

LSTMを用いたミリ波帯における到来パス電力予測に関する一検討

明治大学大学院 先端数理科学研究科 ネットワークデザイン専攻 email: cs223029@meiji.ac.jp
山崎天翔 大野光平

背景・目的


LSTMは時系列予測に優れており、過去のデータから未来の受信電力を予測することが可能である。過去に受信したミリ波の電力とアンテナ座標のみから、**現在より先の地点におけるミリ波の受信電力の予測を行う**。これにより、**地図データや、事前の測定を必要とせずに伝送路の予測が可能である**。機械学習には多くのデータが必要となるが、実際には学習に十分な量のデータを得るのは困難な場合がある。そのため、測定した伝送路の伝達関数をより狭い帯域に分けてデータ数を増やす手法を、LSTMネットワークに適用することを提案する。また、提案手法をLSTMネットワークに適用することにより、**現在より先の地点における特定の周波数帯の受信電力予測が可能になることを示す**。

伝送路測定

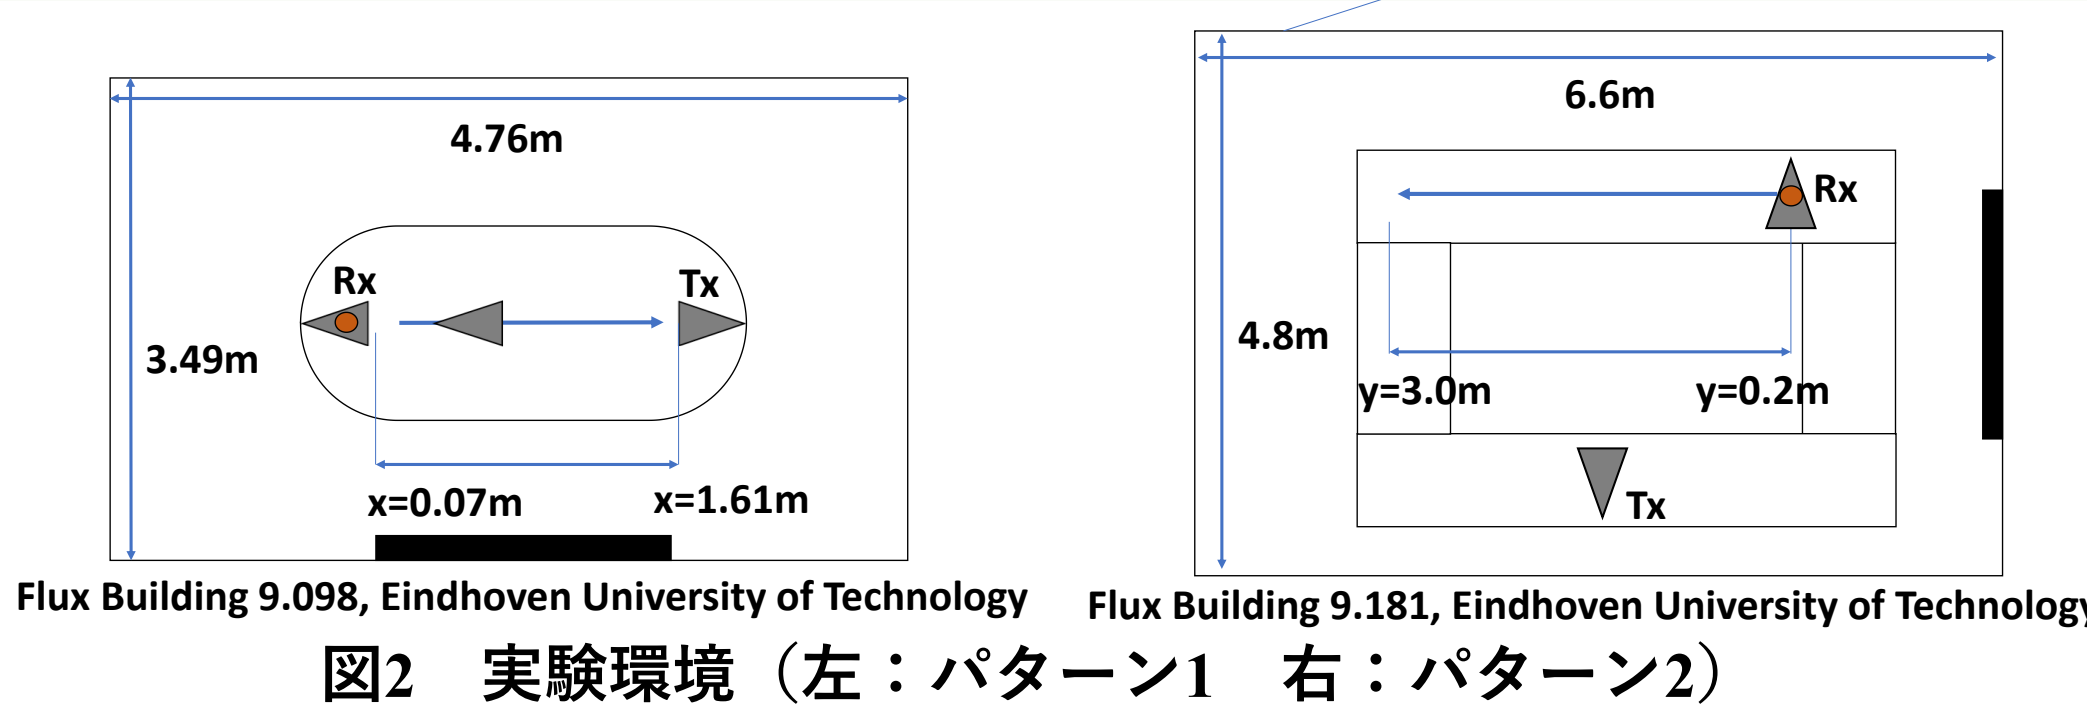
本研究で使用したチャンネルは、アイントホーフェン工科大学の会議室で測定したものである。測定のための設定諸元を表1に示す。

