

# 太陽光発電の分散予測技術に関する研究

ガリ ダ シルバ フォンセカ ジュニア ジョアン (産業技術総合研究所)  
 大関 崇 (産業技術総合研究所)  
 高島 工 (産業技術総合研究所)  
 荻本 和彦 (東京大学)

独立行政法人 産業技術総合研究所

## 太陽光発電量予測

### 予測分類

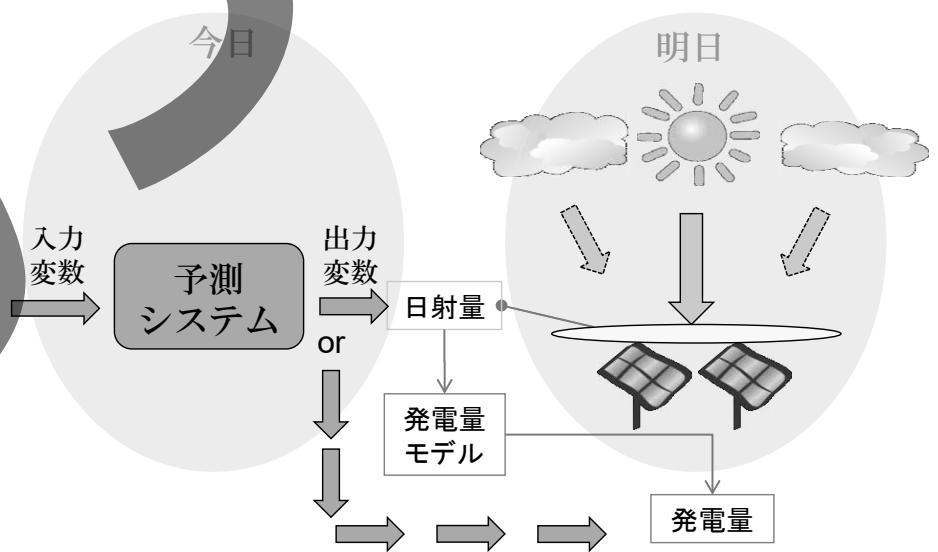
- ・ 間接法
- ・ 直接法

### 利用データ分類

- ・ GPV-MSM (気象庁)

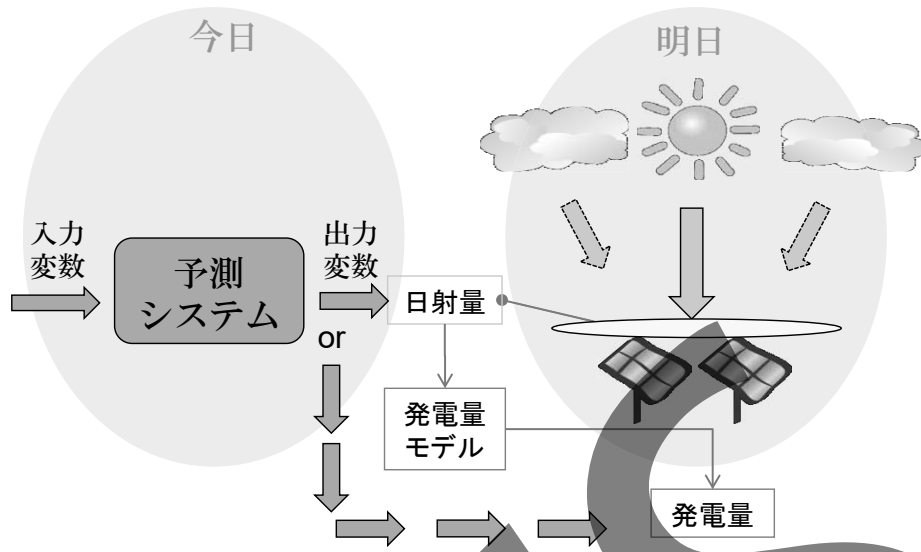
### 手法

人工知能(ニューラルネットワーク、SVM等)



目的: 事前に(1日前)1日の太陽光発電システムの発電量を予測することです。

# 太陽光発電量予測



## 最初に（2010年）

### 予測分類

- ・ 間接法でGPV-MSMを利用しながら日射量の予測に集中した。

### 手法

人工知能（基本的なニューラルネットワークを作った）

独立行政法人 産業技術総合研究所

Table 1. ANN input parameters.

