




機械学習を用いたマルチパス検出 2I05


尾関 友啓 久保信明

東京海洋大学 情報通信工学研究室
2022/11/02


Background




9機



54機



Bosch





Panasonic





Quantum-Systems

Background




静止している状況では、**NLOS&LOS+reflected**信号が移動体より受信できる

Background




上空視野(Google Earth)

DGNSS測位結果(水平)




衛星数(時系列)




青色：分類せずに測位
赤色：LOS衛星のみで測位

DGNSS測位結果(水平)




衛星数(時系列)




あくまで一例だが、測位誤差が極端に大きい環境下ではNLOSが支配的
→LOS/NLOSの分類に焦点を当てればよい

Classification of LOS/NLOS


3D map



魚眼カメラ



Residual チェック



3Dマップ、魚眼カメラ：追加機器必要、計算コストの観点から×
Residual チェック：高層ビル街では、観測事後残差 ≠ マルチパス誤差
→機械学習を用いたLOS/NLOS分類ができないか？


Flowchart of this study



GNSS演算に関してはC言語、SVMに関してはPythonで実装
各エポックごとに衛星数×特徴量を分類器に入力し、判定(瞬時値のみで)

Classification of LOS/NLOS using SVM

- ・ 香港理工大の「Machine learning based LOS/NLOS classifier and robust estimator for GNSS shadow matching」を参考
- ・ 今回はSVM(サポートベクターマシン)を用いてLOS衛星を選択(0:LOS、1:NLOS)
SVMはパターン認識問題で使用する教師あり学習の1つ
- ・ 参考にした論文では、**仰角、SNR、最小二乗法から出力される観測残差、擬似距離変化率**を特徴量として使用



SNR : Signal Noise Ratio

SNRが高いほど信号追尾状況が安定している

→LOSである確率が高い


高仰角衛星は障害物の影響が少なく、SNRも高い

→LOSである確率が高い



SNR=...45...40...35...30...25 <25

Classification of LOS/NLOS using SVM

- 各エポックの残差で**標準化した観測誤差**
(**Normalized Pseudo-range Residual : NPR**)を特徴量に使用
- 擬似距離変化率(Pseudo-range Rate Consistency : PRC)
NLOSの場合、障害物により信号伝搬が上手くいっていないため、伝搬経路が時々刻々に変化している
つまり擬似距離の時間差分を監視するとLOSとNLOSの判別がある程度できる
- SNRの標準偏差(SNR Fluctuation Magnitude : SFM)
NLOS衛星のSNRは安定しないため、SNRの標準偏差によって判別ができる
- Guard Time



- 東京駅周辺及び東京海洋大学構内のマルチパス環境下でRINEXデータを取得
 - ①～⑤：訓練データ
 - A：テストデータ
- LOS/NLOSのラベル付けは、真値からの残差 + fish-eye view(Google Earth)より設定



Dataset	Date & Time(Tow)	Train or Test	NLOS rate (%)
①	2020/04/03, 461880~463500	Train	28.38
②	2020/06/24, 269905~278129	Train	43.54
③	2020/07/04, 541936~543560	Train	42.63
④	2022/10/26, 270180~272399	Train	14.87
⑤	2020/04/17, 381780~383400	Train	29.74
A	2020/04/18, 277379~279005	Test	29.80

- ・各地点とも約30分程度のデータ
- ・データ取得日及び取得場所は異なる
→訓練データとして最適
- ・Ublox-F9P,ANN-MB-0000を使用してデータを取得



(%)	Accuracy	NLOS rate 選択前	NLOS rate 選択後
①	92.11	28.38	6.08
②	77.38	43.54	27.20
③	81.23	42.64	24.30
④	87.04	14.87	4.79
⑤	87.05	29.74	12.88
A	89.80	29.79	4.68


		予測	
		LOS	NLOS
正解	LOS	TN(True Negative)	FP(False Positive)
	NLOS	FN(False Negative)	TP(True Positive)

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TP}$$

NLOS rate 選択前：SVM classifierで分類前のNLOS rate
 NLOS rate 選択後：SVM classifierで分類後のNLOS rate

NLOSと判定された衛星を除外することで、NLOS rateを下げる能够做到ている



Flowchart of this study



残ったNLOS衛星(偽陰性)はResidualチェックで排除

Result(Horizontal error)

Datasets (1619 epochs)	DGNSS	DGNSS+ Residual check	DGNSS+ SVM	DGNSS+ SVM+ Residual check
Mean error	27.68 m	14.12m	9.03 m	6.09 m
STD	10.39 m	13.10 m	11.00 m	9.82 m
Percentage (<3 meters)	1.05%	17.17%	27.85%	31.37%
Percentage (<10 meters)	5.78%	55.14%	51.94%	91.22%



- SVMでLOS/NLOS判定を実施
5カ所の訓練データにより分類器を訓練、1カ所のテストデータで精度を確認
分類器によってNLOSと判定された衛星を測位演算から排除することで、測位演算に使用する観測方程式に混在するNLOS衛星の比率(NLOS rate)が下がる
- 分類器によってLOS衛星と誤判定されたNLOS衛星はResidualチェックにより除去
NLOS rateを下げたことにより、Residualチェックの効果が顕著に出る
- 今後の課題
 - 受信機各社が出している独自の情報を特徴量に採用することを検討
 - 複数周波数を用いた分類器の生成
 - 信号相関波形を利用したマルチパス誤差の推定
 - 回帰分析によるマルチパス誤差の推定