アンテナ	STANDARD GAIN HORN Model 22240-20
ベクトルネットワークアナライザ	Keysight Field FOX N9918
周波数	24.1[GHz] - 26.5[GHz]
帯域幅	2.4[GHz]
IF帯域幅	10[kHz]
測定点	10001
パラメータ	S_{21}

屋内において、ユーザーがゲージが直線的な歩行など、単純な移動を行う場面を想定し、2種類の環境で S_{21} パラメータを得る



手順1
屋内の会議室において、アンテナを少しずつ移動させ、各地点での S_{21} パラメータを取得する。



手順2 (提案手法)
測定した2.4[GHz]帯域を m 個の幅240[MHz]の小さい帯域に分割する。この手順により、学習データを m 倍に増やすことができる。

手順3
 S_{21} パラメータをIFFTし、取得したインパルス応答から第一到来波を取り出す。


図3 取得したインパルス応答の例(図2 $y=3.0$ [m]の場合)

測定結果

パターン1: 受信アンテナに近づくほど受信電力が増加する。

パターン2: 受信アンテナが正面にあるとき受信電力が増加し、正面から遠ざかるにつれて低下する。

これらは、ミリ波は距離に対する減衰が大きく、直進性が高いためである。



提案手法: チャンネル分割によるデータの拡張

測定した帯域を小さく分割することによって学習データ数を増やす。取得した広い帯域 B_w [GHz]を、より狭い帯域 $B_n=240$ [MHz]に、 Δf [Hz]ずつ移動させる。それぞれが異なる中心周波数を持つ幅 B_w の帯域を m 個の伝達関数が得られる。