# 入力データ

## 気象庁のGPV-MSM予報システム

気温  
湿度  
雲量（下層、中層、上層）

気象庁の地上気象観測再統計値 気象庁のメソ数値予報モデルGPV。


■メソ数値予報モデルGPV (MSM)  
平成18年3月から、計算の格子間隔を5kmメッシュに細分化するとともに、運用回数を1日8回としました。

### ◇データの概要◇

内容	要素は下記を参照してください。
初期値	00, 03, 06, 09, 12, 15, 18, 21UTC(1日8回)
予報時間	15時間予報(00, 06, 12, 18, UTC)、33時間予報(03, 09, 15, 21UTC) 地上は1時間間隔、気圧面は3時間間隔
データ形式	国際気象通報式FM92 GRIB 二進形式格子点資料気象通報式(第2版)※略称: GRIB2
配信領域	北緯22.4度~47.6度、東経120度~150度(※下図参照)
格子系	等緯度等経度 地上: 0.0625度×0.0625度(格子数505×481) 気圧面: 0.1度×0.125度(格子数253×241)
サイズ	15時間予報: 約114MB/回×4回、33時間予報: 237MB/回×4回=1404MB/日
技術資料	配信資料に関する技術情報第205号 国際気象通報式-別冊

### ◇地上物理量

	海面更正気圧	地上気圧	風	気温	相対湿度	時間降水量	雲量
地上	○	○	⊙	○	○	○	④



ソース: JMBSCのホームページ

# 何故人工知能？

## • 計算法を利用手法 (人工知能)

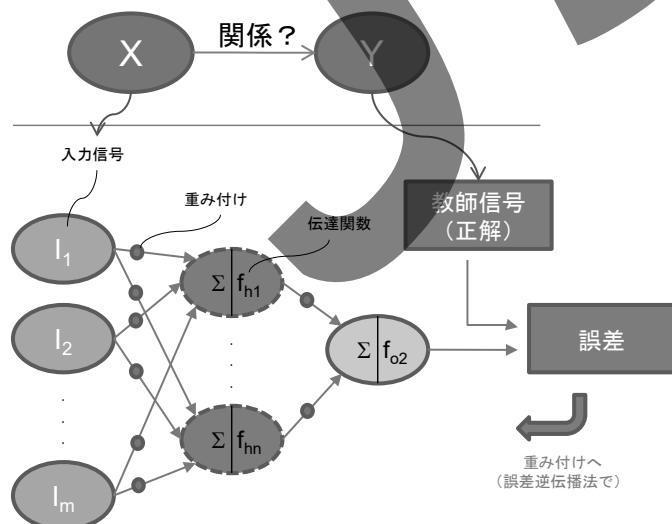
### 利点

- 一般化能力 (例外が割と対応出来る)
- 膨大なデータベースが不必要
- 並列処理ができる

## 予測手法 1

### 最初の予測手法 — ニューラルネットワーク (ANN)

「脳機能に見られるいくつかの特性を計算機上のシミュレーションによって表現することを目指した数学モデルである。」[1]



### 利点 [2]

- 線型、非線型問題でも対応出来る。
- 一般化能力
- 並列処理能力

### 欠点


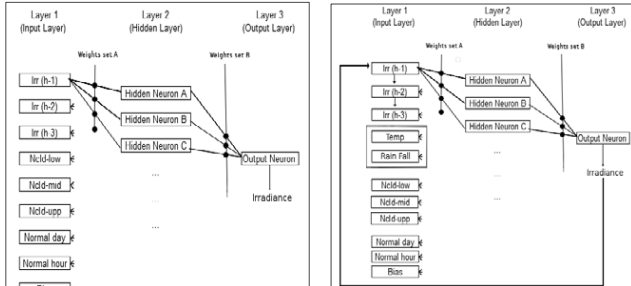
- 極小値に収束しやすい
- 大規模な対象に対する精密な計画・設計や制御 [3]

