

2024 年度 卒業論文

論文題目

大学内における無線 LAN 接続数を用いた
大学食堂の利用者数の予測

指導教員

舟橋 健司 准教授

伊藤 宏隆 助教

名古屋工業大学 工学部 情報工学科

2020 年度入学 32114061 番

名前 小塩 希槻

目次

第1章 はじめに	1
第2章 背景知識	3
2.1 RNN	3
2.2 勾配消失問題	3
2.3 LSTM	4
2.3.1 忘却ゲート	4
2.3.2 入力ゲート	4
2.3.3 出力ゲート	4
2.4 RNN Encoder-Decoder	5
2.5 Attention 機構	5
2.6 DA-RNN	5
2.6.1 第1段階の Attention 機構	5
2.6.2 第2段階の Attention 機構	6
第3章 データの詳細	8
3.1 大学会館1階食堂の無線LAN接続数	8
3.2 大学内の無線LAN接続数	9
3.3 データの処理	10
第4章 DA-RNN を用いた利用予測	11
4.1 DA-RNN のハイパーパラメータの定義	11
4.2 評価方法	11
4.3 予測方法	12
4.4 予測結果	12
4.5 考察	15
第5章 むすび	18
謝辞	19
参考文献	20

第1章 はじめに

近年、情報通信技術やハードウェアの発展により、大規模なデータ群であるビッグデータが保存されている。これらを活用して、データから潜在的に有意義なパターンや関係性を抽出する手法をデータマイニング [1] と呼ぶ。データマイニングは様々な分野で活用されており、紙おむつとビールはセットで購入されやすいという関係性を発見 [2] したり、クレジットカードの不正利用の検知 [3]、製造業やインフラ整備における工場設備の異常検知 [4]、などの事例がある。

また、従来のデータマイニングでは、統計学や確率論を利用してデータ分析を行う統計分析が主な手法であり、先に述べた事例もこの手法を用いている。しかし、近年ではデータマイニングで機械学習が使われることが増えている。前者は、仮説を立てた後、分析手法を選択した上で考察を行うことを自らの手で行う必要があるが、後者はその必要がなく、人間では見落としがちな特徴や傾向を見つけることも可能である。機械学習を用いたデータマイニングの手法の一つとして、人間の脳神経のメカニズムを人工的に再現した機械学習手法である、ニューラルネットワークが挙げられる。ニューラルネットワークは入力層・隠れ層・出力層の3つの層から構成されており、入力層では入力されたデータを受け取り、隠れ層ではデータの特徴を定量的な数値で表した特徴量と呼ばれる値を抽出し、出力層では特徴量をもとに予測結果を出力する。隠れ層は複数階層構成することが可能で、そのように構成されたニューラルネットワークを特に DNN (Deep Neural Network) と呼ぶ。これによって非線形性を持つ計算が実現でき、画像・音声・自然言語処理分野で活用されている。また、これを用いて時間の経過とともに連続的に観測されるデータ系列である時系列データを分析することも可能である。

ところで、多くの大学の食堂は、時間帯によって利用者が集中する。その主な要因は、学部生によるものであると考えられる。学部生は大学を卒業するための単位

を取得するために大学を訪れる必要があり、昼食休憩を挟んで講義を受講する人も多い。そのため、昼食休憩時に食堂が混雑する場合が多い。しかし、大学では、各学生で時間割が異なり、中学校や高等学校に比べて休講や補講が多いため、それによって大学を訪れない人が出てくる場合もある。そのような場合、食堂利用者は減少し、食堂が混雑しない可能性がある。また、学部卒業研究生や大学院生は、講義の受講よりも自身の研究に時間を充てることが多く、各自の都合で行動が異なるため、日によって食堂利用者数は不規則である。これらの理由のため、食堂の混雑度を把握することは難しい。

先行研究として、過去に iBeacon を用いた食堂の混雑度把握システムの検討 [5] や、新型コロナウイルス感染症予防を目的とした、無線 LAN を用いた混雑度把握システムが提案されている [6][7]。しかし、これらの研究はリアルタイムでの混雑度把握が目的であり、将来の混雑度を知ることはできないという課題があった。そこで、事前に食堂内の人数を予測することで、予め混雑度を把握したいと考えた。