$$B_w = B_n + \Delta f(m-1) \quad (2)$$

このようにチャンネルを細かく分割する手法を**マルチバンド方式**に対して、元データを使用する場合を**シングルバンド方式**とする。

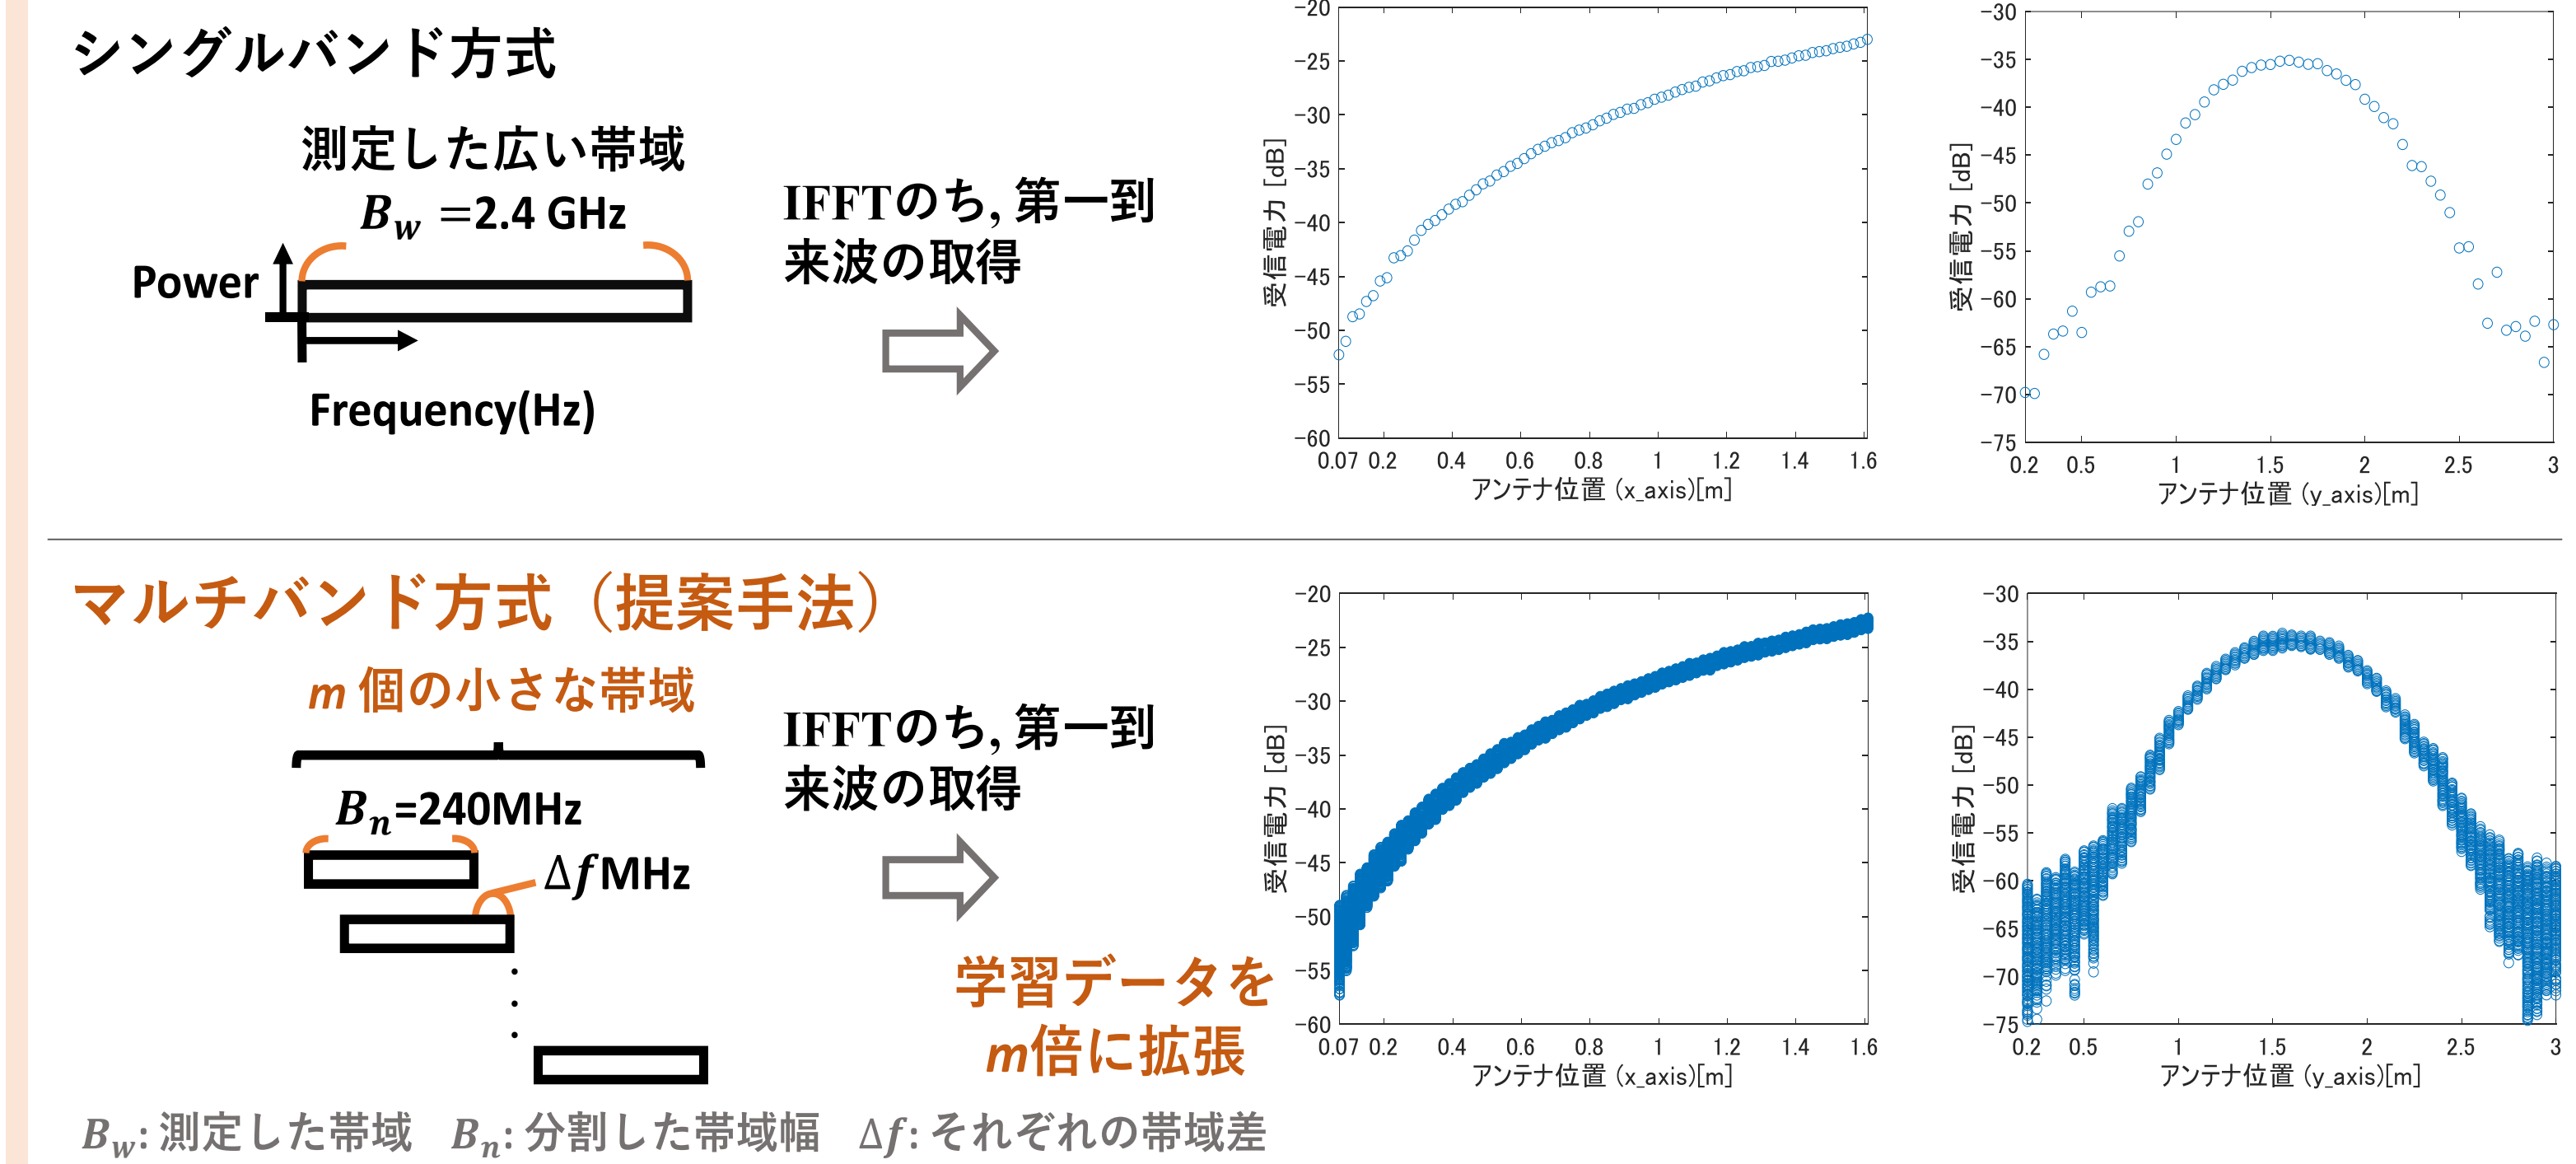


図7: チャンネル分割の概要 (m=1001の場合)

マルチバンド方式における受信電力予測

マルチバンド方式では、入力した m 個の帯域それぞれにおける受信電力の予測が出力される。これにより、**現在より先の地点における特定の周波数帯域の受信電力の予測が可能となる**。

