

Leaky ReLU	ReLU	Tanh	Sigmoid
$g(z) = \max(\epsilon z, z)$ $\epsilon \ll 1$	$g(z) = \max(0, z)$	$g(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$	$g(z) = \frac{1}{1 + e^{-z}}$

ملخص مختصر التعلم العميق

افشين عميدى و شروين عميدى

١٤ ربيع الثاني، ١٤٤١

□ دالة الانتروبيا التقاطعية للخسارة (Cross-entropy loss) - في سياق الشبكات العصبونية، دالة الانتروبيا $L(z, y)$ تستخدم و تعرف كالآتي □

$$L(z, y) = - \left[y \log(z) + (1 - y) \log(1 - z) \right]$$

تمت الترجمة بواسطة امجد الخطابي. تمت المراجعة بواسطة زيد اليافعي.

□ معدل التعلم (Learning rate) - معدل التعلم، يرمز ، و هو مؤشر في اي تجاة يتم تحديث الازان. يمكن تثبيت هذا المعامل او تحديثه بشكل تأقلمي . حاليا اكثر النسب شيوعا تدعى Adam ، وهي طريقة تجعل هذه النسبة سرعة التعلم بشكل تأقلمي α او η ،

□ التغذية الخلفية (Backpropagation) - التغذية الخلفية هي طريقة لتحديث الازان في الشبكة العصبونية عبر اعتبار القيم الحقيقية للنتاج مع القيمة المطلوبة للخروج. المشتقة بالنسبة للوزن w يتم حسابها باستخدام قاعدة التسلسل و تكون عبر الشكل الآتي □

$$\frac{\partial L(z, y)}{\partial w} = \frac{\partial L(z, y)}{\partial a} \times \frac{\partial a}{\partial z} \times \frac{\partial z}{\partial w}$$

كنتيجة ، الوزن سيتم تحديثه كالتالي:

$$w \leftarrow w - \eta \frac{\partial L(z, y)}{\partial w}$$

□ تحديث الازان - في الشبكات العصبونية ، يتم تحديث الازان كما يلي:


- الخطوة ١: خذ حزمة من بيانات التدريب
- الخطوة ٢: قم بعملية التغذية الامامية لحساب الخسارة الناتجة
- الخطوة ٣: قم بتغذية خلفية للخسارة للحصول على دالة الانحدار
- الخطوة ٤: استخدم قيم الانحدار لتحديث اوزان الشبكة

□ الاسقاط (Dropout) - الاسقاط هي طريقة الغرض منها منع التكيف الزائد للنموذج في بيانات التدريب عبر اسقاط بعض الواحدات في الشبكة العصبونية، العصبونات يتم اما اسقاطها باحتمالية p او الحفاظ عليها باحتمالية $1 - p$.

الشبكة العصبونية الاصطناعية (Neural Networks)

الشبكة العصبونية الاصطناعية هي عبارة عن نوع من النماذج يبني من عدة طبقات ، اكثر هذه الانواع استخداما هي الشبكات الالتفافية و الشبكات العصبونية المتكررة

□ البنية - المصطلحات حول بنية الشبكة العصبونية موضح في الشكل ادناه



عبر تدوين i كالطبقة رقم i و j للدلالة على رقم الوحدة الخفية في تلك الطبقة ، نحصل على □

$$z_j^{[i]} = w_j^{[i]T} x + b_j^{[i]}$$

حيث نعرف w, b, z كالوزن ، و معامل التعديل ، و الناتج حسب الترتيب.

□ دالة التفعيل (Activation function) - دالة التفعيل تستخدم في نهاية الوحدة الخفية لتضمن المكونات الغير خطية للنموذج. هنا بعض دوال التفعيل الشائعة

الشبكات العصبونية الالتفافية (CNN)

□ دالة القاعدة - لاي قاعدة معطاة π و حالة s ، نقوم بتعريف دالة القيمة V^π كما يلي:

$$V^\pi(s) = E \left[R(s_0) + \gamma R(s_1) + \gamma^2 R(s_2) + \dots | s_0 = s, \pi \right]$$

□ معادلة بيلمان - معادلات بيلمان المثلى تشخص دالة القيمة دالة القيمة V^{π^*} : للقاعدة المثلى

$$V^{\pi^*}(s) = R(s) + \max_{a \in \mathcal{A}} \gamma \sum_{s' \in \mathcal{S}} P_{sa}(s') V^{\pi^*}(s')$$