本研究では、過去の学内全体の無線 LAN 接続数のデータと食堂内の無線 LAN 接続数のデータを利用し、後述する DA-RNN という手法を用いて人数予測を行った。名古屋工業大学における無線 LAN は MAINS-X という無線 LAN アクセスポイントで統一されており、利用者は名工大 ID と呼ばれる、学内で使用される個人識別子を用いて MAINS-X に接続する。そのため、一台数に加えて重複接続を除いた実際の人数の容易であり、リアルタイムでの計測も可能である。これを利用することで、計測時点で学内にいる人数の概数を推定し、それに伴う食堂の利用者数を予測する。

本文では、第2章で本研究で用いた予測手法を、第3章では使用したデータの詳細を、第4章では予測結果及び考察について、第5章では予測結果と今後の課題について述べる。

第2章 背景知識

本研究で使用する手法を説明するにあたり、機械学習に関連する知識について述べる。

2.1 RNN

RNN (Recurrent Neural Network) [8] とは、過去の情報を利用して現在・将来の入力に対する精度を向上させるニューラルネットワークである。RNN は入力層・1 層の隠れ層・出力層の 3 層で構成されている。時系列データのある時刻のデータを入力し、そのデータに対して隠れ層で得られる演算結果を出力層に送ると同時に、その演算結果を隠れ層自身に入力を行い、それ以降のデータに対しても同様の処理を行う。これによって、隠れ層が 1 層のみにも関わらず、見かけ上複数の隠れ層で構成されたニューラルネットワークとなり、過去の入力内容が再帰的に利用されている。そのため、現在・将来の予測値の出力に過去の入力が影響を与えることが可能になり、柔軟な出力が可能となる。

2.2 勾配消失問題

ニューラルネットワークは学習を行う際、予測値と実測値の誤差を減らすために、誤差逆伝播法と呼ばれる方法を用いてパラメータの変更を繰り返す。誤差逆伝播法は誤差関数の勾配を計算し、その勾配に基づきパラメータを更新することで学習が進められる。隠れ層が多くなるほど勾配が徐々に小さくなり、ニューラルネットワークの下層でのパラメータが更新されにくくなることで学習が停滞する、勾配消失問題が発生する。RNN においてもこの問題に直面し、過去の入力を学習できなくなる。

2.3 LSTM

LSTM (Long Short Term Memory) [9] とは、RNNにおける隠れ層を LSTM Block と呼ばれる層に置き換えたニューラルネットワークである。LSTM Block では忘却ゲート・入力ゲート・出力ゲートの3つで構成されており、これにより勾配消失問題に対応することが可能である。

2.3.1 忘却ゲート

忘却ゲートは、入力された情報を元にして、保存されている過去の情報をどれだけ忘れるか決定する機構である。その忘れ度合いを0から1の数値で表し、0では過去の情報を完全に忘却する、1では過去の情報をそのまま利用するとして定義すると、過去の情報の忘れ度合いを数値で表すことが可能になる。その数値を出力する関数を、式 2.1 で表されるシグモイド関数で定義する。

$$\sigma = \frac{1}{1 + e^{-x}} \quad (2.1)$$

2.3.2 入力ゲート

入力ゲートは、入力された情報の取捨選択を行い、必要な情報を決定する機構である。情報の重要度は0から1の数値で表し、数値が大きくなるにつれて重要度が増すように定義する。その数値の出力は忘却ゲートと同様にシグモイド関数で定義する。

2.3.3 出力ゲート

出力ゲートは、最終的に出力される情報を決定する機構である。忘却ゲート・入力ゲートで決定された情報の重要度に応じたパラメータの重み付けを行い、情報を出力する。このゲートで行われる重み付けにも他のゲート同様にシグモイド関数で定義する。

2.4 RNN Encoder-Decoder

RNN Encoder-Decoder[10] は、エンコーダ、デコーダと呼ばれる2種類のRNNを使用する手法であり、入力・出力ともに時系列にしたい場合に有用である。エンコーダは入力データに対して符号化処理を行い、入力データよりも短い固定長のベクトルに変換する機構である。情報をベクトルに圧縮する際、入力した情報から不要な部分を消去する。デコーダはそのベクトルを復号化する機構であり、エンコーダにより入力した情報から余分な要素が排除されているため、本質的な部分を抽出することが可能である。

2.5 Attention 機構

Attention 機構は、時系列入力に対して、関連度の高い過去の情報に焦点を当てる機構[11]である。RNN Encoder-Decoder では、時系列情報はエンコーダによって1つの固定長ベクトルに圧縮される。入力する情報ごとに重視する過去の情報は異なるため、入力によって動的に変更可能なベクトルを導入する。

