

LSTNet に基づく注目区間情報を強調する多変量時系列予測 Target spotting Multiple time series prediction based on LSTNet

佐野 隼乙[†] 六井 淳[‡]
Hayato Sano Jun Rokui

1 まえがき

時系列データ予測は、データの過去情報を分析し、含まれる傾向や特徴を捉えて未来の値を予測するものであり、一変量か多変量かに関わらず盛んに研究が行われてきた。Siami-Namini らの研究 [1] では、金融指標の時系列データ予測において、Neural Network モデルが従来手法である ARIMA モデル [2] に比べ優れた結果であったと報告している。中挾らによる研究 [3] では、Neural Network モデルで列車の乗車率、遅延の予測を行い、予測対象の前後の列車情報を学習に用いると予測精度が向上する場合があると報告している。

また、多変量時系列データを利用する手法として、安達らの研究 [4] や Guokun Lai らの研究 [5] が高い成果を挙げている。安達らは、重回帰分析を用いて多変量時系列データを単変量に集約するフレームワークの研究を行い、単変量を入力とする従来手法より優れた予測精度を実験的に確認した。Guokun Lai らは、多変量時系列データに対し Convolutional Neural Network (CNN) [6] を適用し単変量に変換して予測を行う。Long and Short term Time series Network (LSTNet) [5] を提案し、長期及び短期のパターンが混在しているデータに対しても優れた予測精度を示した。

LSTNet は、CNN と Recurrent Neural Network (RNN) [7] の一種である Gated Recurrent Unit (GRU) [8] を組み合わせたモデルであり、GRU は過去の情報を均一に参照して予測を行う。Zhang らの研究 [9] や Oiu らによる研究 [10] では、過去の情報を評価し参照する Attention 機構を RNN に適用することで、従来手法と比較して高い成果が報告されている。LSTNet に基づく時系列予測の研究 [11] では、LSTNet に Attention 機構を適用した Attention-LSTNet (ALSTNet) と LSTNet を長期予測モデルに改良した Multiple Autoregressive LSTNet (MALSTNet) を提案し、優れた予測精度を示した。また、Attention 機構を適用する過去情報区間の最適な長さについては検証実験が必要であると報告している。その為、本研究では、LSTNet の長期予測モデルである MALSTNet に対して、特定の区間ごとに中央値を算出し、作成した Attention データを入力に用いて予測を行う Attention MALSTNet (AMALSTNet) を提案する。また、Attention の適切な区間の長さについて、Attention を適用する区間を変化させて、予測精度を比較する検証実験を行う。

2 LSTNet

LSTNet は、Convolution 層、Recurrent 層、Output 層の 3 層からなる多変量時系列予測のモデルである。LSTNet の概念図を図 1 に示す。

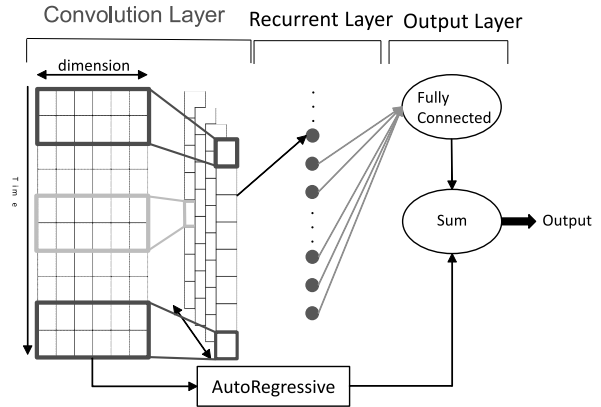


図 1 LSTNet の概念図

2.1 Convolution 層

Convolution 層では、時間次元の短期パターンと変数間のローカル依存関係の抽出を目的として、入力された 2 次元データの部分的な特徴抽出を行う。入力データを $m \times n$ の多変量データ X (式 (1)) とすると、 X に対して、畳み込みを行い特徴マップを出力する $\omega \times d$ のフィルタを D (式 (2)) とおくと生成される特徴マップ F は式 (3) として定義される。

$$X = \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{m1} & x_{m2} & \dots & x_{mn} \end{pmatrix} \quad (1)$$

$$K = \begin{pmatrix} w_{11} & \dots & w_{1d} \\ \vdots & \ddots & \vdots \\ w_{\omega 1} & \dots & w_{\omega d} \end{pmatrix} \quad (2)$$

$$F = \begin{pmatrix} f_{11} & f_{12} & \dots & f_{1q} \\ f_{21} & f_{22} & \dots & f_{2q} \\ \vdots & \vdots & \ddots & \vdots \\ f_{p1} & f_{p2} & \dots & f_{pq} \end{pmatrix} \quad (3)$$

$$p = m - \omega + 1 \quad (4)$$

$$q = n - d + 1 \quad (5)$$

$$f_{jk} = \sum_{s=0}^{\omega-1} \sum_{l=0}^{d-1} X(j+s)(k+l) * w_{jl} \quad (6)$$

