隠れ状態を順次伝える。

ウ. 計算資源は系列長に依存する。

エ. Self-Attentionは位置間を直接結ぶためパス長を短くできる。

答え・解説 **正答：エ**

ア： この説明は別の論点『Self-Attentionでは近接要素しか参照できない。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『RNNは全位置間を常に1回の内積だけで直接結ぶ。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『どちらも系列長に関係なく計算量とメモリ量が完全に一定である。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『離れた位置同士をAttentionで直接関連付けられ、RNNのように多数の時間ステップを順に経由せず情報を結び付けられる。』である。

総合解説： 対象の主張は『離れた位置同士をAttentionで直接関連付けられ、RNNのように多数の時間ステップを順に経由せず情報を結び付けられる。』である。Self-Attentionは位置間を直接結ぶためパス長を短くできる。 背景となる論点は次のとおりである。Attentionの利点と計算コストを両面で理解することが重要で、長系列ではself-attentionの二次的コストが問題になる場合もある。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0129 発展的要素技術 > Attention ｜ 難易度：応用

研修資料に「どこを強く参照したかの手がかりにはなるが、重みだけをそのまま完全な因果説明とみなすべきではない。」と記載されている。この記述を最も直接的に裏付ける説明はどれか。

ア. 予測は多層の計算全体で決まる。

イ. 学習された参照パターンとして情報を含む。

ウ. 可視化だけで非機能要件は保証できない。

エ. Attentionは参照関係の一側面を示すが、完全な因果説明とは限らない。

答え・解説 **正答：エ**

ア： この説明は別の論点『Attention重みが最大の要素だけが常に予測の唯一の原因である。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『Attention重みはモデル出力と無関係な乱数なので一切意味がない。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『重みが可視化できればモデルの公平性や安全性も自動的に保証される。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『どこを強く参照したかの手がかりにはなるが、重みだけをそのまま完全な因果説明とみなすべきではない。』である。

総合解説： 対象の主張は『どこを強く参照したかの手がかりにはなるが、重みだけをそのまま完全な因果説明とみなすべきではない。』である。Attentionは参照関係の一側面を示すが、完全な因果説明とは限らない。 背景となる論点は次のとおりである。『Attention＝説明可能性の完全な証明』と短絡せず、解釈手段の一つとして扱う。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0130 発展的要素技術 > Attention ｜ 難易度：応用

ある受験者が「Self-Attentionは入力長に関係なくメモリを1要素しか使わない。」と回答した。この誤りを最も適切に指摘する説明はどれか。

ア. 関係が逆である。

イ. 定義上の固定上限はない。

ウ. 標準Self-Attentionは全位置ペアの関連を扱うため長系列ではコストが大きい。

エ. 入力長に応じて行列が増える。

答え・解説 **正答：エ**

ア： この説明は別の論点『系列が長いほどAttention行列は必ず小さくなる。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『系列長が100を超えると数学的にAttentionは定義できない。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『系列長に対してAttention行列が大きくなり、計算量・メモリ量が増えるため長系列向け工夫が必要になることがある。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『Self-Attentionは入力長に関係なくメモリを1要素しか使わない。』である。

総合解説： 対象となる誤った主張は『Self-Attentionは入力長に関係なくメモリを1要素しか使わない。』である。入力長に応じて行列が増える。 正しい理解の背景は次のとおりである。Attentionは並列化しやすい一方、全位置間Attentionの計算コストという別の制約を持つ。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0131 発展的要素技術 > オートエンコーダ ｜ 難易度：基礎

AI関連の資料レビューで「入力を乱数へ置換して元情報を完全に捨てる。」という記述が見つかった。レビューコメントとして最も適切なものはどれか。

ア. encoderとdecoderを通じて入力再構成を学ぶのが基本である。

イ. ラベルなしでも自己教師的に学習できる。

ウ. 系列予測専用ではない。

エ. 情報を全て捨てるのではなく有用な表現を保持する。

答え・解説 **正答：エ**

ア：この説明は別の論点『入力を潜在表現へ符号化し、そこから元の入力を再構成できるように学習する。』に対応するもので、今回示された主張を直接説明するものではない。

イ：この説明は別の論点『必ず正解クラスのラベルを出力する教師あり分類器としてのみ学習する。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『系列データの未来時刻だけを予測することに限定される。』に対応するもので、今回示された主張を直接説明するものではない。

