

分光画像と機械学習を用いた トマトの収穫時期予測に関する研究

洞井 晋一¹ 増田 貴大¹ 坂川 涼¹ 東田 光裕¹

概要: 農作物を効率的に流通・販売するために収穫時期の正確な予測が求められている。特にトマトの収穫時期を予測することは、様々な要因が複雑に関係しているため困難であることが知られている。我々はトマトの成熟に伴って変化する成分値変化に着目し、スペクトルカメラによって撮影した分光画像をニューラルネットワークを用いて解析した。千葉・熊本の協力農家で撮影したトマトの分光画像と、TensorFlow を用いたニューラルネットワークによる解析の結果、5日前のトマトであれば誤差2日以内で予測可能であることが分かった。また、多段のニューラルネットワークを用いてもそれほど効果は見られず、糖度などの成分値を反映していると考えられる近赤外線領域を学習しても大きな効果は見られなかった。これらの結果から、5日より以前の予測精度を高めるためには、ニューラルネットワークの再設計と、トマトそのものの大きさなどを考慮する必要があると考えられる。

A Study on Prediction of Harvest Time using Multi-Spectral Imaging and Machine Learning

SHINICHI DOI¹ TAKAHIRO MASUDA¹ RYO SAKAGAWA¹ MITSUHIRO HIGASHIDA¹

1. はじめに

農作物を効率的に生産・流通させるために、収穫時期を予測する試みが行われている [1][2][3]。個々の野菜の収穫時期を予測することで農場全体の収穫量を予測することができるため、特に農作物を流通・販売する分野において技術確立が期待されている。例えば生産現場での効率的な労働力確保や、流通に使用する車両の確保と適切なルート設定、効率的な販売店への分配や効果的な広告戦略など、収穫時期の予測は幅広い用途に応用することができる。農作物の中でも特にレタスやキャベツ、小松菜といった葉物（葉菜類）に関しては気温と日照量を計測することで高い精度での収穫時期予測が可能であることが知られている。一方、健康志向の盛り上がりと栄養価の高さから様々な料理におけるトマトの利用が注目されているが、トマトやイチゴのような果物（果菜類）に関しては気温や日照量などの環境情報だけで収穫時期を正確に予測することが難しい。このため、特に果実の大きな大玉トマトでは個々の収穫時期の

誤差が農場全体の収穫量に大きな影響を及ぼしている。大規模な農場においては一部トマトの収穫時期を調整することで収穫量の誤差を吸収することができるが、中・小規模農家ではそうした調整も難しい。

我々はトマトの収穫時期を予測するために、個々のトマトを収穫する際に農業者が基準としているトマトそのものの色と、成長に伴って変化する糖度や酸度といったトマトの成分値に着目した。一般的に農業者はトマトを収穫する際にトマトの着色度合で判断する。2章で説明するようにトマトは成熟段階になると緑色から赤色に変化するため、基本的に農業者はこの色の変化で収穫可能かどうかを判断する。このような着色度合による収穫判断は比較的容易であるが、着色度合による収穫時期の予測は農業者の経験や勘に左右される。これは収穫数日前の着色度合は変化が微細であることや、農場の光源環境なども一定ではないことが影響している。このような微細な変化は人間の目で判断するよりも条件を一定にしたカメラなどで機械的に判断した方が予測の精度は高まると考えられる。また、トマトは成熟するに従って糖度や酸度といった成分値が変化

¹ 西日本電信電話株式会社

するため、成分値の変化を捉えることができればより収穫時期の予測精度は向上すると考えられる。このような植物に含まれる成分値の変化は近赤外線の吸収スペクトルと相関があることが知られている [4]。そこで、色の変化や近赤外線の波長強度の変化を捉えることができるスペクトルカメラを用い、各波長のスペクトル強度を記録した分光画像の撮影を行った。また、微細な変化や相関を捉えることができるニューラルネットワークの技術を用いて分光画像を解析し、収穫時期の予測を行った。