LSTNet モデルでは入力された多変量データ X の変数の数 n とフィルタサイズの d は同じになるように設定される。Convolution 層の出力を hc とする。 e 番目のフィルタの出力 hc_e は各フィルタを K_e とすると式 (7) で表すことができる。

$$hc_e = \text{RELU}(K_e * X + b_e) \quad (7)$$

ここで、 $*$ は畳み込み演算、 b はバイアスベクトルを示し、RELU 関数は $\text{RELU}(x) = \max(0, x)$ である。入力データ X に対し、ゼロパディング (zero padding) を行

[†] 静岡県立大学大学院経営情報イノベーション研究科, Graduate School of Management and Information of Innovation, University of Shizuoka

うことにより, 長さ T の各ベクトル hc_e を生成する. 畳み込み層の出力行列のサイズはフィルタ数を o とすると $o \times T$ で表される.

2.2 Recurrent 層

LSTNet の Recurrent 層では RELU 関数を活性化関数とした GRU が用いられる. GRU のモデル図を図 2 に示す. また, 時刻 t の入力層における値を x_t , 時刻 $t-1$ の隠れ層の値を h_{t-1} , リセットゲートの値を r_t , 更新ゲートの値を u_t とおくと, リセットゲートと更新ゲートの値はそれぞれ式 (8), 式 (9) で求められる.

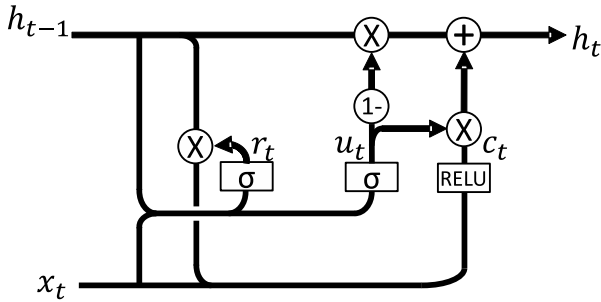


図 2 GRU の内部構造

$$r_t = \sigma(x_t W_{xr} + h_{t-1} W_{hr} + b_r) \quad (8)$$

$$u_t = \sigma(x_t W_{xu} + h_{t-1} W_{hu} + b_u) \quad (9)$$

ここで, σ はシグモイド関数, W は重み行列, b はバイアスベクトルを表す. リセットゲートの値 r_t は, 時刻 $t-1$ での隠れ層の値と掛け合わされ, 入力 x_t とともに活性化関数の RELU 関数で活性化される. 活性化後の値を c_t とおくと, c_t は式 (10) で表される.

$$c_t = \text{RELU}(x_t W_{xc} + r_t \odot (h_{t-1} W_{hc}) + b_c) \quad (10)$$

\odot は要素ごとの積を表す. 更新ゲートの値は, $1 - u_t$ と u_t に分かれ, それぞれ h_{t-1} と c_t に掛け合わされる. よって, 最終的な GRU の隠れ層の出力 h_t は式 (11) で求められる.

$$h_t = (1 - u_t) \odot h_{t-1} + u_t \odot c_t \quad (11)$$

2.3 Output 層

Output 層では, Recurrent 層の出力と Autoregressive (AR) 層の出力の和を最終出力とする. Recurrent 層の出力に AR 層の出力を合わせることで, スケール変化の大きいデータにも敏感に予測を行うことが可能となる. AR 層で用いられる変数を上付き添え字 ar を用いて表し, 重み行列を W^{ar} , バイアスベクトルを b^{ar} , 入力データを x^{ar} とすると, 時刻 t における AR 層の出力 h_t^{ar} は式 (12) で求められる.

$$h_t^{ar} = \sum_{s=0}^{q^{ar}-1} W_s^{ar} x_{t-s}^{ar} + b^{ar} \quad (12)$$

ここで, q^{ar} は入力行列のウィンドウサイズを表す. よって, 式 (11) と式 (12) から LSTNet の最終出力 H_t は, 式 (13) で表される.

$$H_t = h_t + h_t^{ar} \quad (13)$$

3 提案手法

先行研究 [5][9][10][11] では, 過去の情報を評価し参照する Attention 機構を RNN に適用することで, 従来手法より優れた予測精度を示した. その為, 全ての過去情報が均一に予測に影響を与えている可能性は低く, 特定の過去区間情報を強調することで予測精度の向上が期待できる. 本研究では, LSTNet の AR 層を多変量に改良した Multiple Autoregressive LSTNet (MALSTNet)[11] に Attention 機構を適用した Attention Multiple Autoregressive LSTNet (AMALSTNet) を提案する. AMALSTNet 手法の全体像を図 3 に示す.

本手法は Preprocessing, Attention MALSTNet (AMALSTNet), Forecasting, Comparison に分けられる. Preprocessing は, 入力データの正規化, 切り出し, テストデータの作成などデータの前処理を行う. AMALSTNet では, 各時系列データに対して特定の区間ごと中央値を算出し, 特定の過去情報区間を強調する Attention データを作成する. 中央値を用いることで, 時系列データの実値に基づき Attention データが作成される. その為, 学習において不要なデータが用いられる可能性は低い. Attention データは MALSTNet に入力され, 単変量の予測モデルを作成する. Forecasting では, 単変量の予測モデルを組合せて多変量時系列予測を行う. Comparison では, 予測値と実測値を比較し, 精度を検証する.