エ：対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『入力を乱数へ置換して元情報を完全に捨てる。』である。

総合解説：対象となる誤った主張は『入力を乱数へ置換して元情報を完全に捨てる。』である。情報を全て捨てるのではなく有用な表現を保持する。 正しい理解の背景は次のとおりである。オートエンコーダは再構成課題を利用して表現を学ぶ代表的なニューラルネットワークである。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0132 発展的要素技術 > オートエンコーダ ｜ 難易度：基礎

次の主張「エンコーダが入力を潜在表現へ変換し、デコーダが潜在表現から入力空間へ再構成する。」について、その理由を最も正確に説明しているものはどれか。

ア. ラベル生成・データ増幅が定義ではない。

イ. 単純な恒等写像だけを目的とすると有用表現を学べない。

ウ. 通常は両方のパラメータを学習する。

エ. 圧縮・表現化と再構成が基本的な役割分担である。

答え・解説 **正答：エ**

ア：この説明は別の論点『エンコーダが正解ラベルを作り、デコーダが訓練データ数を増やす。』に対応するもので、今回示された主張を直接説明するものではない。

イ：この説明は別の論点『両者とも入力を変更せず恒等コピーすることだけが目的である。』に対応するもので、今回示された主張を直接説明するものではない。

ウ：この説明は別の論点『デコーダだけが学習し、エンコーダのパラメータは常に固定される。』に対応するもので、今回示された主張を直接説明するものではない。

エ：対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『エンコーダが入力を潜在表現へ変換し、デコーダが潜在表現から入力空間へ再構成する。』である。

総合解説：対象の主張は『エンコーダが入力を潜在表現へ変換し、デコーダが潜在表現から入力空間へ再構成する。』である。圧縮・表現化と再構成が基本的な役割分担である。 背景となる論点は次のとおりである。潜在表現に制約やノイズを加えることで、単なるコピーを超えた特徴抽出を促す設計もある。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0133 発展的要素技術 > オートエンコーダ ｜ 難易度：基礎

学習者が「正解ラベルの個数と潜在次元を必ず一致させる。」と理解している。この理解を修正するための説明として最も適切なものはどれか。

ア. むしろ入力より狭い表現を用いる。

イ. 低次元ボトルネックは情報圧縮を通じた表現学習を促す。

ウ. 勾配学習を行う。

エ. クラス数との一致は必須でない。

答え・解説 **正答：エ**

ア： この説明は別の論点『入力の全要素を個別に保存するため潜在次元を必ず大きくする。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『再構成に必要な情報を低次元の潜在表現へ圧縮して学習させる。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『勾配を計算できなくするため中間層を狭くする。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『正解ラベルの個数と潜在次元を必ず一致させる。』である。

総合解説： 対象となる誤った主張は『正解ラベルの個数と潜在次元を必ず一致させる。』である。クラス数との一致は必須でない。 正しい理解の背景は次のとおりである。Hintonらの深層オートエンコーダは高次元データを低次元コードへ変換する次元削減手法として示された。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0134 発展的要素技術 > オートエンコーダ ｜ 難易度：標準

実務上の判断で「入力とデコーダ出力のずれを測り、元データの再現性を学習目標として評価する。」という考え方を採用した。その判断根拠として最も適切なものはどれか。

ア. パラメータ数ではない。

イ. 分類Accuracyとは別の目的関数である。

ウ. サンプル数を決めない。

エ. 再構成損失は入力と復元結果の差を測る。

答え・解説 **正答：エ**

ア： この説明は別の論点『エンコーダのパラメータ数だけを数える指標である。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『必ず分類Accuracyと同じ値になる指標である。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『データセットのサンプル数を決めるハイパーパラメータである。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『入力とデコーダ出力のずれを測り、元データの再現性を学習目標として評価する。』である。