「結果として次元削減されるため、画像や統計など多次元量のデータでかつ線形分離不可能な問題に対して、比較的小さい計算量で良好な解を得られることが多い。」 [1]

# 予測手法 1

## 最初の予測手法 — ニューラルネットワーク (ANN)

自分のANNを作り出来る限り様々な観点から設定入力データなどの適切な設定を検討した。

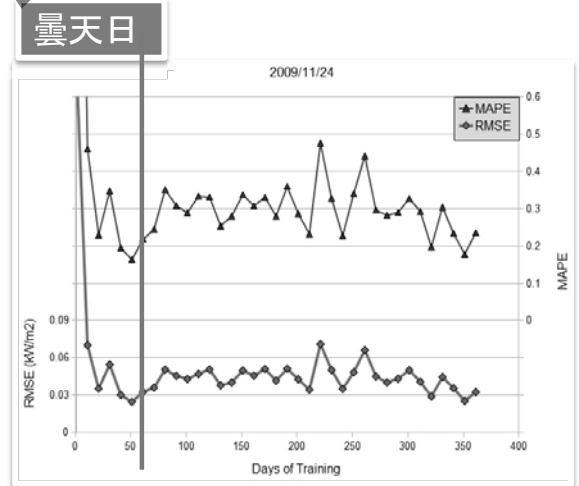
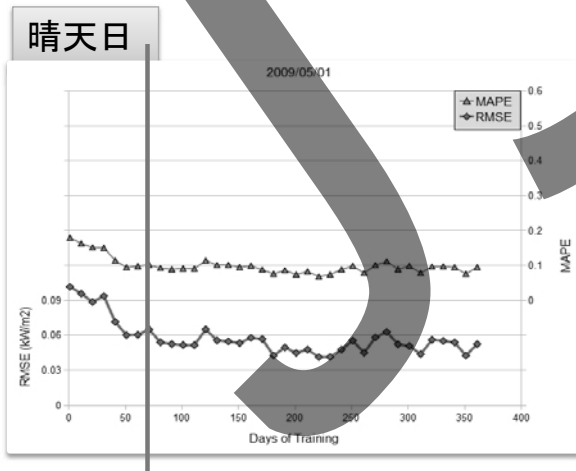


- ① 一年に一つANN 対 一日に一つANN。
- ② Context layerを使うか使わないか。
- ③ 適切な入力データの検討。
- ④ 適切な活性化関数の検討。
- ⑤ 適切な訓練事例量の検討。
- ⑥ 訓練の機関の検討など行った。