図 3 AMALSTNet の全体像

3.1 Preprocessing

本研究では, 多変量時系列データを用いる. 入力データを X (式 (1)) とすると, m は時系列の長さ, n は時系列データの系列数を表す. X は, 各時系列の最大値で除して $[0, 1]$ の範囲に正規化し, 学習データを 8 割, テストデータを 2 割として切り出す. 時系列データの長さ m' より後をテストデータとし, 予測対象の時系列を系列 n' とすると, 学習データ X' とテストデータ Y' はそれぞれ式 (14), 式 (15) となる.

$$X' = \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{m'1} & x_{m'2} & \dots & x_{m'n} \end{pmatrix} \quad (14)$$

$$Y' = \{x_{(m'+1)n'}, x_{(m'+2)n'}, \dots, x_{mn'}\} \quad (15)$$

3.2 Attention Multiple Autoregressive LSTNet

AMALSTNet は, Convolution 層, Recurrent 層, Output 層の 3 層からなる MALSTNet に Attention 層を組み合わせた 4 層からなる単変量時系列予測のモデルである. LSTNet より長期予測を行うことが可能である MALSTNet に, 特定の過去情報を強調する Attention 層を組み合わせることで, 予測精度の向上が期待できる. AMALSTNet の概念図を図 4 に示す.

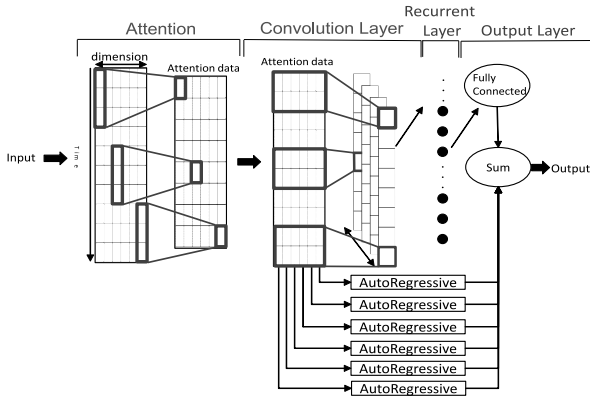


図 4 AMALSTNet の概念図

3.2.1 Attention 層

Attention では, 特定の過去情報区間を強調する手法として, 中央値を用いて入力データの各時系列データから Attention データを作成する. 中央値を用いてデータを集約することで, 予測に必要な過去情報を抽出し学習精度の向上が期待できる. z 個のデータに対して, データを小さい順に並べたものを $\{x_1, x_2, \dots, x_z\}$ とすると, 中央値 M は式 (16) で求まる.

$$M = \begin{cases} x_{(\frac{z+1}{2})} & (z = 2y - 1) \\ \frac{1}{2}(x_{(\frac{z}{2})} + x_{(\frac{z+1}{2})}) & (z = 2y) \end{cases} \quad (16)$$

ここで, y は整数である. 入力されたデータ X' (式 (14)) に対して, 各時系列データごとに中央値を算出する. 中央値を求める区間 (Attention 数) を α とすると, 時系列データ i における時刻 t では, 式 (14) から抽出した式 (17) で表されるデータ U について中央値を求めればよい.

$$U = \{x_{ti}, x_{(t+1)i}, \dots, x_{(t+\alpha-1)i}\} \quad (17)$$

式 (17) の中央値を $M^{(t,t+\alpha-1)}$ とすると, Attention データ A は式 (18) で表せる.

$$A = \begin{pmatrix} M_{11}^{(1,\alpha)} & M_{12}^{(1,\alpha)} & \dots & M_{1n}^{(1,\alpha)} \\ M_{21}^{(2,\alpha+1)} & M_{22}^{(2,\alpha+1)} & \dots & M_{2n}^{(2,\alpha+1)} \\ \vdots & \vdots & \ddots & \vdots \\ M_{(m'+1-\alpha)1}^{(m'+1-\alpha,m')} & M_{(m'+1-\alpha)2}^{(m'+1-\alpha,m')} & \dots & M_{(m'+1-\alpha)n}^{(m'+1-\alpha,m')} \end{pmatrix} \quad (18)$$

ここで, $(t, t + \alpha - 1)$ は時刻 t における中央値を求める時系列の区間を表す.