総合解説： 対象の主張は『入力とデコーダ出力のずれを測り、元データの再現性を学習目標として評価する。』である。再構成損失は入力と復元結果の差を測る。 背景となる論点は次のとおりである。データ型に応じて平均二乗誤差や交差エントロピーなど、再構成に適した損失を選ぶ。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0135 発展的要素技術 > オートエンコーダ ｜ 難易度：標準

教材の草案に「正解ラベルをランダムに入れ替えて分類する。」とある。内容を訂正する際に示す説明として最も適切なものはどれか。

ア. 壊した入力から元データを復元する課題により頑健な表現を学ばせる。

イ. 目的はノイズ生成ではなく復元である。

ウ. 単なるメモリコピーを目的としない。

エ. ラベルシャッフルではない。

答え・解説 **正答：エ**

ア： この説明は別の論点『入力にノイズや欠損を加えたデータを与え、元のクリーンな入力を再構成するよう学習する。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『クリーンな入力からさらに強いノイズだけを出力するよう学習する。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『入力と出力を常に同一メモリアドレスへ固定する。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『正解ラベルをランダムに入れ替えて分類する。』である。

総合解説： 対象となる誤った主張は『正解ラベルをランダムに入れ替えて分類する。』である。ラベルシャッフルではない。 正しい理解の背景は次のとおりである。ノイズ付加は入力の恒等コピーを避け、データ構造を捉える表現学習を促す方法の一つである。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0136 発展的要素技術 > オートエンコーダ ｜ 難易度：標準

「限られたユニットだけが強く活性化する表現を促し、特徴の選択的な表現を学ばせる。」という説明を正しいと判断する際、最も適切な根拠はどれか。

ア. 一様最大活性はスパースではない。

イ. 次元数そのものではなく活性の疎性を制約する。

ウ. 再構成損失と組み合わせることが一般的である。

エ. スパース制約は少数ユニットの活性を促す。

答え・解説 **正答：エ**

ア： この説明は別の論点『全ての潜在ユニットを常に同じ最大値にする。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『潜在表現を必ず入力より高次元にしないよう禁止する。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『再構成誤差を計算しないようにする。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『限られたユニットだけが強く活性化する表現を促し、特徴の選択的な表現を学ばせる。』である。

総合解説： 対象の主張は『限られたユニットだけが強く活性化する表現を促し、特徴の選択的な表現を学ばせる。』である。スパース制約は少数ユニットの活性を促す。 背景となる論点は次のとおりである。ボトルネックの次元制約以外にも、スパース性やノイズ付加などで有用な表現を促せる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0137 発展的要素技術 > オートエンコーダ ｜ 難易度：標準

研修資料に「正常パターンはよく再構成できる一方、未知の異常パターンでは再構成誤差が大きくなることを利用する。」と記載されている。この記述を最も直接的に裏付ける説明はどれか。

ア. 一般的な期待と逆である。

イ. 閾値やデータ分布を考慮する必要がある。

ウ. ラベル文字列長とは無関係である。

エ. 再構成誤差を異常度の一候補として用いる。

答え・解説 **正答：エ**

ア： この説明は別の論点『異常データほど必ず再構成誤差が0になることを利用する。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『潜在表現の次元数だけで異常かどうかを無条件に決める。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『入力のラベル名が長いほど異常と判定する。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『正常パターンはよく再構成できる一方、未知の異常パターンでは再構成誤差が大きくなることを利用する。』である。

総合解説： 対象の主張は『正常パターンはよく再構成できる一方、未知の異常パターンでは再構成誤差が大きくなることを利用する。』である。再構成誤差を異常度の一候補として用いる。 背景となる論点は次のとおりである。異常検知では正常・異常の分布、再構成能力、閾値設計を検証し、再構成誤差だけを万能指標としない。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0138 発展的要素技術 > オートエンコーダ ｜ 難易度：標準