我々が想定している将来的なシステム全体像を図 1 に示す。定点カメラもしくはレールを走行する移動カメラなどを圃場内に設置し、定期的にトマトを撮影する。こうしたレールはトマトを収穫する際に作業負担を軽減する目的で設置されることが多く、システムのために別途設置する必要はないため低コストでの導入が可能である。撮影した画像はサーバに転送し、サーバ上で画像解析を行うことで圃場全体で収穫されるトマトの個数や時期などを集計する。農家によっても異なるが、トマトの収穫間隔は 2~3 日程度であることが多く、リアルタイム性を必要としないためクラウド上の余剰資源などを使うことで低コストでシステム構築を見込むことができる。我々はこのように農作業者に新たな作業を加えることなく、高精度な収穫時期の予測を機械的に行えるシステム構築を目指しており、本システムでは自動的に撮影した画像から収穫時期を予測する方法が重要となる。本論文ではこの予測の方法について詳細を述べる。2 章では関連研究としてトマトの収量予測とスペクトルカメラを用いた成分分析について述べ、3 章では我々が提案するスペクトルカメラとニューラルネットワークを用いた収穫時期の予測手法について述べる。4 章に千葉・熊本で撮影した画像を用いた提案手法の結果、4.3 章にその考察を述べ、5 章でまとめる。

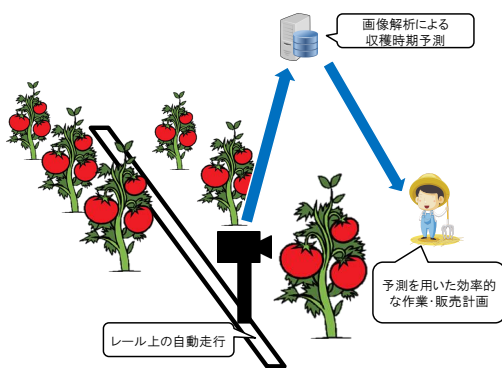


図 1 将来的なシステム全体像

2. 関連研究

本章では 2.1 節でトマトの収穫量予測の現状と、2.2 節で成分値解析に用いるスペクトルカメラについて述べる。

2.1 トマトの収穫量予測

トマトは開花後、果実肥大期を経て緑熟期となり、徐々に赤みを帯びて完熟期となる。完熟してから収穫すると、流通過程の温度にもよるが短時間で過熟状態になるため、市場等を経由して流通させる場合は市場価値が失われてしまう。そのため少し着色した程度、または着色していない状態（早採り果）で出荷されることが多く、流通の過程で果実温度が 20 度前後であれば着色が進み可食状態になる [5]。しかしこうした早採り果は完熟した状態のトマト（完熟収穫果）に比べて食味が悪く栄養価も低い [6]。完熟収穫果は健康志向の盛り上がりや栄養価の高さ [7] などから需要が高く、農家が量販店や直販所を通じて提供する事例も増えてきている。このような中・小規模の農家が完熟収穫果を市場を経ずに流通させる場合において、2、3 日前における精度の高い収穫量予測は流通や販売の効率化に大きく貢献できる。

トマトの収穫量は積算日射量と高い相関があることが分かっている [8] が、中・小規模農家にとっては精度が十分ではない。個々のトマトの収穫時期を高い精度で予測できれば、それらを集計することで収穫量の予測精度を向上できるが、トマトの成熟には様々な要因が関係しているため個々の予測は容易ではない。まず、葉菜類では葉の光合成によって生成された栄養素がそのまま葉に蓄積されるのに対し、果菜類では茎を伝って果実に分配されるため、どの果実にどの程度分配されるかを予測することが難しく、特に果実肥大期に果実の成長度合いを事前に知ることは難しい。また、トマトの緑熟期から完熟期への移行には果実温が大きく関係しているが、葉の密集したトマトハウス内では場所により日照量が変わるため、果実温が一定にならない。加えて葉による蒸散効果も影響するためトマト周辺の葉の量なども果実温に影響する。また、日本国内において広く行われている長期多段栽培（一本のトマト樹から複数の房を収穫する栽培法）では、トマト樹の成長に伴って高所にあったトマト房を低所に移すなどの作業が行われる。こうした農作業の結果、個々のトマトに対する日照量が変わるため、果実温が変化し、個々のトマトについての収穫時期予測を難しくしている。

こうした複雑な要因に対する予測を行う手法として、ニューラルネットワークを用いた AI 技術を適用する事例がある [9][10]。これらの手法では気温や日照量などの環境データを元にモデル化しているため、個々のトマトについての収穫時期を高い精度で予測することは困難である。