2.6 DA-RNN

DA-RNN (Dual-stage Attention-based RNN) [12] は、2段階の Attention 機構を組み込んだRNNモデルである。また、このモデルで使用されているエンコーダ・デコーダはLSTMで構成されている。

2.6.1 第1段階の Attention 機構

第1段階の Attention 機構は入力情報に注意した機構であり、その構造を図2.1に示す。ある時刻 t において、外生変数ベクトル x を直前の時刻 $t-1$ の隠れ層 h_{t-1} に入力することでベクトル e_t が得られる。その後、ベクトル e_t の各要素の和を1にするため、以下の式2.2で定義されるソフトマックス関数を利用する。ただし、 k はベクトル e の通し番号、 n はベクトル e の要素数とする。

$$\alpha_t^k = \frac{\exp(e_t^k)}{\sum_{i=1}^n \exp(e_t^i)} \quad (2.2)$$

これによって、各外生変数が影響を与える度合いを表すベクトル α が出力され、これを外生変数ベクトル x とかけ合わせることで、補正された外生変数ベクトル $\tilde{x}_t$ が出力される。

2.6.2 第2段階の Attention 機構

第2段階の Attention 機構は時系列情報に注意した機構であり、その構造を図 2.2 に示す。RNN Encoder-Decoder は入力するシーケンス長が長いほどパフォーマンスが低下する事が分かっている。ここで、時刻 T の予測値 $\hat{y}_T$ を求める時、ある時刻 t ($t < T$) について、第1段階の Attention 機構で得られたベクトル $\tilde{x}_T$ をエンコーダに入力する。このとき、時刻 t のエンコーダは時刻 $t-1$ までで得られたエンコーダの隠れ層 h_{t-1} も入力の対象となっている。得られた値を時刻 $T-1$ のデコーダの隠れ層 d_{t-1} に入力することで、ベクトル l_T が得られる。その後、ベクトル l_T の各要素の和を1にするため、式 2.2 の e_t^k を l_T^k 、 α_t^k を β_T^k と置き換えて同様に計算していく。これによって得られたベクトル β_T を利用し、エンコーダの隠れ層ベクトル h_T とかけ合わせると、ベクトル c_{T-1} が得られる。そして、ベクトル c_{T-1} と目的変数 y_{T-1} をデコーダの隠れ層 d_{T-1} に入力することで、予測値 $\hat{y}_T$ が得られる。




図 2.1: 第1段階の Attention 機構の構造 ([12] から引用)




図 2.2: 第2段階の Attention 機構の構造 ([12] から引用)

第3章 データの詳細

本研究で使用するデータの内容について述べる。

3.1 大学会館1階食堂の無線LAN接続数

今回の研究で予測する目的変数である。本学の大学会館1階食堂には4台の無線LANアクセスポイントが存在しており、それぞれで得られた接続数の合計値を使用する。対象期間は2023年度前期4月1日から7月31日、2023年度後期10月1日から1月31日、2024年度前期の4月1日から7月31日、2024年後期の10月1日から12月23日の内、土曜日と日曜日を除外した計322日分である。また、各日の食堂の営業時間である11時00分から14時00分までの時間帯で、10分ごとに接続数を計測しているため、1日あたり19個のデータが用意されている。そのため、総計で6118個のデータを使用した。

ここで、サンプルデータとして2024年11月1日、4日、5日の接続数の推移を図3.1に示す。1日は平日であるが休講日、4日は祝日であり、5日は平日であり講義は通常通り行われている。この推移図の5日の接続数の推移の仕方を見ると、11時00分から11時30分の間では緩やかに増加しているが、11時30分から12時00分の間では急激に増加している。その後、12時00分から12時30分の間に接続数はピークを迎え、12時30分から13時00分の間では急激に減少し、それ以降の間では緩やかに減少している。1日の接続数でも同様の推移が見られるが、5日と比較すると、接続数の増減具合やピーク時の接続数は控えめであることが分かる。また、4日は祝日であるため食堂は営業しておらず、接続数は0に近い推移が続いている。