ある受験者が「PCAはニューラルネットワークの誤差逆伝播でのみ計算できる。」と回答した。この誤りを最も適切に指摘する説明はどれか。

ア. 一般には一致しない。

イ. 非線形活性化を利用できる。

ウ. 非線形ネットワークは線形PCAより柔軟な写像を表現し得る。

エ. PCAには固有値分解やSVD等の方法がある。

答え・解説 **正答：エ**

ア： この説明は別の論点『PCAもオートエンコーダも必ず同じ潜在表現を返す。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『オートエンコーダは線形変換しか使えない。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『PCAは線形部分空間を求めるのに対し、非線形活性化を持つオートエンコーダはより複雑な非線形表現を学べる可能性がある。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『PCAはニューラルネットワークの誤差逆伝播でのみ計算できる。』である。

総合解説： 対象となる誤った主張は『PCAはニューラルネットワークの誤差逆伝播でのみ計算できる。』である。PCAには固有値分解やSVD等の方法がある。 正しい理解の背景は次のとおりである。深層オートエンコーダは非線形次元削減の代表例だが、学習コストや過学習なども考慮が必要である。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0139 発展的要素技術 > オートエンコーダ ｜ 難易度：応用

AI関連の資料レビューで「入力より大きい潜在次元では誤差逆伝播が禁止される。」という記述が見つかった。レビューコメントとして最も適切なものはどれか。

ア. 十分な容量があると入力をそのまま写す解へ逃げやすい。

イ. 再構成は定義できる。

ウ. 必ずゼロ活性になるわけではない。

エ. 勾配学習は可能である。

答え・解説 **正答：エ**

ア： この説明は別の論点『単純な恒等写像に近いコピーを学ぶだけでも再構成誤差を小さくでき、有用な特徴学習にならない可能性がある。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『潜在次元が大きいと数学的に再構成を定義できない。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『必ず全ての潜在ユニットが0になり学習不能になる。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『入力より大きい潜在次元では誤差逆伝播が禁止される。』である。

総合解説： 対象となる誤った主張は『入力より大きい潜在次元では誤差逆伝播が禁止される。』である。勾配学習は可能である。 正しい理解の背景は次のとおりである。過完備構成ではスパース性、ノイズ付加、正則化などを組み合わせ、単純コピーを避ける設計が重要になる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0140 発展的要素技術 > オートエンコーダ ｜ 難易度：応用

次の主張「VAEは潜在変数の確率分布を仮定し、再構成に加えて事前分布との整合を促す項を含む生成モデルとして設計される。」について、その理由を最も正確に説明しているものはどれか。

ア. 通常AEにその制約は必須でない。

イ. VAEにも生成側のdecoderがある。

ウ. 潜在変数を中心に構成される。

エ. VAEは確率的潜在変数モデルとして通常AEとは目的関数が異なる。

答え・解説 **正答：エ**

ア： この説明は別の論点『通常のオートエンコーダも必ず潜在分布を標準正規分布へ一致させる。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『VAEはデコーダを持たず分類器だけで構成される。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『VAEでは潜在変数を使わず入力をそのまま出力する。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『VAEは潜在変数の確率分布を仮定し、再構成に加えて事前分布との整合を促す項を含む生成モデルとして設計される。』である。

総合解説： 対象の主張は『VAEは潜在変数の確率分布を仮定し、再構成に加えて事前分布との整合を促す項を含む生成モデルとして設計される。』である。VAEは確率的潜在変数モデルとして通常AEとは目的関数が異なる。 背景となる論点は次のとおりである。G検定でオートエンコーダを理解する際は、入力再構成を基礎に、生成モデルへ発展したVAEとの違いも整理するとよい。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0141 発展的要素技術 > データ拡張 ｜ 難易度：基礎

学習者が「入力特徴量を必ず1個だけに減らす。」と理解している。この理解を修正するための説明として最も適切なものはどれか。

ア. これはデータリークになる。

イ. 学習自体を不要にする手法ではない。

ウ. 訓練分布の多様性を増やし、変換に対する頑健性を学ばせる。

エ. 次元削減が目的ではない。

答え・解説 **正答：エ**

ア： この説明は別の論点『テストデータの正解ラベルを訓練データへコピーする。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『モデルの全パラメータを削除して学習を不要にする。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『ラベルの意味を保つ変換などで訓練データの多様性を増やし、過学習を抑えて汎化性能を高める。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『入力特徴量を必ず1個だけに減らす。』である。