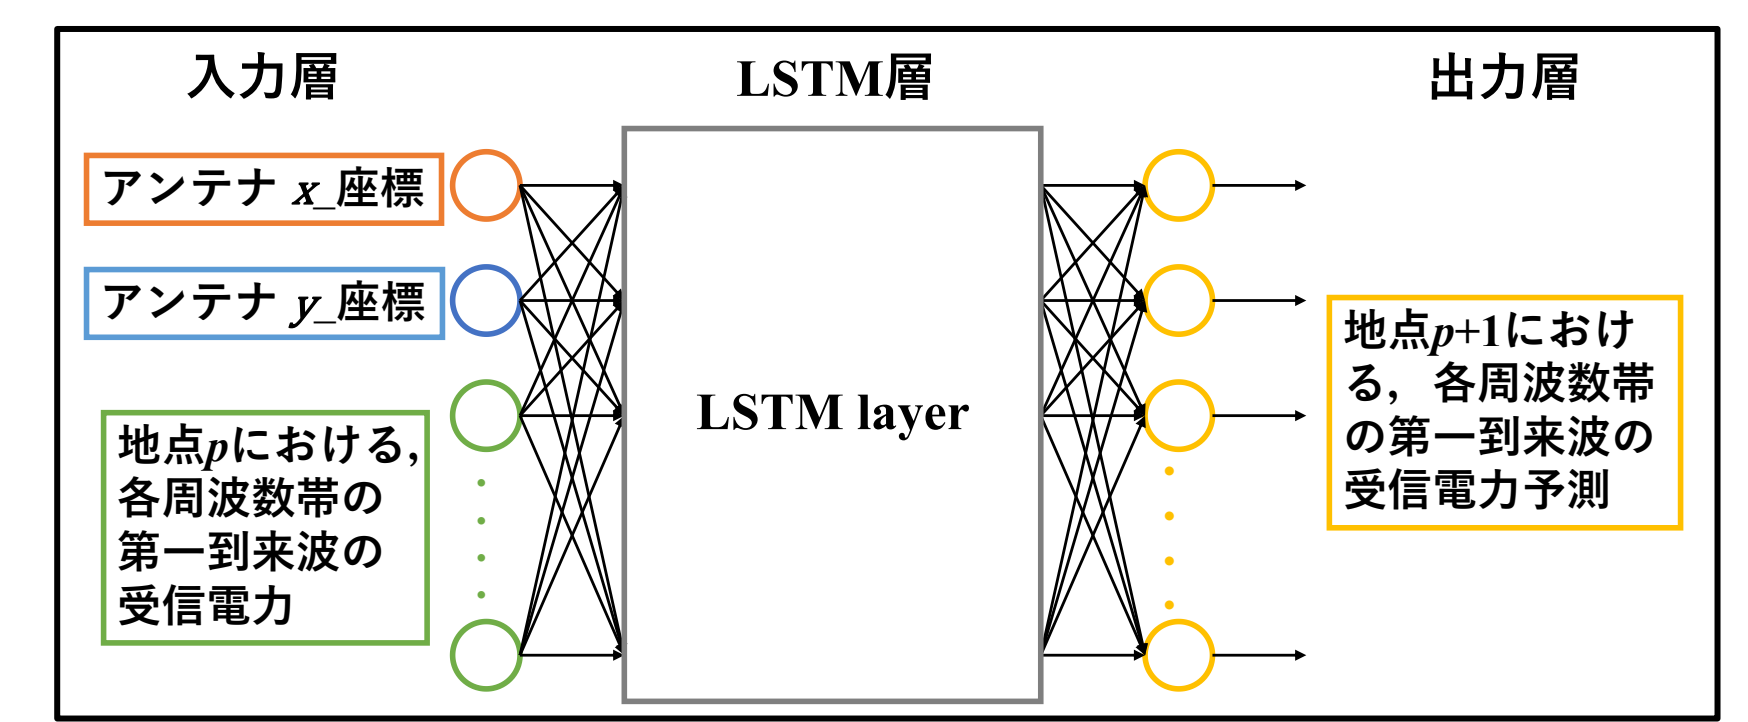


図8: マルチバンド方式で使用するLSTMネットワーク

マルチバンド方式において、チャンネルの分割数 m を変化させていき、受信電力予測を行う。結果、パターン1では $m=7$ 、パターン2では $m=41$ が最も良い結果となった。分割数 m にかかわらず、LSTMネットワークにおける予測結果は全結合ネットワークの予測よりも良好な結果が得られた。




図9: チャンネル分割数 m を変化させたときのRMSE (左: パターン1 右: パターン2)