3.2.2 Convolution 層

Convolution 層では, Attention 層の出力 (式 (18)) を入力として, 畳み込みフィルタ (式 (2)) を用いて特徴マップ F (式 (3)) を生成する. 提案手法では, 入力された Attention データ A の系列数 n と畳み込みフィルタのサイズ d は同じになるように設定される. したがって, 式 (7) より Convolution 層の出力を hc とすると, e 番目のフィルタの出力 hc_e は式 (19) で表すことができる.

$$hc_e = RELU(K_e * A + b_e) \quad (19)$$

ここで, K_e は各フィルタ, A は Attention データ (式 (18)), $*$ は畳み込み演算, b はバイアスベクトルである. RELU 関数は $RELU(x) = \max(0, x)$ であり, Attention データ A に

対し, ゼロパディングを行うことにより, 長さ T の各ベクトル hc_e を生成する. 畳み込み層の出力行列のサイズはフィルタ数を o とすると $o \times T$ で表される.

3.2.3 Recurrent 層

MALSTNet の Recurrent 層では Convolution 層の出力 hc を入力として, RELU 関数を活性化関数とした GRU が用いられる. 同様に, 多変量分に拡張された AR 層では Attention データの各系列データを入力として, RELU 関数を活性化関数とした GRU を用いる. GRU のリセットゲートの値, 更新ゲートの値, 活性化後の値, 及び GRU の出力はそれぞれ式 (8), 式 (9), 式 (10), 式 (11) で表せる. ここで, 入力時系列 v における時刻 t での AR 層の出力を h_t^v とすると, 時刻 t での各 AR 層の出力の総和 h_t^{AR} は式 (20) で求まる.

$$h_t^{AR} = \sum_{v=1}^n h_t^v \quad (20)$$

n は時系列データの数である.

3.2.4 Output 層

Output 層では, Recurrent 層の出力と AR 層の出力の和を最終出力とする. 多変量分の AR 層の出力を合わせることで, 各系列データの情報を個別に長期的に出力まで伝達することが期待されている. その為, LSTNet に比べ長い範囲の予測を行うことが可能となる. 式 (11) と式 (20) より, 最終出力 H' は式 (21) で表される.

$$H'_t = h_t + h_t^{AR} \quad (21)$$

3.3 Forecasting

Forecasting の流れを図 5 に示す.

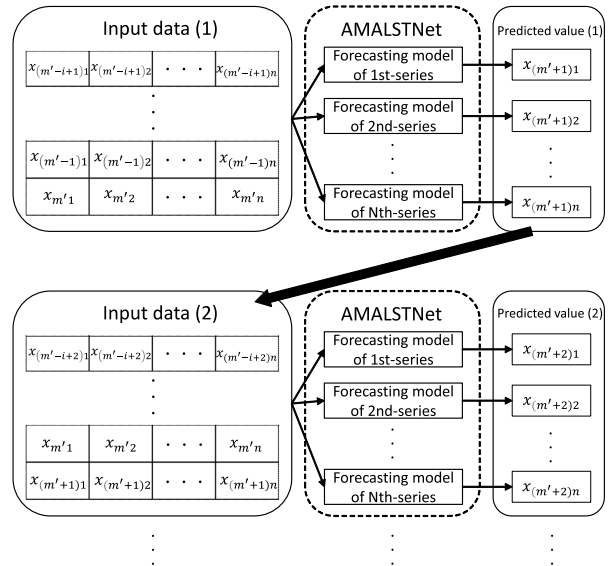


図 5 AMALSTNet による予測

Forecasting では, AMALSTNet で作成した各系列の予測モデルに学習データ X' (式 (14)) の末尾から i 個のデータ (図中: Input data(1)) を入力する. 各予測モデル (図中: AMALSTNet) は, 入力されたデータの各系列の直後の未来の値 (図中: Predicted data(1)) を予測する. 各予測モデルの出力を学習データの末尾に追加し, 再び学習

データの末尾から i 個のデータ (図中:Input data(2)) を入力することで、さらに 1 個先の未来の値 (図中:Predicted data(2)) を予測する。これを繰り返すことで任意の長さの予測を行うことができる。

3.4 Comparison

Comparison では、予測値と実測値を比較して予測精度を検証する。本研究では予測精度の評価指標として、平均 2 乗誤差 (Mean Squared Error, 以下 MSE) を用いた。MSE は、実測値と予測値の差の 2 乗値を計算し、その総和の平均を求めたもので、各 z' 個の予測値を $\hat{Y} = \{\hat{y}_1, \hat{y}_2, \dots, \hat{y}_{z'}\}$, 実際の値を $X = \{x_1, x_2, \dots, x_{z'}\}$ とすると、式 (22) で求まる。また、MSE の値が小さいほど誤差の少ないモデルといえる。

$$MSE = \frac{1}{z'} \sum_{s=1}^{z'} (\hat{y}_s - x_s)^2 \quad (22)$$

4 検証実験

従来手法である LSTNet と既存モデルである Attention LSTNet (ALSTNet) 及び MALSTNet, 更に提案手法の AMALSTNet による MSE 値の比較検証を行う。また, Attention において中央値を求める区間 (Attention 数) を学習データに対して一定の割合で変化させ Attention 数の違いによる実験を行う。実験に使用するデータの概要を表 1 に示す。データは日本銀行 [12], 内閣府 [13], e-Stat[14], 経済産業省 [15], セントルイス連邦準備銀行 [16] 及び YahooFinance[17] から入手した。月次データ, 年次データの詳細はそれぞれ表 2, 表 3 に示す。