以上のように個々のトマトについて果実肥大期から完熟期にかけての変化を環境データを元にして予測することは難しい。そこで我々はトマト個体の色の変化や、含有する成分値の変化に着目し、収穫時期の予測を行った。

2.2 スペクトルカメラを用いた成分値解析

果実の成分値を測定するには光の吸収スペクトルを計測する方法が一般的である [11]. 物質は特有の波長領域で光を吸収するため、物質を通過もしくは反射した光を測定することで対象物に含まれる成分を知ることができる. 特に近赤外線の波長 (700nm から 2500nm) は野菜や果物の品質検査に古くから用いられており、穀物 [12] やメロン [13], イチゴ [14] の品質検査や、トマトのリコピン量 [15] の測定などの試みがある. このような成分値分析では、特定の成分値を単一の波長による吸収率だけで表すことは難しく、複数の波長の組み合わせによって成分値を算出している. そのため、未知の成分や収穫日と関連性のある波長を導出するには膨大な組み合わせの計算が必要となる. こうした光の吸収スペクトルを画像として撮影できる「スペクトルカメラ」と呼ばれる製品が市販されている. 画像としてスペクトル情報を得ることで、例えば果実の底部における成分値と側面における成分値の違いなど、より詳細に分析することができる.

こうしたスペクトルカメラによって撮影されたデータ (分光画像) は、製品によっても異なるが各波長毎の画像として記録される場合が多い. 例えば横幅 1280 ピクセル、高さ 1024 ピクセルの画像を 350nm から 1100nm までの波長を 5nm の分解能で撮影できるスペクトルカメラの場合、各波長毎に 151 枚のグレースケール画像が生成される. 各波長の反射率を確認することは容易だが、複数の波長の組み合わせとそれらの画像の特徴、成分値や収穫日との関連を見つけるには、単純なスペクトル強度の組み合わせ以上の計算が必要となる.

3. スペクトルカメラとニューラルネットワークを用いた収穫時期予測

我々は 2.2 節で述べたように、スペクトルカメラを用いてトマトの果実を直接撮影し、得られた分光画像を解析することで個々のトマトの収穫日を予測を試みた. このとき波長の組み合わせによる計算量の増大が問題となるため、ニューラルネットワークを用いることで現実的な時間内で精度の高い収穫日予測を行う.

ニューラルネットワークは、図 2 のように、教師データとして入力値 X_{train} と出力値 Y_{train} を用意したとき、行列 X_{train} と、重みとなる行列 W_0 の積を計算し、行列 X_0 を得る. この計算を繰り返し行うことで最終的に行列 Y を得る. 行列 Y と Y_{train} を比較したときの誤差を用いて行列 W_n を更新し、様々な入力値に対して誤差が小さくなるように何度も重みの値を計算させることで、入力値に対して適切な出力値を得るような重み行列を学習していく. 一般的にニューラルネットワークにおいて画像解析を行う場合、モノクロ画像か、カラー画像として赤・緑・青の三色画像を用いるため、スペクトルカメラで撮影した分光画像をそのま

ま適用することはできない. 例えば 28 ピクセル四方の三色画像を入力値として与える場合は、 $28 \times 28 \times 3$ の行列として入力するが、分光画像の場合は $27 \times 28 \times 151$ の行列として入力する必要がある. また、画像処理を行うニューラルネットワークは、空間的な特徴が近接した場所に関連性が高くなる傾向を利用し、CNN[16] に代表されるように画像の空間的な特徴を効率よく学習するように設計されている. 吸収スペクトルは離れた波長に関連性が見られることもあり一般的なニューラルネットワークの手法を用いても効率的な学習を期待することは難しい.

我々はトマトの収穫時期予測にニューラルネットワークを用いるにあたり、下記のように画像に対する前処理と学習フェーズを分離することで効率的な収穫時期予測を行った.




図 2 ニューラルネットワークの概要

3.1 トマトの収穫日

トマトの収穫時期予測を学習させるために、まずトマト画像に対して正解となる値 (収穫までの日数) を付与する必要がある. 我々は実際にトマトを栽培している農家に協力いただき、農場で栽培されているトマトを撮影した. このとき、撮影対象となる個々のトマトに一意な識別子を付与し、それらのトマトを追跡して定期的に撮影した. 撮影した画像を確認することでトマトが実際に収穫されたかどうかを判断し、識別子と収穫された日に関連付け、撮影日時と収穫日を用いて、収穫までの日数を逆算した. これらの作業は実際に行うと摘果や撮影ミスなどの影響が大きいため、作業者が目視で確認しながら行う必要があった.