独立行政法人 産業技術総合研究所

## 例: 訓練事例量の検討

Fonseca et al, 電気学会部門大会B2011



訓練事例量による誤差変動

	51日	61日	181日	361日
MAPE	9.51%	9.87%	7.66%	9.58%
RMSE	0.060	0.060	0.042	0.052

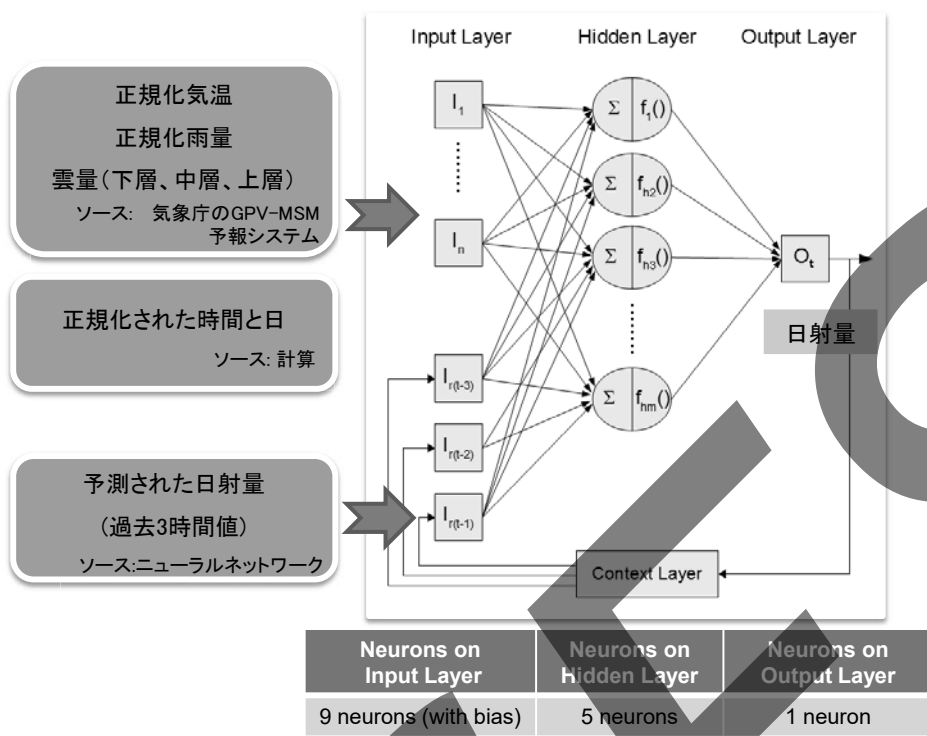
訓練事例量による誤差変動

	51日	61日	181日	361日
MAPE	16.2%	21.7%	27.9%	23.5%
RMSE	0.024	0.032	0.041	0.032

独立行政法人 産業技術総合研究所

# ANNの設定

## ニューラルネットワークの設定



## 収束アルゴリズム

➤ 誤差逆伝播

## 活性化関数

➤  $0.52 * \tanh(X) - 0.51$

## 他の設定パラメーター

➤ 学習係数: 0.3

➤ 慣性項: 0.2



➤ 訓練: 2000 epochs

独立行政法人 産業技術総合研究所

## 日射量予測

## 最初の結果

### 結果 (東京)



独立行政法人 産業技術総合研究所

# 最初の結果

## 結果の比較

ニューラルネットワーク(ANN) 対 A社のプログラム(2011年の版)

予測場所: 東京(緯度: 35.68° N 経度: 139.76° E)

予測日数: 150日(2007年08月~ 2007年12月)

月間毎




図6 予測日射量: 二手法の比較 二乗平均平方根誤差。

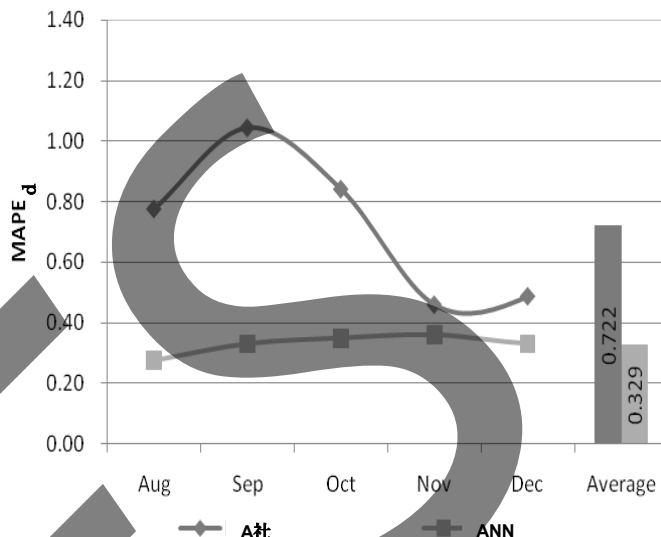


図7 予測日射量: 二手法の比較 平均絶対誤差率。

独立行政法人 産業技術総合研究所

# 最初の結果

## 日射量予測

## 結果の比較

ニューラルネットワーク(ANN) 対 回帰式と天気予報用プログラム

予測場所: 東京(緯度: 35.68° N 経度: 139.76° E)

予測日数: 360日(2008年01月~ 2008年12月)