総合解説： 対象となる誤った主張は『入力特徴量を必ず1個だけに減らす。』である。次元削減が目的ではない。 正しい理解の背景は次のとおりである。画像では回転・反転・クロップ・色変換など、タスク意味を壊さない変換を選ぶことが重要である。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0142 発展的要素技術 > データ拡張 ｜ 難易度：基礎

実務上の判断で「変換後も原則として元ラベルが妥当である範囲で、位置・色・形状などに多様性を与える。」という考え方を採用した。その判断根拠として最も適切なものはどれか。

ア. ラベルを無作為に変えると教師信号が壊れる。

イ. 対象情報を破壊すると誤った学習になり得る。

ウ. データリークを招く。

エ. 拡張はタスクの意味を保つことが基本である。

答え・解説 **正答：エ**

ア： この説明は別の論点『画像内容が何であってもラベルを毎回別クラスへ変更する。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『識別対象を完全に消すほど強い変換だけを使う。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『検証データを訓練データへ混ぜることで多様性を増やす。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『変換後も原則として元ラベルが妥当である範囲で、位置・色・形状などに多様性を与える。』である。

総合解説： 対象の主張は『変換後も原則として元ラベルが妥当である範囲で、位置・色・形状などに多様性を与える。』である。拡張はタスクの意味を保つことが基本である。 背景となる論点は次のとおりである。有効な拡張はタスク依存であり、物理・意味的に妥当な不変性をモデルへ教える設計と考えられる。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0143 発展的要素技術 > データ拡張 ｜ 難易度：基礎

教材の草案に「訓練データには一切適用せず、テストデータだけをランダム変換する。」とある。内容を訂正する際に示す説明として最も適切なものはどれか。

ア. 訓練時の多様化と評価時の公平な測定を分けるのが基本である。

イ. テスト情報の訓練利用はリークである。

ウ. 検証情報への過適合を招く。

エ. 通常のデータ拡張の目的と逆である。

答え・解説 **正答：エ**

ア： この説明は別の論点『主に訓練データへ適用し、検証・テストでは評価条件を一定にして元分布上の性能を測る。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『テストセットを拡張して、その生成画像を訓練に戻す。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『検証データのラベルを見ながら最も有利な変換だけを選び訓練へ反映する。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『訓練データには一切適用せず、テストデータだけをランダム変換する。』である。

総合解説： 対象となる誤った主張は『訓練データには一切適用せず、テストデータだけをランダム変換する。』である。通常のデータ拡張の目的と逆である。 正しい理解の背景は次のとおりである。Test-Time Augmentationという別手法もあるが、通常の拡張と区別し、評価設計を明示する必要がある。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0144 発展的要素技術 > データ拡張 ｜ 難易度：標準

「ランダムクロップ、左右反転、回転、色調変換などをタスクに応じて適用する。」という説明を正しいと判断する際、最も適切な根拠はどれか。

ア. これは転移学習に近く、データ拡張ではない。

イ. ラベル順序の変更は入力多様化ではない。

ウ. 情報を消してしまい通常は有効な拡張にならない。

エ. 幾何変換や色変換は代表的な画像拡張である。

答え・解説 **正答：エ**

ア： この説明は別の論点『学習済み重みを毎回別の資格試験モデルからコピーする。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『画像ラベルをアルファベット順に並べ替える。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『全画像の画素を同じ一定値へ置換する。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『ランダムクロップ、左右反転、回転、色調変換などをタスクに応じて適用する。』である。

総合解説： 対象の主張は『ランダムクロップ、左右反転、回転、色調変換などをタスクに応じて適用する。』である。幾何変換や色変換は代表的な画像拡張である。 背景となる論点は次のとおりである。拡張手法は対象タスクの不変性と整合するものを選ぶ。例えば左右反転が意味を変える文字認識などでは注意が必要である。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0145 発展的要素技術 > データ拡張 ｜ 難易度：標準