3.2 トマトの矩形画像抽出

図 3 のように、一般的にトマトは 2~3 個の房として実が成り、長期多段栽培ではそれらの房を一段として計上し、一本の樹に数段実らせる. トマトを個別に撮影することは実際の作業として現実的ではなく、房ごとに撮影を行った. 一方でトマトは房ごとではなく個別に収穫されるため、個々の識別子に対応した入力値となる画像を得るためには撮影

画像からトマト部分を切り出す必要がある。トマトの輪郭などの特徴から矩形部分としてトマトを抽出することもできるが、3.1節での目視確認の作業時に平行して矩形部分の特定を行った。



図 3 房なりトマトの成果状態

3.3 吸収スペクトル強度の抽出

個々のトマト画像を目視で確認したところ、収穫1週間前のトマトは外観に変化がほとんどないことが明らかになった。そのため、まず色や成分値の変化を学習させるためにトマトの各スペクトルの強度だけに着目し、学習を実施した。この強度の抽出を行う際には平均値ではなく中央値を用いた。これは、トマトの表面が滑らかな球面であるために、撮影時のライトなどが飽和した状態で写っている場合に平均値では比較的高い値となってしまったり、またはトマト画像が小さい場合に背景部分の黒い部分が影響して低い値になってしまうためである。

3.4 回帰分析を行うニューラルネットワークの設計

スペクトル強度だけを抽出したデータを図4に示すニューラルネットワークを用いて学習させた。ニューラルネットワークの作成には TensorFlow[17] を用いた。例えば入力した画像に何が写っているかを判別するような問題はクラス分類に属し、出力される Y の行列は各クラスに属する確率として表される。一方で我々の収穫日予測の問題は回帰分析の分類に属するため、出力される Y の行列は1次元の値のみとした。学習に用いる損失関数には二乗和誤差を用い、パラメータの更新には rmsprop[18] を用いた。

4. 実験と評価

2016年10月17日から2016年11月11日にかけて千葉県農家の協力を頂き、トマトの分光画像を合計711枚撮影した。また、2016年11月24日から2016年12月20日にかけて熊本県の農家に協力して頂き、トマトの分光画像を合計2263枚撮影した。これらの分光画像からトマトの抽出と収穫が特定できるトマトを選別し、152枚の分光画

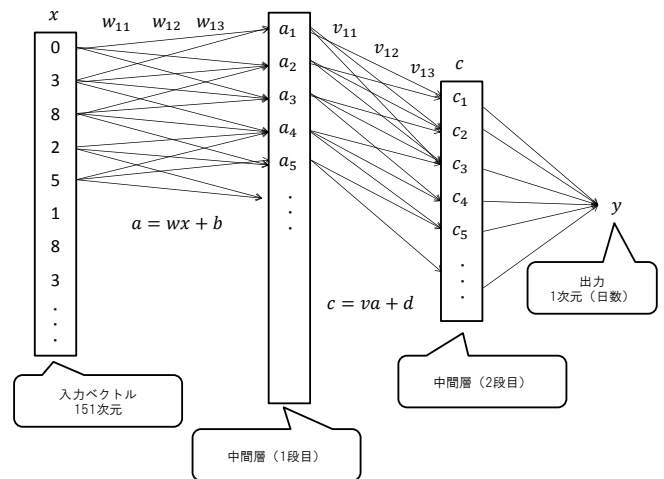


図 4 ニューラルネットワークの設計図

像を実験用データとして得た。152枚のうち106枚を教師用データとして利用し、残りの46枚を検証用データとして利用した。

評価対処となる予測精度として、 N 個の検証用データをニューラルネットワークに与えたときの出力 Y と、実際の収穫までの日数 Y_{train} を用いて式4のように精度 V を評価した。

$$V = \frac{1}{N} \sum_{n=0}^N |Y^n - Y_{train}^n|$$

V は正解値と予測値の差分を日数単位で表し、それらの平均によって表す。 V を2、3日毎の各期間ごとに集計し、収穫日が近づくにつれてどのように精度が変化するかを検証した。また、近赤外領域による学習効果を検証するため、可視光データのみによる検証も実施した。評価に用いたニューラルネットワークは表1のものを扱い、段数によって精度にどの程度影響が出るかを確認した。