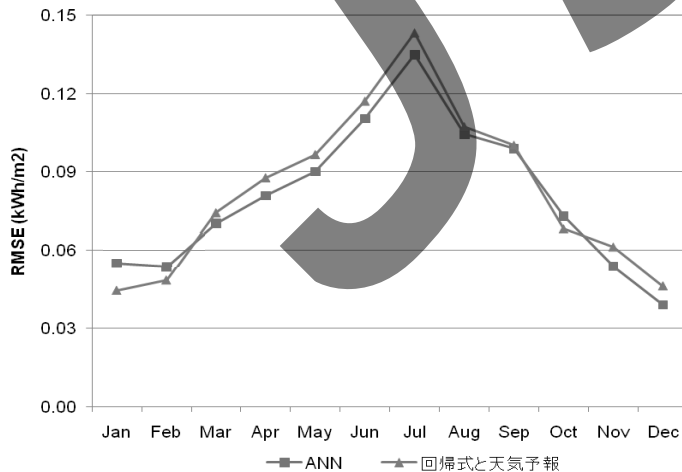


図8 予測日射量: 二手法の比較 二乗平均平方根誤差。




図9 予測日射量: 二手法の比較 平均絶対誤差率。

最適な結果を果たす為実際の天気状態を用いた。

表4 予測日射量: 二手法の比較 1年間の誤差。

誤差値 (1年間)	RSME (kWh/m <sup>2</sup> )	MAE (kWh/m <sup>2</sup> )	MAE <sub>d</sub> (kWh/m <sup>2</sup> )	MAPE <sub>d</sub>
ANN	0.0936	0.0575	0.5318	22.29%
回帰式と天気予報	0.0963	0.0577	0.6142	23.91%
	時間毎	2.9%	日時毎	15%
		0.35%		7.3%

## これまでの考察 1

- ✓ ANNとGPVで開発してきた日射量予測手法が従来(2011)予測手法よりせめて同じ予測精度か良い予測精度を実現できたことが分かった。
- ✓ 然し絶対値でみると予測精度がまだ高精度と呼ばれないのでそれを向けて一層の努力が求められる。
- ✓ それでより良い予測精度を実現する為に別予測技術の検討を行った。

## 別手法の検討

### サポートベクターマシン

「サポートベクターマシン は、教師あり学習を用いる識別手法の一つである。パターン認識や回帰分析へ適用できる。現在知られている多くの手法の中で一番認識性能が優れた学習モデルの一つである」。