研修資料に「回転により意味するクラスが変わり得るため、誤った教師ラベルを生成する可能性がある。」と記載されている。この記述を最も直接的に裏付ける説明はどれか。

ア. 暗号化とは無関係である。

イ. タスクによっては有効な場合もある。

ウ. 教師ありデータ拡張ではラベルを維持して使うことが多い。

エ. ラベル保存性が成立しない変換は教師信号を壊す。

答え・解説 **正答：エ**

ア： この説明は別の論点『回転すると画像データは必ず暗号化され学習不能になる。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『180度回転はどの画像タスクでも数学的に禁止されている。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『データ拡張ではラベルを使えないため問題になる。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『回転により意味するクラスが変わり得るため、誤った教師ラベルを生成する可能性がある。』である。

総合解説： 対象の主張は『回転により意味するクラスが変わり得るため、誤った教師ラベルを生成する可能性がある。』である。ラベル保存性が成立しない変換は教師信号を壊す。 背景となる論点は次のとおりである。『よく使われる拡張だから常に正しい』ではなく、対象ドメインで意味が保存されるかを判断する必要がある。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0146 発展的要素技術 > データ拡張 ｜ 難易度：標準

ある受験者が「2つのモデルの重みを平均するだけで入力データは変更しない。」と回答した。この誤りを最も適切に指摘する説明はどれか。

ア. 難例削除ではない。

イ. 単純重複より異なる中間例を生成する。

ウ. Mixupは入力とラベルの線形補間による拡張として知られる。

エ. モデル重み平均とは別概念である。

答え・解説 **正答：エ**

ア： この説明は別の論点『訓練データから難しい例を全て削除する。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『同じ画像を無変換で複製し続けることだけを指す。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『2つの訓練例とそのラベルを重み付きで混合し、中間的なサンプルを作って学習する。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『2つのモデルの重みを平均するだけで入力データは変更しない。』である。

総合解説： 対象となる誤った主張は『2つのモデルの重みを平均するだけで入力データは変更しない。』である。モデル重み平均とは別概念である。 正しい理解の背景は次のとおりである。高度な拡張では画像変換だけでなく、複数サンプルを混合して決定境界を滑らかにする考え方もある。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0147 発展的要素技術 > データ拡張 ｜ 難易度：標準

AI関連の資料レビューで「少数クラスのラベルを多数クラスへ全て変更する。」という記述が見つかった。レビューコメントとして最も適切なものはどれか。

ア. 少数クラスのデータ多様化に利用できるが、万能ではない。

イ. 少数クラス性能を評価できなくなる。

ウ. 不均衡ではPrecision/Recall等も重要になり得る。

エ. 分類目的を壊す。

答え・解説 **正答：エ**

ア： この説明は別の論点『少数クラスに妥当な変換を適用して多様な訓練例を増やす方法は候補になるが、実分布を歪めないか評価が必要である。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『少数クラスを削除して二度と評価しない。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『拡張を行えば評価指標は必ずAccuracyだけで十分になる。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『少数クラスのラベルを多数クラスへ全て変更する。』である。

総合解説： 対象となる誤った主張は『少数クラスのラベルを多数クラスへ全て変更する。』である。分類目的を壊す。 正しい理解の背景は次のとおりである。データ拡張は再サンプリングや損失重み付け等と並ぶ選択肢で、元データの偏りや実運用分布を考慮する。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0148 発展的要素技術 > データ拡張 ｜ 難易度：標準

次の主張「各foldで訓練部分にだけ拡張を適用し、検証部分由来の情報が訓練サンプル生成へ入らないようにする。」について、その理由を最も正確に説明しているものはどれか。