表 1 ニューラルネットワークのパターンと各段における次元数

検証パターン	1 段目	2 段目	3 段目	4 段目
A	2048			
B	2048	200		
C	2048	1024	200	
D	4096	2048	1024	200
E	4096	200		

4.1 可視光データのみによる検証

撮影した分光画像のうち、350nm から 680nm までの可視光領域のみに限定して教師データを作成し、ニューラルネットワークを用いて検証を行った。結果を表2に示す。

4.2 近赤外線を含むデータによる検証

撮影した分光画像の 350nm から 1100nm のすべての波長領域を用いて教師データを作成し、ニューラルネットワークを用いて検証を行った。結果を表3に示す。

表 2 可視光データのみによる検証結果

検証パターン	1 日前	3 日前	5 日前	6 日以前
A	0.62	2.17	2.16	2.16
B	1.01	1.82	1.78	2.49
C	0.99	1.94	1.91	2.96
D	0.63	2.49	2.99	2.41
E	0.73	2.13	1.78	2.58

表 3 近赤外線を含むデータによる検証結果

検証パターン	1 日前	3 日前	5 日前	6 日以前
A	1.04	2.44	2.25	2.33
B	1.29	2.16	2.04	2.59
C	1.22	1.95	2.04	2.37
D	0.51	1.76	2.89	2.89
E	0.82	1.96	2.18	2.88

4.3 考察

実験結果からの考察を下記に示す。

4.3.1 トマトの収穫時期予測

表 2 の結果にあるように、可視光データを用いてニューラルネットワークの学習を行うことで 5 日前程度であれば誤差 2 日程度での予測が可能であることが分かった。農園の作業体制にもよるが、トマトの採取作業は 2~3 日毎に実施する農園が多いため誤差が 2 日程度であれば収穫量の予測に影響が出ないと考えられる。また、可視光データを用いるだけで予測が可能であったため、一般的なカメラで撮影した画像であっても収穫時期を予測できる可能性が高い。

一方で表 3 にあるように、近赤外線を含むデータを用いてもほとんど学習効果が得られないことが分かった。一部のデータを目視で確認したところ、近赤外線領域での変化はほとんど見られなかった。また、成熟段階の異なるトマトを破壊検査し、糖度の計測を行ったところ、表 4 のようになった。成熟が進むにつれてトマトの糖度は変化しているため、スペクトルカメラによる撮影で糖度の成分値の差を発見できていないことになる。これは、トマトが大玉であったため、トマト内部で乱反射した赤外光をスペクトルカメラで撮影することができず、トマト内部の成分値がスペクトル強度として現れなかったためと考えられる。

表 4 成長度合いと糖度

成長度合い	Brix 値 (%)
1	3.40
2	3.96
3	4.10
4	4.25
5	4.67

4.3.2 ニューラルネットワークによる学習

実験結果が最も良かったのは段数が 1 段のみのものとなり、段数を増やすほど結果が悪化することを確認した。これは段数を増やすことでニューラルネットワーク内のニュー

ロン数が増えたため、より過学習を起こしやすくなったためと考えられる。

3 日より以前の予測に関しては、スペクトルによる解析だけでなく、画像を用いた方法を検討する必要がある。特に 7 日より前は果実肥大期であるため、画像から判断するには果実そのものの大きさを学習する必要がある。しかし、一般的な画像認識の手法は被写体との距離を無効化するためにスケールに対して頑健であるため、画像の大きさを認識させることは難しい。ニューラルネットワークなどを用いて果実の大きさを推定させる場合は、撮影時に焦点距離を一定にするか撮影時の画角を用いるなどして撮影対象の大きさを測定し、画像とは別に大きさに関する情報を与えるなどの工夫が必要となる。

5. まとめ

トマトの収穫量を予測することは、特に中・小規模の農家が品質の良いトマトを販売する際に重要となる。スペクトルカメラとニューラルネットワークを用いることで、3 日前程度であれば収穫時期を予測可能であることが分かった。一方で近赤外線領域による判別は難しく、ニューラルネットワークを多段にしても学習効果が得られないことも分かった。7 日より以前の果実肥大期に関して予測を行う場合はトマトの大きさなどを考慮して予測する必要がある。今後はこのようなトマト特有の予測について精度を高めることと、イチゴなどの他の果菜類について適用可能性を検討していく。