#### ニューラルネットワーク

##### 反復法

学習際最適化問題を解決しない発見的な、ヒューリスティックな

#### サポートベクターマシン

##### 直接法

学習際最適化問題を解決する

# 別手法の検討

## ニューラルネットワーク

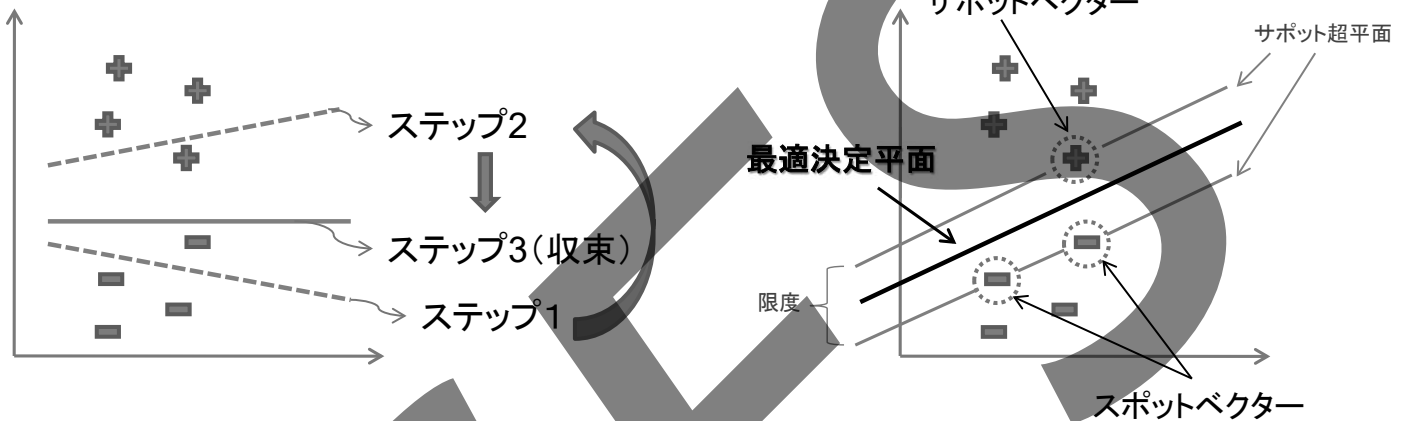
### 反復法

学習際最適化問題を解決しない発見的な、ヒューリスティックな

## サポートベクターマシン

### 直接法

学習際最適化問題を解決する



# サポートベクターマシン

## サポートベクターマシンについて (ν-SVR)

$y = f(x) = (w \cdot x) + b$  線形表現

同じ問題超平面で表現すると

$y_i \approx \sum_{j=1}^m w_j \phi(x_{ij}) + b$   $w$ はラグランジュの乗数で表現できる

$w = \sum_{j=1}^n (\alpha_j - \alpha_j^*) \phi(x_j)$

$y_i \approx \sum_{j=1}^m (\alpha_j - \alpha_j^*) k(x_i, x_j) + b$

マップ関数カーネル関数\*で表現できる

\*マッピングを定義する為二変数関数。

問題はラグランジュ関数に変換し最適化問題に成り。αを解決する為次の問題を最大にする。

$$-\frac{1}{2} \sum_{i,j=1}^n (\alpha_i - \alpha_i^*) k(x_i, x_j) (\alpha_j - \alpha_j^*) - \sum_{i=1}^n (\alpha_i - \alpha_i^*) y_i$$

制約条件

$$\begin{aligned} \sum_{i=1}^n (\alpha_i - \alpha_i^*) &= 0 \\ 0 &\leq \alpha_i^* \leq \frac{C}{n} \\ \sum_{i=1}^n (\alpha_i - \alpha_i^*) &\leq C \cdot \nu \end{aligned}$$