図 3.1: 2024 年 11 月 1 日、4 日、5 日の大学会館 1 階の無線 LAN 接続数推移

3.2 大学内の無線 LAN 接続数

今回の研究で食堂無線 LAN 接続数を予測するために使用される説明変数である。現在、学内には 707 台の無線 LAN アクセスポイントが設置されており、それぞれのアクセスポイントで得られた接続数の合計値を使用する。3.1 節で述べたデータと同様の日付のデータを利用しているため、こちらのデータも計 322 日分のデータを利用した。ただし、接続数を予測するにあたり、予測したい時刻の 1 時間前の学内無線 LAN 接続数を利用している。つまり、各日 10 時 00 分から 13 時 00 分までの時間帯で、10 分おきに計測を行っており、こちらも 1 日あたり 19 個のデータが用意されている。そのため、こちらも総計で 6118 個のデータを使用した。

ここで、サンプルデータとして図 3.1 と同様に、2024 年 11 月 1 日、4 日、5 日の接続数の推移を図 3.2 に示す。5 日における接続数の推移は、10 時 00 分から 11 時 00 分の間で増加しており、11 時 00 分から 12 時 00 分の間ではほぼ横ばいとなる。その後、12 時 00 分から 12 時 30 分にかけてわずかな減少が見られるが、それ以降の時間で緩やかに増加している。1 日の接続数は 5 日と比べると少なくなっており、5 日と同様に 10 時 00 分から 11 時 00 分の間で増加しており、それ以降の時間は、10 分ごとに見るとほぼ横ばいとなっているが、11 時 00 分から 13 時 00 分の長期的な推移として見ると、わずかに増加している。また、4 日は祝日のため、1 日や 5 日の接続数




図 3.2: 2024 年 11 月 1 日、4 日、5 日の大学内の無線 LAN 接続数推移

よりも少なく、11 時 00 分から 14 時 00 分の長期的な推移で見てもわずかな増加しか見られない。

3.3 データの処理

無線 LAN では同一人物が複数のデバイスを所有し、それぞれのデバイスが無線 LAN に接続されている場合がある。そのため、接続数と実際に無線 LAN を使用している人数は異なる。しかし、第 1 章で述べたように、MAINS-X では名工大 ID で接続者の管理を行っているため、各デバイスにおける接続主を知ることが可能である。これにより、重複を除外することが可能であるため、デバイスの接続主が重複する場合は接続数のカウントから除外した。また、計測に不測の事態が起こった場合、そのときのデータは欠損値となる。今回用意したデータの一部にも欠損値が生じており、それらのデータは補間した。

第4章 DA-RNNを用いた利用予測

第2章で述べたDA-RNNを用いて、第3章で述べたデータをもとに、食堂の無線LAN接続数を予測する。

4.1 DA-RNNのハイパーパラメータの定義

ハイパーパラメータとは、学習前に設定するパラメータである。本研究におけるハイパーパラメータは表4.1の通りとなる。

表 4.1: 使用したハイパーパラメータとその値

ハイパーパラメータ	値
隠れ層の数	64
バッチサイズ	32
エポック数	100
学習率	0.01
シーケンス長	19

4.2 評価方法

学習モデルの評価方法にはMAEとRMSEの2つの評価指標を使用する。それぞれの指標は以下の式で定義される。ただし、 y は実測値、 $\hat{y}$ は予測値、 n はデータの総数とする。

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4.1)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4.2)$$

MAE (Mean Absolute Error) とは平均絶対値誤差のことであり、実測値と予測値の差の絶対値の平均化した値である。この値はデータ全体としての誤差を平等に評価する指標である。また、RMSE (Root Mean Squared Error) とは二乗平均平方根誤差のことであり、実測値と予測値の差の二乗の和を平均化した後、平方根を求めた値である。この値は、実測値と予測値の差が大きい外れ値があると値が大きくなる傾向がある。いずれの指標も実測値と予測値の誤差に関する指標のため、小さいほど学習モデルの精度が良いと評価できる。

4.3 予測方法

食堂内接続数を予測するにあたって、予測日前日の学内接続数と食堂内接続数、予測日の学内接続数を使用し、前準備として、予測日前日の学内接続数を格納したリスト A、予測日前日の食堂内接続数を格納したリスト B をそれぞれ作成する。まず、11 時 00 分の値を予測したい場合、リスト A の末尾に 10 時 00 分の学内接続数を追加し、ダミー変数として 0 をリスト B の末尾に追加する。これらを事前に用意した学習モデルに入力すると、予測値が出力され、リスト B の末尾に格納されたダミー変数 0 をこの予測値に置き換える。次に、11 時 10 時の予測値を取得したい場合、古い情報を除外するため、リスト A、B の先頭の値を削除する。その後、リスト A の末尾に 10 時 10 分の学内接続数を追加し、ダミー変数 0 をリスト B の末尾に追加し、学習モデルにこれらのリストを入力すると予測値が得られ、同様にダミー変数を予測値に置き換える。11 時 10 分以降の予測値取得にはリスト A、B からリストの先頭の値を削除することに注意しながら同様の処理を行うと、現在時刻の 1 時間後の食堂内接続数の予測値が得られる。