謝辞

トマト撮影においては千葉県の上野市三須トマト農園、熊本県の高松農園、JA たまのの皆様に全面的にご協力いただいた。ここに感謝の意を表す。

参考文献

- [1] V Andrew McGlone, Robert B Jordan, and Paul J Martinsen. Vis/nir estimation at harvest of pre-and post-storage quality indices for 'royal gala' apple. *Postharvest Biology and Technology*, Vol. 25, No. 2, pp. 135-144, 2002.
- [2] PP Subedi, Kerry B Walsh, and G Owens. Prediction of mango eating quality at harvest using short-wave near infrared spectrometry. *Postharvest Biology and Technology*, Vol. 43, No. 3, pp. 326-334, 2007.
- [3] 脇山恭行, 井上君夫, 中園江. 水稻の登熟期における衛星データおよびアメダスデータを用いた収量予測法. *農業気象*, Vol. 59, No. 4, pp. 277-286, 2003.
- [4] 伊藤秀和, 森本進. 拡散反射・透過モードの近赤外分光法を用いる 10g 未満のトマトの糖度の非破壊計測. *照明学会雑誌*, Vol. 98, No. 11, pp. 581-584, 2014.
- [5] 今河茂, 南雅人, 八鍬利郎. 収穫熟度の異なる果実の追熟特性と果実構造についてのトマト 2 品種の比較. *北海道大学農学部農場研究報告 = Research bulletin of the University Farm Hokkaido University*, Vol. 26, pp. 87-92, 1989.
- [6] CA Bisogni, G Armbruster, and PE Brecht. Quality

comparisons of room ripened and field ripened tomato fruits. *Journal of Food Science*, Vol. 41, No. 2, pp. 333–338, 1976.

- [7] Jinliang Chen, Shaozhong Kang, Taisheng Du, Ping Guo, Rangjian Qiu, Renqiang Chen, and Feng Gu. Modeling relations of tomato yield and fruit quality with water deficit at different growth stages under greenhouse condition. *Agricultural water management*, Vol. 146, pp. 131–148, 2014.
- [8] 久枝和昇, 仁科弘重. 大規模トマト生産温室における生産性向上に関する研究. *植物環境工学*, Vol. 19, No. 1, pp. 11–18, 2007.
- [9] Kefaya Qaddoum, EL Hines, and DD Iliescu. Yield prediction for tomato greenhouse using efunn. *ISRN Artificial Intelligence*, Vol. 2013, , 2013.
- [10] Kamyar Movagharnejad and Maryam Nikzad. Modeling of tomato drying using artificial neural network. *Computers and electronics in agriculture*, Vol. 59, No. 1, pp. 78–85, 2007.
- [11] 岩元睦夫. 近赤外分光法による食品成分の非破壊測定. *日本食品工業学会誌*, Vol. 27, No. 9, pp. 464–472, 1980.
- [12] 夏賀元康, 川村周三, 伊藤和彦. 近赤外分光法による穀物成分測定の精度 (第 1 報) 北海道産小麦の水分, タンパク質, 灰分について. *農業機械学会誌*, Vol. 54, No. 1, pp. 89–96, 1992.
- [13] 伊藤秀和. 近赤外分光法によるメロン品質の非破壊計測法の開発. *野菜茶業研究所研究報告*, Vol. 6, pp. 83–115, 2007.
- [14] 山田久也, 田中伸明, 高田咲子. イチゴ非破壊品質測定装置の実用化. *照明学会誌*, Vol. 93, No. 5, pp. 273–277, 2009.
- [15] 伊藤秀和, 森本進. トマトに含まれるリコペンの可視・近赤外分光法を用いる非破壊計測の可能性について. *照明学会誌*, Vol. 93, No. 8A, pp. 510–513, 2009.
- [16] Honglak Lee, Roger Grosse, Rajesh Ranganath, and Andrew Y Ng. Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations. In *Proceedings of the 26th annual international conference on machine learning*, pp. 609–616. ACM, 2009.
- [17] Tensorflow. <https://www.tensorflow.org/>.
- [18] Tijmen Tieleman and Geoffrey Hinton. Lecture 6.5-rmsprop: Divide the gradient by a running average of its recent magnitude. *COURSERA: Neural networks for machine learning*, Vol. 4, No. 2, 2012.