時系列データ名	期間	系列数	詳細の表番号
月次データ	1988 年 1 月~2005 年 3 月	26 系列	表 2
年次データ	1973 年~2003 年	15 系列	表 3

表 1 実験データ概要

正式名称	本論文内での略称	出典
企業物価指数	cgpi	日本銀行 [12]
マネタリーベース	mbase	
米ドル円レート	usd_jpy	
輸出物価指数	export_index	内閣府 [13]
輸入物価指数	import_index	
コンボジットインデックス	ci	内閣府 [13]
ディフュージョンインデックス	di	
機械受注額	MO	e-Stat[14]
消費者物価指数	cpi	
総人口	japanese_number	
失業率	situgyou	
労働人口	prole	
実質賃金	tingin	
常時雇用指数	koyou_s	
実労働時間	work_time	
雇用保険基本手当受給資格決定数	kpremium_num	
有効求人倍率	kyuzin	
鉱工業生産付加価値指数	kokogyo	
全産業活動指数	sangyou	
日経平均株価 (終値月平均)	nikkei	セントルイス連邦準備銀行 (FRED)[16]
マネーストック統計 M1	M1	
マネーストック統計 M1	M2	
マネーストック統計 M1	M3	
消費者物価指数 (米国)	cpi_usa	
米国マネーストック統計 M2	M2_usa	
失業率 (米国)	situgyou_usa	

表 2 月次データ一覧

正式名称	本論文内での略称	出典
企業物価指数	cgpi	日本銀行 [12]
公定歩合	official_rate	
金価格	gold	YahooFinance[17]
消費者物価指数	cpi	e-Stat[14]
出生数	b_baby	
発電量	ene	
外貨準備高	exchange	
耕地面積	farm	
通貨流通高	money	
入国外国人数	nyukoku	
自殺者数	suicide	
租税	tax	
輸出入	trade	
輸送指数	trans	
国家予算	yosan	

表 3 年次データ一覧

4.1 月次データ実験

月次データでは, Attention 数を学習データ X' (式 (14)) の 1 割から 9 割まで変化させて検証実験を行った。LSTNet と ALSTNet の結果を表 4 に, MALSTNet と AMALSTNet の結果を表 5 に示す。表において, カッコ内の値は Attention 数を表し, 下線は表内の各系列の MSE 値の最小値, *は表 4 と表 5 の表間での各系列の最小値を表す。月次データの実験では, Attention を用いた ALSTNet 及び AMALSTNet が従来手法と比較し, 多くの系列で予測精度の向上が確認された。また, ALSTNet では Attention 数の増加に伴い精度向上の傾向がみられ, 逆に AMALSTNet では Attention 数の減少に伴い精度が向上した。Attention 数を増加させることで, データ数の削減とデータの振動幅を小さくすることが可能である。その為, 長期予測に適さない LSTNet において, 振動の少ないデータを学習させることで, 予測値の増減幅も少なくなり, Attention 数の少ないデータに比べ, 誤差が小さくなったと考えられる。加えて, Attention 数の大きいデータは, データ数が削減され, 増減傾向を強調したデータとなる。LSTNet は, 入力データに対して, CNN を適用し, 時間次元の特徴抽出を行う。Attention により強調されたデータの特徴が CNN の特徴抽出でさらに強調され, 予測において増減傾向が一致したと考えられる。一方で, MALSTNet は長期予測に適したモデルである。その為, Attention 数の増加による過度な特徴量の削減が学習に寄与しない。少ない Attention 数で予測への影響が低い情報を減らすことで, 予測精度が向上したと考えられる。

4.2 年次データ実験

年次データでは, Attention 数を学習データ X' (式 (14)) の 1 割から 4 割まで変化させて検証実験を行った。LSTNet と ALSTNet の結果を表 6 に, MALSTNet と AMALSTNet の結果を表 7 に示す。表において, カッコ内の値は Attention 数を表し, 下線は表内の各系列の MSE 値の最小値, *は表 6 と表 7 の表間での各系列の最小値を表す。年次データを用いた実験では, ALSTNet 及び, AMALSTNet において従来手法と比較し優れた精度を示した。年次データは短い時系列データであり, Attention 数の増加は深刻な学習データの減少に繋がる。その為, 少ない Attention 数による予測への影響が大