π^* للحالة المعطاه s تعطى كالتالي: ملاحظة: نلاحظ ان القاعدة المثلى

$$\pi^*(s) = \operatorname{argmax}_{a \in \mathcal{A}} \sum_{s' \in \mathcal{S}} P_{sa}(s') V^*(s')$$

□ خوارزمية تكرار القيمة (Value iteration algorithm) - خوارزمية تكرار القيمة تكون في خطوتين:

١. □ نقوم بوضع قيمة اولية □

$$V_0(s) = 0$$

٢. □ نقوم بتكرير القيمة حسب القيم السابقة □

$$V_{i+1}(s) = R(s) + \max_{a \in \mathcal{A}} \left[\sum_{s' \in \mathcal{S}} \gamma P_{sa}(s') V_i(s') \right]$$

□ تقدير الامكانية القصوى - تقديرات الامكانية القصوى □ تقدير الاحتمال الأرجح □ لاحتماليات انتقال الحالة تكون كما يلي □

$$P_{sa}(s') = \frac{\text{اوقات تنفيذ الاجراء } a \text{ في الحالة } s \text{ وانتقلت الى } s'}{\text{اوقات تنفيذ الاجراء } a \text{ في الحالة } s}$$

□ التعلم- Q (Q -learning) - هي طريقة غير منمذجة لتقدير Q ، و تتم كالآتي:

$$Q(s,a) \leftarrow Q(s,a) + \alpha \left[R(s,a,s') + \gamma \max_{a'} Q(s',a') - Q(s,a) \right]$$

□ احتياج الطبقة الالتفافية - عبر رمز W لحجم المدخل، F حجم العصبونات للطبقة الالتفافية، P عدد الحشوات الصفرية، فإن N عدد العصبونات لكل حجم معطى يحسب عبر الآتي:

$$N = \frac{W - F + 2P}{S} + 1$$

□ تنظيم الحزمة (Batch normalization) - هي خطوه من قيم التحسين الخاصة γ, β والتي تعدل الحزمة $\{x_i\}$. لنجعل μ_B, σ_B^2 المتوسط والانحراف للحزمة المعنية و نريد تصحيح هذه الحزمة، يتم ذلك كالتالي:

$$x_i \leftarrow \gamma \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} + \beta$$

في الغالب تتم بعد الطبقة الالتفافية أو المتصلة كليا و قبل طبقة التغيرات الغير خطية و تهدف للسماح للسرعات التعليم العالية للتقليل من الاعتمادية القوية للقيم الاولية.

(RNN) الشبكات العصبونية التكرارية

□ انواع البوابات - هنا الانواع المختلفة التي ممكن مواجهتها في الشبكة العصبونية الاعتيادية:

بوابة ادخال	بوابة نسيان	بوابة اخراج	بوابة منفذ
كتابة ام عدم كتابة الى الخلية؟	مسح ام عدم مسح الخلية؟	مدى الافصاح عن الخلية ؟	كمية الكتابة الى الخلية ؟

□ LSTM - ذاكرة طويلة قصيرة الامد (long short-term memory) هي نوع من نموذج ال RNN تستخدم لتجنب مشكلة اختفاء الانحدار عبر اضافة بوابات النسيان.

التعلم و التحكم المعزز (Reinforcement Learning)

الهدف من التعلم المعزز للتعلم الذكي هو التعلم لكيفية التأقلم في اي بيئة.

□ عملية ماركوف لاتخاذ القرار - عملية ماركوف لاتخاذ القرار هي سلسلة خماسية $(S, \mathcal{A}, \{P_{sa}\}, \gamma, R)$ حيث

• S هي مجموعة من حالات البيئة

• \mathcal{A} هي مجموعة من حالات الاجراءات

• $\{P_{sa}\}$ هو حالة احتمال الانتقال من الحالة $s \in S$ و $a \in \mathcal{A}$

• $\gamma \in [0, 1]$ هي عامل الخصم

• $R : S \times \mathcal{A} \rightarrow \mathbb{R}$ هي دالة المكافأة والتي تعمل الخوارزمية على جعلها اعلى قيمة

□ دالة القواعد - دالة القواعد $\mathcal{A} : S \rightarrow$ هي التي تقوم بترجمة الحالات الى اجراءات.

ملاحظة: نقول ان النموذج ينفذ القاعدة المعينه π للحالة المعطاة s ان نتخذ الاجراء $a = \pi(s)$.