4.4 予測結果

学習データを 2023 年度前期及び後期と 2024 年度前期の学内接続数と食堂内接続数、テストデータを 2024 年度後期の学内接続数・食堂内接続数としてデータを分割し、予測を行った。テストデータを 2024 年度後期の接続数として利用して検証した結果を図 4.1、表 4.2 に示す。また、予測値の推移図は 1 日の途中でであっても出力可

能であり、これによってリアルタイムで1時間後までの予測を見ることが可能である。サンプルとして2024年12月11日の11時、12時、13時に予測推移図を図4.2、図4.3、図4.4に示す。本来なら予測時点では1時間後までの実績値は判明していないが、検証は過去のデータで行なっているため、実測値を付加している。




図 4.1: テストデータに対する実測値・予測値のプロット図

表 4.2: 学習結果

MAE	35.000
RMSE	46.997




図 4.2: 2024 年 12 月 11 日の 11 時時点で得られる予測値と実測値の推移図




図 4.3: 2024 年 12 月 11 日の 12 時時点で得られる予測値と実測値の推移図




図 4.4: 2024 年 12 月 11 日の 13 時時点で得られる予測値と実測値の推移図

4.5 考察

図 4.1 を見ると、休講がなく講義が授業日程予定の通りに行われている日 (以下、通常日と呼ぶ) と、通常日と比べて接続数の増減及びピーク時の接続数が控えめな休講日で予測値の推移が異なり、ピーク時の食堂接続数の最大値も異なる。学内接続数によってこれらの日の区別がつけられており、それぞれの日に応じた予測値の出力に対応できていることが分かる。また、テストデータには祝日が混在しており、図 4.1 における 10 日目と 25 日目に該当する。これらの日は食堂は営業していないため、実測値は 0 に近い推移が続く傾向があり、予測においても同様の推移が見られ、こちら学内接続数によって柔軟な出力ができていることが分かる。その要因は、DA-RNN における説明変数で用いた学内接続数に関する影響と時系列の流れに関する影響の学習ができているからだと思われる。通常日、休講日、祝日のそれぞれの場合において学内接続数の範囲が異なり、通常日では 1511 から 4014 の範囲、休講日では 259 から 2202 の範囲、祝日では 271 から 807 の範囲である。休講日は通常日に比べて食堂内接続数の増減具合やピーク時の食堂内接続数が控えめになり、祝日は 0 に近い食堂内接続数を維持することから、学内接続数が分かれば、食堂内接続

数の増減具合やピーク時の食堂内接続数を予測することがある程度可能である。また、休講日であっても、学内接続数が通常日と大差ない場合があり、例えば学内接続数が2000である場合が該当する。しかし、1日の流れにおける学内接続数を考慮すると、時間が経過するほど学内接続数が増加していく傾向にあるため、この場合、学内接続数の測定時刻を参照することによって食堂内接続数の予測値を予測することが可能になる。これらが要因となり、通常日、休講日、祝日のそれぞれに合わせた予測値が出力されたと思われる。

また、図4.1の9日目のように、13時頃に食堂内接続数がわずかに上昇する場合がある。これは、研究室所属生がピーク時の混雑を回避するべく、お昼休憩が終わり講義が再開する13時頃は混雑しないだろう、と考える人が多くなり、そういった人たちによる利用が一時的に集中するからだと思われる。この時間帯の予測をする際、学内接続数は12時頃の接続数を利用するが、学内接続数の推移傾向によると12時頃から学内接続数はわずかに減少するため、学内接続数の影響を受けた予測値とは考えにくい。また、この現象が発生することで一時的な接続数の増加具合が大きくなるほど、ピーク時の予測値が小さくなる傾向がある。