	LSTNet	ALSTNet(3)	1 割 (16)	2 割 (33)	3 割 (49)	4 割 (66)	5 割 (88)	6 割 (99)	7 割 (115)	8 割 (132)	9 割 (149)
cgpi	0.002585	0.001111	0.000432	0.024106	0.000249	0.007497	0.000839	0.000496	0.002189	0.000480	0.043211
ci	0.020594	0.014723	0.007438	0.025543	0.010522	0.123169	0.010298	0.011393	0.021387	0.006126	0.152869
di	0.163774	0.173600	0.438626	0.596709	0.468483	0.287975	0.397844	0.330673	0.457103	0.385133	22.225412
cpi	0.001387	0.001257	0.000878	0.025522	0.000075*	0.120776	0.000436	0.000169	0.000299	0.000148	0.001335
japanese_number	0.001356	0.000822	0.000469	0.015947	0.000276	0.022995	0.000249	0.000416	0.000016*	0.000027	0.001707
kokogyo	0.022711	0.008175	0.011660	0.003883	0.004977	0.029787	0.003438	0.003959	0.009077	0.003809	0.860511
MO	0.032476	0.027146	0.049554	0.174152	0.020958	0.071154	0.009967	0.006678	0.017144	0.004575	2.241972
mbase	0.305192	0.348919	0.286338	0.236126*	0.303508	0.381188	0.330470	0.374914	0.321362	0.380969	0.643724
nikkei	0.004726	0.007085	0.008171	0.069730	0.004393	0.016348	0.008231	0.009298	0.001799*	0.002798	0.801354
usd_jpy	0.007630	0.004559	0.016900	0.013740	0.100693	0.068569	0.001889*	0.002937	0.010563	0.002062	0.175374
situgyou	0.036404	0.026083	0.017876	0.192516	0.005426	0.030916	0.005252	0.017640	0.029819	0.005043	1.788606
prole	0.001331	0.001244	0.000326	0.022940	0.000183	0.027581	0.000357	0.000352	0.003416	0.000185	0.003034
sangyou	0.002438	0.001680	0.001079	0.011399	0.001468	0.142267	0.000852	0.001568	0.000290	0.000190	0.007734
tingin	0.016610	0.026491	0.029936	0.111785	0.037547	0.068767	0.064966	0.065015	0.059027	0.036597	2.582798
koyou_s	0.002585	0.001541	0.000562	0.053536	0.000220*	0.085049	0.000915	0.000520	0.000359	0.000567	0.002107
work_time	0.001075	0.000883	0.000475	0.007731	0.001422	0.043262	0.000186	0.000130	0.000571	0.000175	0.023458
export_index	0.004677	0.002697	0.003196	0.041561	0.035558	0.037902	0.002077	0.001979	0.002924	0.001125	0.055038
import_index	0.007186	0.008753	0.005118	0.024151	0.131929	0.040322	0.001347	0.002124	0.012153	0.002750	0.047837
M1	0.091646	0.104660	0.080417	0.099147	0.146548	0.161133	0.159640	0.172373	0.069239	0.119929	0.685885
M2	0.003022	0.002554	0.002790	0.051039	0.005577	0.011421	0.007029	0.012254	0.001901	0.003622	0.215915
M3	0.002191	0.002919	0.001176	0.040860	0.006668	0.100056	0.001297	0.002748	0.000399	0.000198*	0.121604
cpi_usa	0.002887	0.002826	0.001984	0.004876	0.007323	0.052832	0.006397	0.009696	0.005040	0.002139	0.147731
M2_usa	0.014247	0.015418	0.011204	0.019279	0.026408	0.038354	0.038947	0.051116	0.030405	0.029177	0.641118
situgyou_usa	0.016193	0.034345	0.005571	0.016303	0.008570	0.110275	0.004778*	0.006736	0.250374	0.010326	0.230548
kpremium_num	0.038475	0.032509	0.045265	0.075421	0.025675	0.237617	0.020124	0.010349	0.058284	0.016935	1.212849
kyuzin	0.043159	0.060067	0.028468	0.053640	0.177491	0.023199	0.026401	0.012076	0.018109	0.020898	0.214782

表 4 LSTNet と ALSTNet の月次データの結果

きいと考えられる。

5 おわりに

本研究では、LSTNet を用いた多変量時系列予測において、特定の過去区間情報を強調するモデルとして、Attention MALSTNet (AMALSTNet) を提案した。

提案手法と従来手法である LSTNet、ALSTNet 及び、MALSTNet を用いて実際の多変量時系列データを対象とした検証実験を行った。月次データを対象とした実験では、Attention を適用した ALSTNet と AMALSTNet において、多くの系列で予測精度が向上した。ALSTNet と AMALSTNet では、モデルの特徴により適切な Attention 数は異なり、長期予測に適したモデルでは少ない Attention 数が有効であると実験的に確認された。年次データを対象とした実験でも Attention を適用したモデルは多くの系列で予測精度が向上した。今後の課題として、長期予測を対象とした日次データによる検証実験や自動で適切な Attention 数を算出するアーキテクチャの提案が挙げられる。

参考文献

- [1] Sima Siami-Namini, Neda Tavakoli, and Akbar Siami Namin. "A comparison of ARIMA and LSTM in forecasting time series". In 2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA), pp.1394-1401. IEEE, 2018.
- [2] George E.P.Box, Gwilym M. Jenkins, and Gregory C.Reinsel, "Time Series Analysis Forecasting and Control", Prentice-Hall International, Inc, Third Edition.
- [3] 中挟晃介, 辰井大祐, 國松武俊ほか. ニューラルネットワークを用いた列車遅延・乗車率予測手法. 情報処理学会論文誌 Vol.60, No.4, pp.1129-1140, 2019.
- [4] 安達 凜, 六井 淳, "複数入力を用いた Recurrent Neural Network に基づく時系列予測", FIT2019 講演論文集, 第二分冊, pp.45-52, 2019.
- [5] Guokun Lai, Wei-Cheng Chang, Yiming Yang, and Hanxiao Liu, "Modeling Long- and Short-Term Temporal Patterns with Deep Neural Networks", The 41st International ACM

SIGIR Conference on Research & Development in Information Retrieval, pp.95-104, 2018.