ア. 同一元データの派生画像が別foldへ入る危険がある。

イ. 明確なリークである。

ウ. テスト情報による調整は評価を汚染する。

エ. 元画像とその派生版がtrain/validationをまたぐと情報漏洩が起こり得る。

答え・解説 **正答：エ**

ア： この説明は別の論点『全データを先に拡張してから元画像と派生画像を無作為に別foldへ分ける。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『検証画像の拡張版を訓練foldへ必ず追加する。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『テストセットを含む全データの統計を使って拡張条件を最適化する。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『各foldで訓練部分にだけ拡張を適用し、検証部分由来の情報が訓練サンプル生成へ入らないようにする。』である。

総合解説： 対象の主張は『各foldで訓練部分にだけ拡張を適用し、検証部分由来の情報が訓練サンプル生成へ入らないようにする。』である。元画像とその派生版がtrain/validationをまたぐと情報漏洩が起こり得る。 背景となる論点は次のとおりである。データ拡張も前処理パイプラインの一部として、データ分割後に訓練側だけで適用する原則を守る。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/

0149 発展的要素技術 > データ拡張 ｜ 難易度：応用

学習者が「拡張強度は無限大でも必ず精度が単調に向上する。」と理解している。この理解を修正するための説明として最も適切なものはどれか。

ア. 拡張は通常データ多様性を増やすためのものだが、強さとの関係は単純でない。

イ. 拡張には適切な強度範囲があり、タスク依存で検証が必要である。

ウ. 学習分布を変えるため性能に影響し得る。

エ. 性能向上は保証されない。

答え・解説 **正答：エ**

ア： この説明は別の論点『強い拡張ほど訓練データ数が減るので過学習が必ず増える。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『強すぎる変換は現実のデータ分布から外れたりラベル意味を壊したりするため、検証データで妥当性を確認する必要がある。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『拡張強度はモデル性能に一切影響しない。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の誤った主張がなぜ不適切かを直接説明しているため適切である。対象の主張は『拡張強度は無限大でも必ず精度が単調に向上する。』である。

総合解説： 対象となる誤った主張は『拡張強度は無限大でも必ず精度が単調に向上する。』である。性能向上は保証されない。 正しい理解の背景は次のとおりである。拡張は『現実に起こり得る変動』や求める不変性をモデルへ教える手段であり、過度な変換は逆効果になり得る。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

0150 発展的要素技術 > データ拡張 ｜ 難易度：応用

実務上の判断で「広義のデータ拡張として利用できるが、生成物の品質・偏り・重複・ラベル妥当性を検証してから学習へ使うべきである。」という考え方を採用した。その判断根拠として最も適切なものはどれか。

ア. 生成物にもアーティファクトや偏りがあり得る。

イ. 実データを排除する一般原則はない。

ウ. 生成ベースのaugmentationも研究・実用されている。

エ. 生成データも訓練分布を補う手段になり得るが品質管理が必要である。

答え・解説 **正答：エ**

ア： この説明は別の論点『生成モデルが作ったデータは必ず実データより正確なので無検証でよい。』に対応するもので、今回示された主張を直接説明するものではない。

イ： この説明は別の論点『合成データを使えば実データは必ず全て削除すべきである。』に対応するもので、今回示された主張を直接説明するものではない。

ウ： この説明は別の論点『生成画像はデータ拡張に含まれ得ないため学習に使えない。』に対応するもので、今回示された主張を直接説明するものではない。

エ： 対象の主張に対応する根拠を直接説明しているため適切である。元の主張は『広義のデータ拡張として利用できるが、生成物の品質・偏り・重複・ラベル妥当性を検証してから学習へ使うべきである。』である。

総合解説： 対象の主張は『広義のデータ拡張として利用できるが、生成物の品質・偏り・重複・ラベル妥当性を検証してから学習へ使うべきである。』である。生成データも訓練分布を補う手段になり得るが品質管理が必要である。 背景となる論点は次のとおりである。データ拡張の本質は単なる件数増加ではなく、実運用に役立つ多様性を追加することにある。

対象：G検定シラバス2024 v1.4（2026-05-11改訂） / 基準日 2026-09-09

© 2026 資格ブートキャンプ｜個人学習用。法令上認められる場合を除き、無断転載・再配布・販売・第三者への配布・教材等への無断利用を禁止します。利用規約：https://shikaku-bootcamp.com/terms/