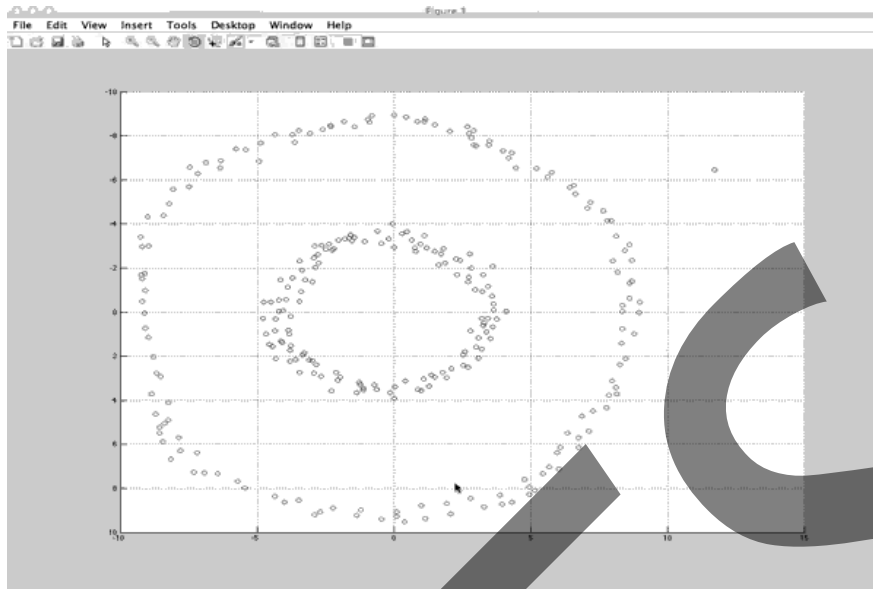
### 設定パラメーター

カーネル関数	C	n	γ
--------	---	---	---

様々な形で決定できる

$k(x_i, x_j) = e^{-\gamma |x_i - x_j|^2}$





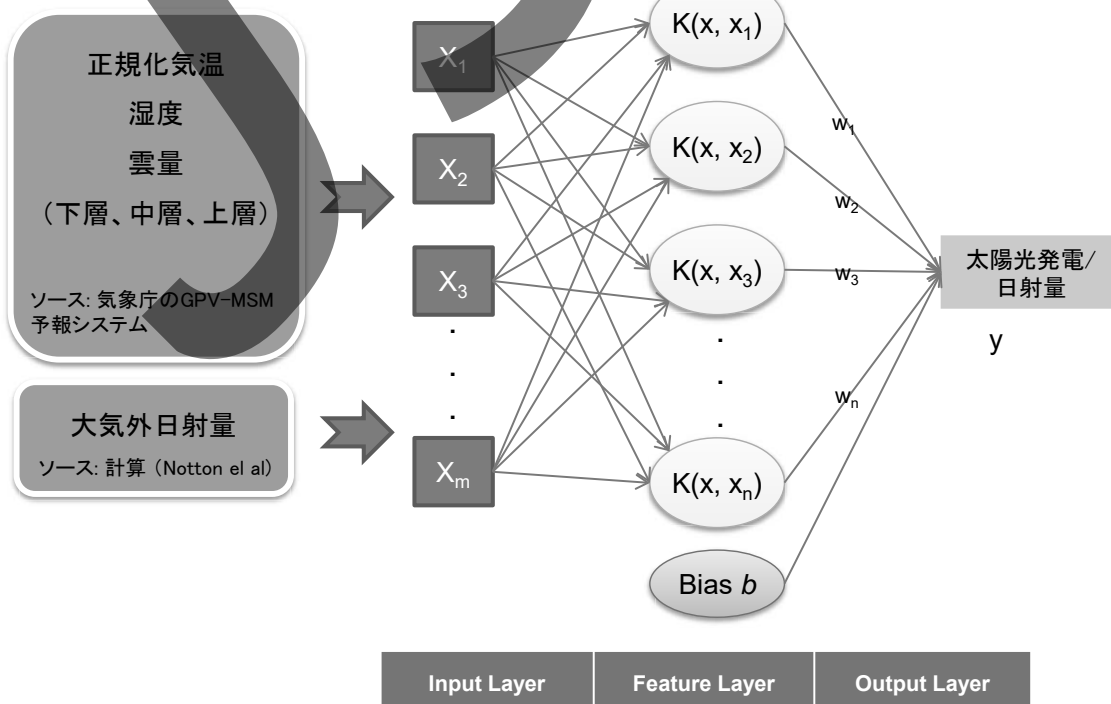
2Dで線形分離出来ない

3Dで線形分離出来る

Source: <http://rivasveld.github.io/images/oc-svm/visualization.gif>

# サポートベクターマシン

## サポートベクターマシンの設定



# 手法の比較

1

日射量予測の例  
(日本国内の25箇所)

予測手法の比較

2

発電量予測の例  
(響灘太陽光発電所)