- [6] Y. LeCun, L. Bottou, Y. Bengio, and P.Haffner, "Gradient-based learning applied to document recognition", Proc. of the IEEE, pp.2278-2324, 1998.
- [7] Jeffrey L Elman. "Finding structure in time", Cognitive science, Vol.14, No.2, pp.179-211, 1990.
- [8] Kyunghyun Cho, Bart van Merriënboer, Caglar Gulcehre, Dzmitry Bahdanau, Fethi Bougares, Holger Schwenk, and Yoshua Bengio, "Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation", Association for Computational Linguistics, pp.1724-1734, 2014.
- [9] Pengfei Zhang, Jianru Xue, Cuiling Lan, Wenjun Zeng, Zhanning Gao, and Nanning Zheng, "EleAtt-RNN: Adding Attention to Neurons in Recurrent Neural Networks", IEEE Transactions on Image Processing (Volume:29), pp.1061-1073, 2019.
- [10] Jiayu Qiu, Bin Wang, and Changjun Zhou, "Forecasting stock prices with long-short term memory neural network based on attention mechanism", PloS one, Vol.15, No.1, p.e0227222, 2020.
- [11] 佐野 隼乙, 六井 淳, "LSTNet に基づく多変量時系列予測改善法", 信学技報, Vol.121, No.304, pp.71-76, 2021.
- [12] 日本銀行, "日本銀行時系列統計データ検索サイト", <http://www.stat-search.boj.or.jp/index.html>.
- [13] 内閣府, "内閣府統計情報・調査結果", <https://www.esri.cao.go.jp/statistics/>
- [14] 総務省, "e-Stat 政府統計の総合窓口", <https://www.e-stat.go.jp/>.
- [15] 経済産業省, "経済産業省 統計", <https://www.meti.go.jp/statistics/index.html>.
- [16] Federal Reserve Bank of St.Louis, "Federal Reserve Economic Data (FRED) St.Louis Fed", <https://fred.stlouisfed.org/>.
- [17] Yahoo, "YahooFinance.", <https://finance.yahoo.com/>.

	MALSTNet	AMALSTNet(3)	1 割 (16)	2 割 (33)	3 割 (49)	4 割 (66)	5 割 (88)	6 割 (99)	7 割 (115)	8 割 (132)	9 割 (149)
cgpi	0.000297	0.000153*	0.000306	0.001009	0.000871	0.001523	0.001830	0.001175	0.007821	0.107963	0.016083
ci	0.003365	0.006944	0.003451	0.002220*	0.003633	0.006178	0.004666	0.013000	0.040883	0.176504	0.029245
di	0.144841	0.159039	0.205171	0.056700	0.246041	0.070625	0.054312*	0.084391	0.169345	0.259182	0.138084
cpi	0.000427	0.000375	0.000148	0.000392	0.000461	0.000421	0.000445	0.002017	0.027259	0.165481	0.015558
japanese_number	0.000031	0.000171	0.000025	0.000077	0.000037	0.000111	0.000403	0.003812	0.039444	0.186215	0.009099
kogogyo	0.003966	0.005373	0.003977	0.003298*	0.003518	0.003563	0.003382	0.005851	0.028893	0.137992	0.016682
MO	0.012423	0.025406	0.004929	0.002923*	0.004353	0.006619	0.006609	0.005324	0.014729	0.083951	0.017045
mbase	0.362885	0.341236	0.377514	0.406981	0.415399	0.454323	0.472713	0.486745	0.505914	0.533243	0.466308
nikkei	0.006612	0.002937	0.006407	0.019998	0.017684	0.028591	0.031586	0.038043	0.021155	0.004388	0.040507
usd_jpy	0.003866	0.002155	0.003365	0.002540	0.004578	0.003176	0.004520	0.008724	0.020092	0.091080	0.011237
situgyou	0.029101	0.063151	0.010541	0.003732*	0.008026	0.008828	0.049104	0.105894	0.180491	0.299129	0.136253
prole	0.000099*	0.000122	0.000136	0.000150	0.000319	0.000197	0.000287	0.001792	0.029058	0.156799	0.010288
sangyou	0.000205	0.000319	0.000171*	0.000263	0.000229	0.000338	0.000682	0.006021	0.047735	0.187948	0.018487
tingin	0.001595*	0.018482	0.030969	0.031003	0.031862	0.031602	0.032728	0.036530	0.047972	0.082441	0.037721
koyou_s	0.000354	0.000328	0.000361	0.000587	0.001121	0.000854	0.001017	0.000812	0.021328	0.151410	0.024776
work_time	0.000423	0.000154	0.000123*	0.000131	0.000130	0.000137	0.000185	0.000870	0.019210	0.119614	0.013166
export_index	0.003331	0.006401	0.001385	0.000770*	0.000943	0.005366	0.004838	0.003856	0.002681	0.054326	0.009013
import_index	0.002170	0.003146	0.001389	0.002114	0.000846	0.000692*	0.001220	0.002250	0.014184	0.100244	0.010671
M1	0.056529	0.051379*	0.090397	0.124325	0.127267	0.168077	0.191816	0.271341	0.358027	0.456445	0.345183
M2	0.000611	0.001092	0.000412*	0.002478	0.002435	0.008069	0.015793	0.051681	0.125133	0.250254	0.108079
M3	0.000848	0.000848	0.000816	0.001586	0.000576	0.000829	0.000956	0.013262	0.060276	0.212596	0.024318
cpi_usa	0.000690*	0.001335	0.000958	0.003625	0.005523	0.010227	0.014344	0.036928	0.099512	0.268750	0.070872
M2_usa	0.003980*	0.003985	0.007244	0.025869	0.029952	0.053809	0.081424	0.136718	0.204345	0.356434	0.190844
situgyou_usa	0.038157	0.047587	0.078306	0.054641	0.055094	0.037444	0.031161	0.015796	0.029648	0.112943	0.025368
kpremium_num	0.039720	0.027852	0.022122	0.009911	0.017546	0.011096	0.007337*	0.013287	0.050746	0.152132	0.036816
kyuzin	0.006196*	0.011693	0.014482	0.014862	0.016675	0.011265	0.011949	0.006930	0.017161	0.046405	0.013927