LSTMによる予測

予測のために、LSTMネットワークを構築する。また、比較のために、全結合のニューラルネットワークを構築する。

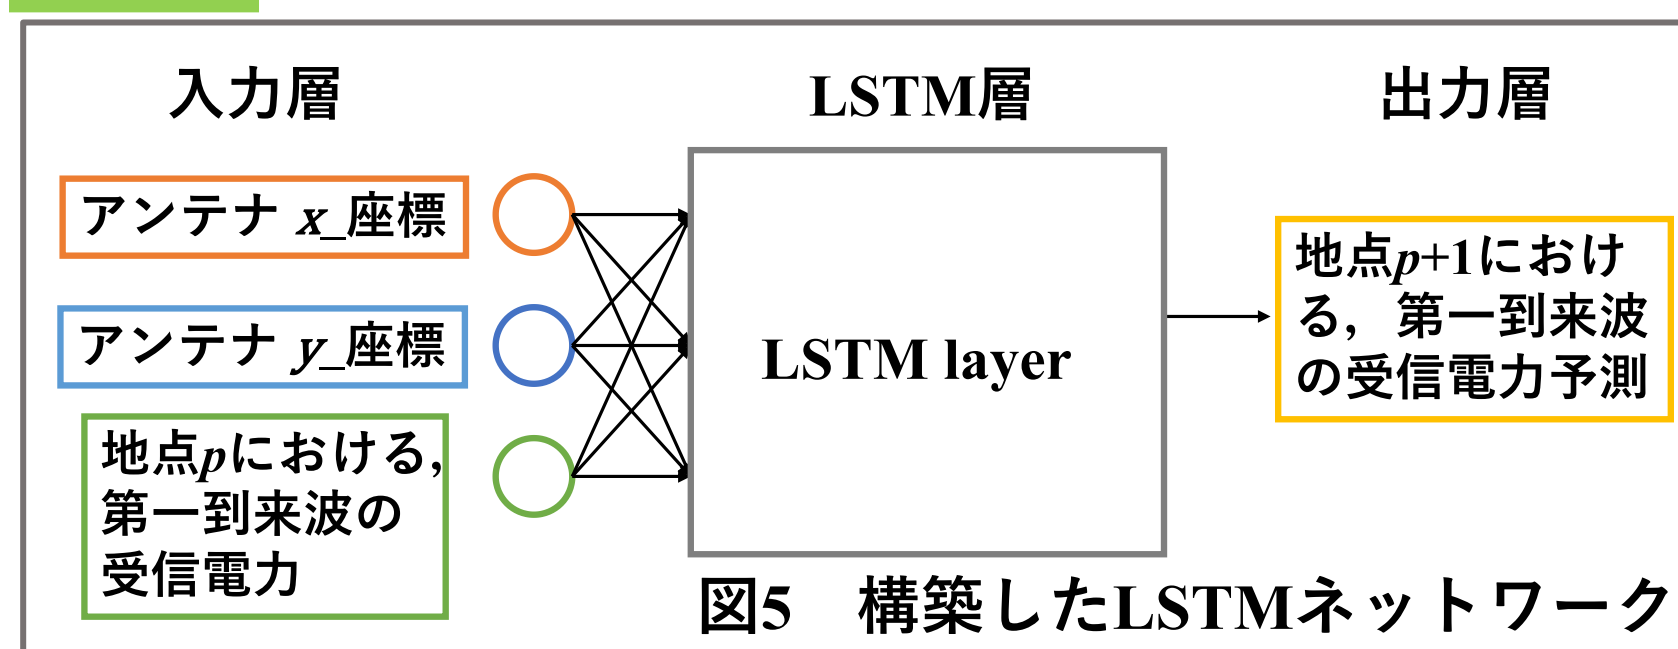


図5: 構築したLSTMネットワーク

LSTMネットワークと全結合のニューラルネットワーク予測結果の評価は、電力予測と元データのRMSE(Root Mean Square Error)を用いて行った。 \hat{y}_p は地点 p におけるテストデータ、 y_p は地点 p における予測値である。

$$RMSE = \sqrt{\frac{1}{n} \sum_{k=1}^n (\hat{y}_p - y_p)^2} \quad (1)$$

LSTMネットワークの予測結果は、テストデータと値ほぼ同じであるため、予測誤差が小さい。一方で、全結合のニューラルネットワークによる予測結果は、大きく離れており、正しく予測ができていないことがわかる。結果より、**LSTMネットワークによる予測は全結合のニューラルネットワークよりも優れている**。




図6: LSTMネットワークと全結合のニューラルネットワークによる予測結果 (左: パターン1 右: パターン2)

結論

本研究では、ミリ波の第一到来波の受信電力予測方式について検討した。その結果、**全結合のニューラルネットワークと比べ、LSTMネットワークはRMSEが改善されることを示した**。

さらに、本研究ではチャンネルを分割し、学習に使用するデータ数を確保することで、**予測精度が向上することを示した**。したがって、全結合のニューラルネットワークに比べLSTMネットワークは予測精度に優れている。また、**マルチバンド方式によってデータ数を増やすことで、予測精度が向上する**。

	LSTMネットワーク		全結合のニューラルネットワーク	
	シングルバンド方式	マルチバンド方式	シングルバンド方式	マルチバンド方式
パターン1	0.087[dB]	0.063[dB]	3.4[dB]	0.20[dB]
パターン2	2.7[dB]	2.1[dB]	5.3[dB]	3.3[dB]