今回の結果における課題として、休講日における予測値の推移は実測値の推移と比べてかなり乖離したものとなる現象が発生する。これは休講日における利用者の性質が要因と思われ、通常日は講義の開催時間に沿って行動する利用者が多く、通常日の学内接続数はどの日も概ね同じ推移を辿っているため、通常日の学内接続数にもその傾向が見られる。しかし、休講日は講義の開催時間に左右されず各々のタイミングで行動ができるため、日によって学内接続数の推移にばらつきが見られ、それに対応できなかったからだと思われる。また、通常日におけるピーク時の食堂接続数が実測値よりも下回る場合が多い。これは学習モデルの構築方法に問題があると考えられ、ハイパーパラメータを適宜変更することで予測精度が上がると期待できる。1日を通した食堂の利用人数の合計は予測できているが、利用時刻は個人によって異なるだろう。図4.2から図4.4の場合、11時台の食堂利用者がいつもより少なければ13時台は食堂利用者がいつもより多くなりそうだと想像できる。少なかった場合、13時台は食堂利用者が多くなるだろう、と考えることができる。そのため、説明変数として予測値の測定時刻までの実測値を加えることで、予測精度が

上がる可能性があると思われる。

第5章 むすび

本研究では DA-RNN を利用して、大学内における無線 LAN 接続数を用いて大学食堂の利用者数の予測を行った。結果として、講義の有無や祝日の影響に関わらず、食堂内の無線 LAN 接続数の予測値は実際の食堂内の無線 LAN 接続数に近づくことができた。今後の課題としては、講義がある日のピーク時の接続数をより実測値に近づける予測を行う学習モデルの構築を行う。また、得られた予測値を利用して、食堂利用者が閲覧可能な web アプリケーションを開発したい。

謝辞

本研究において日頃からご指導頂いた名古屋工業大学 舟橋健司 准教授、伊藤宏隆 助教に心から感謝致します。また、本研究を進めるにあたり多大なご協力をいただきました舟橋研究室の皆様に深く感謝いたします。

参考文献

- [1] Ming-Syan, C., Jiawei, H., Yu, P.S.: “Data mining : an overview from a database perspective. ”, IEEE Transactions on Knowledge and Data Engineering, Vol 8, pp. 866-883, 1996
- [2] Wilke, J. R. Retailing: “ Supercomputers manage holiday stock ”, Wall Street Journal, p. B1. 1992
- [3] Alwan Raghad H., Hamad Murtadha M.,Dawood Omar A.: “ A comprehensive survey of fraud detection methods in credit card based on data mining techniques ”, AIP Conference Proceedings, Vol. 2400, No. 1, p. 20006, 2022
- [4] 鈴木英明, 内山宏樹, 湯田晋也: “ データマイニングによる異常検知技術 ”, オペレーションズ・リサーチ誌 57 巻 9 号, pp. 1-8, 2012
- [5] 土井崇史: “ 大学食堂における iBeacon を用いた混雑度把握システムの検討 ”, 2016 年度名古屋工業大学卒業論文
- [6] 富重秀樹, 井上純一, 畑瀬卓司, 和田数字郎, 林豊洋, 福田豊: “ 無線 LAN 接続情報を利用した密集度表示システムとその改良 ”, 学術情報処理研究 25 巻 1 号, pp. 1-8, 2021
- [7] 小林裕太郎, 橋本啓吾, 谷口義明, 越智洋司, 井口信和: “ 大学キャンパス内混雑度モニタリングシステムの実装と評価 ”, 2021 年度情報処理学会関西支部支部大会講演論文集, 2021
- [8] Williams, Ronald J.; Hinton, Geoffrey E.; Rumelhart, David E.: “ Learning representations by back-propagating errors ”, Nature, Vol. 323, No. 6088, pp. 533-536, 1986

- [9] S. Hochreiter, J. Schmidhuber: “Long short-term memory”, *Neural Computation* Vol. 9, No. 8, pp. 1735–1780, 1997
- [10] Kyunghyun Cho, Bart Van Merriënboer, Dzmitry Bahdanau, Yoshua Bengio.: “On the properties of neural machine translation: Encoder-decoder approaches.”, *arXiv:1409.1259*, 2014.
- [11] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Lukasz Kaiser, Illia Polosukhin: “Attention Is All You Need”, *Advances in Neural Information Processing Systems*, Vol. 30, 2017
- [12] Qin, Y., Song, D., Cheng, H., Cheng, W., Jiang, G., Cottrell, G. W.: “A dual-stage attention-based recurrent neural network for time series prediction”, *International Joint Conference on Artificial Intelligence*, pp. 2627–2633, 2017