表 5 MALSTNet と AMALSTNet の月次データの結果

	LSTNet	ALSTNet1 割 (2)	(3)	2 割 (4)	3 割 (7)	4 割 (9)
b_baby	0.000309	0.000751	0.001915	0.001749	0.000290*	0.001683
cgpi	0.000928	0.000478	0.001455	0.000293*	0.000772	0.002067
cpi	0.002623	0.001725	0.002063	0.000165*	0.002850	0.005038
ene	0.001732	0.001639	0.003238	0.001292	0.001679	0.012054
exchange	0.095222	0.065300	0.070829	0.020981*	0.116826	0.201401
farm	0.000372	0.000099*	0.000910	0.000483	0.000246	0.001217
gold	0.012401	0.011712	0.026542	0.006679*	0.009151	0.022617
money	0.010928	0.007011	0.019227	0.006897	0.040184	0.053528
nyukoku	0.007752	0.006109*	0.015539	0.034268	0.021763	0.025525
official_rate	0.016680	0.012476*	0.072603	0.053013	0.037461	0.027141
suicide	0.047753	0.039147	0.072529	0.020095*	0.105149	0.087984
tax	0.014226	0.017820	0.019476	0.020782	0.010007	0.031262
trade	0.027622	0.019804	0.016501	0.029464	0.005740*	0.014344
trans	0.000995	0.002106	0.003247	0.006765	0.000959	0.005617
yosan	0.016818	0.034004	0.078509	0.030808	0.011051	0.064676

表 6 LSTNet と ALSTNet の年次データの結果

	MALSTNet	AMALSTNet1 割 (2)	(3)	2 割 (4)	3 割 (7)	4 割 (9)
b_baby	0.002478	0.007311	0.002284	0.000510	0.001275	0.001092
cgpi	0.003073	0.005686	0.001650	0.003415	0.007776	0.004272
cpi	0.001866	0.056353	0.004291	0.001199	0.000516	0.001195
ene	0.000609*	0.027180	0.025114	0.002046	0.016083	0.011297
exchange	0.198527	0.190352	0.051201	0.095035	0.244550	0.245983
farm	0.002286	0.026209	0.001969	0.001599	0.002642	0.005954
gold	1.926515	0.059785	0.016253	0.032789	0.024921	0.032796
money	0.013152	0.057995	0.003452*	0.044675	0.109745	0.110963
nyukoku	0.084827	0.055340	0.042651	0.040419	0.051092	0.043988
official_rate	0.053180	3.360490	0.181591	0.069175	0.094234	0.025537
suicide	0.027132	0.112315	0.037060	0.081295	0.087455	0.091753
tax	0.005858	0.024113	0.013829	0.004488	0.001493*	0.005008
trade	0.339708	0.006120	0.016118	0.031943	0.022063	0.024248
trans	0.001161	0.025792	0.006403	0.000703*	0.002762	0.001546
yosan	0.000817	0.001242	0.001577	0.000354	0.000084	0.000054*

表 7 MALSTNet と AMALSTNet の年次データの結果