ANN

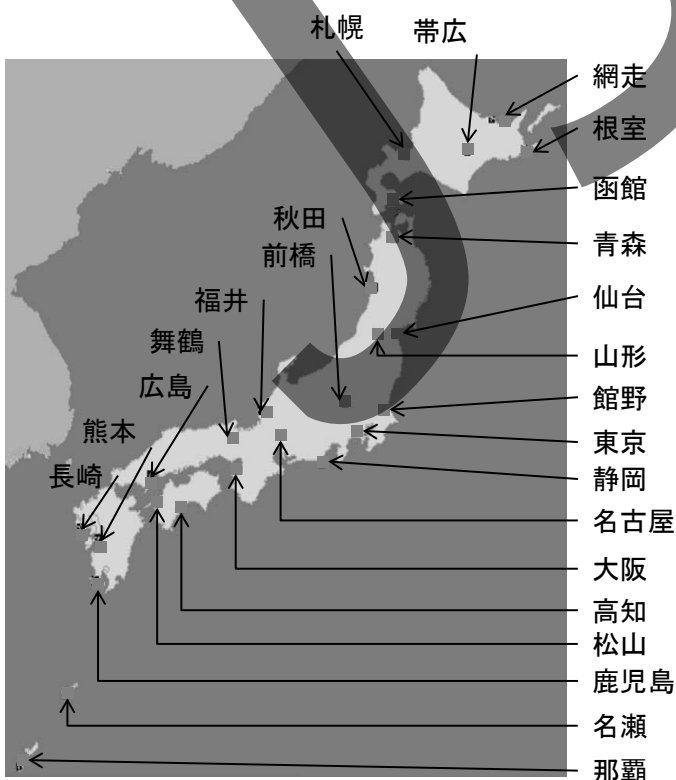
SVM

誤差逆伝播法  
多層ネットワーク  
専用活性化関数  
学習データサイズ60日間

予測手法による予測精度が  
どのように変動するか。

1

## Insolation Forecast for 25 Locations in Japan



### 予測の条件

箇所の数	25
予測期間	1年間(2008年) *時間毎5時から19迄
学習に利用されたデータ	60日間

\*一日の予測は過去の60日間のデータを利用した。

### 誤差

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (I_{fcs,i} - I_{msd,i})^2}$$

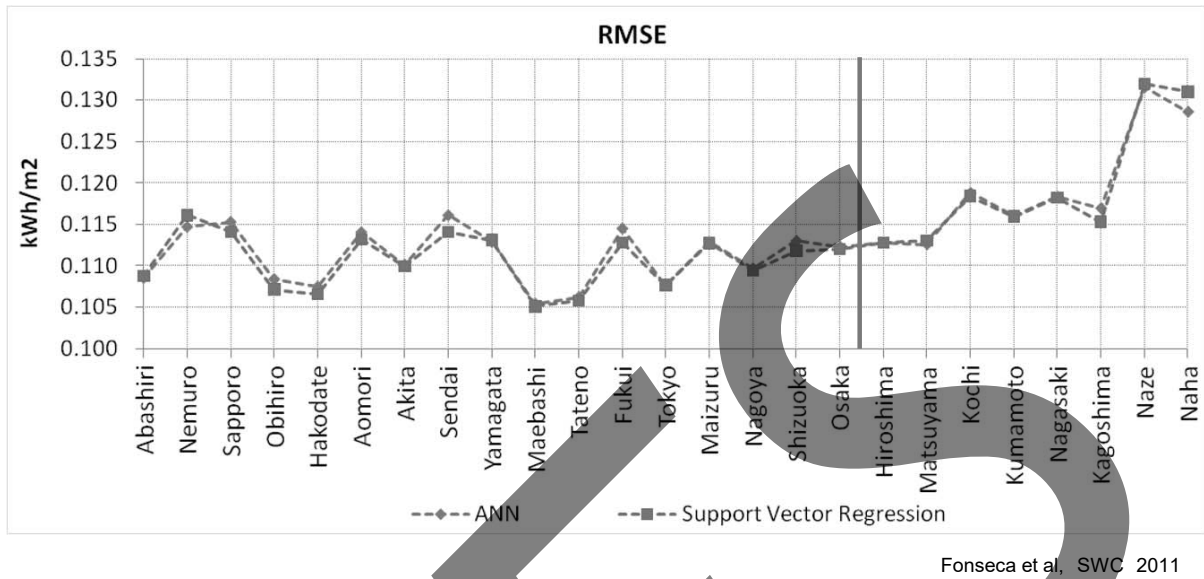
$$MAE = \frac{1}{N} \sum_{i=1}^N |I_{fcs,i} - I_{msd,i}|$$

$I_{fcs,i}$ : 予測日射量(kWh/m<sup>2</sup>);  
 $I_{msd,i}$ : 実測日射量(kWh/m<sup>2</sup>);  
N: 時間の数

1

# Results

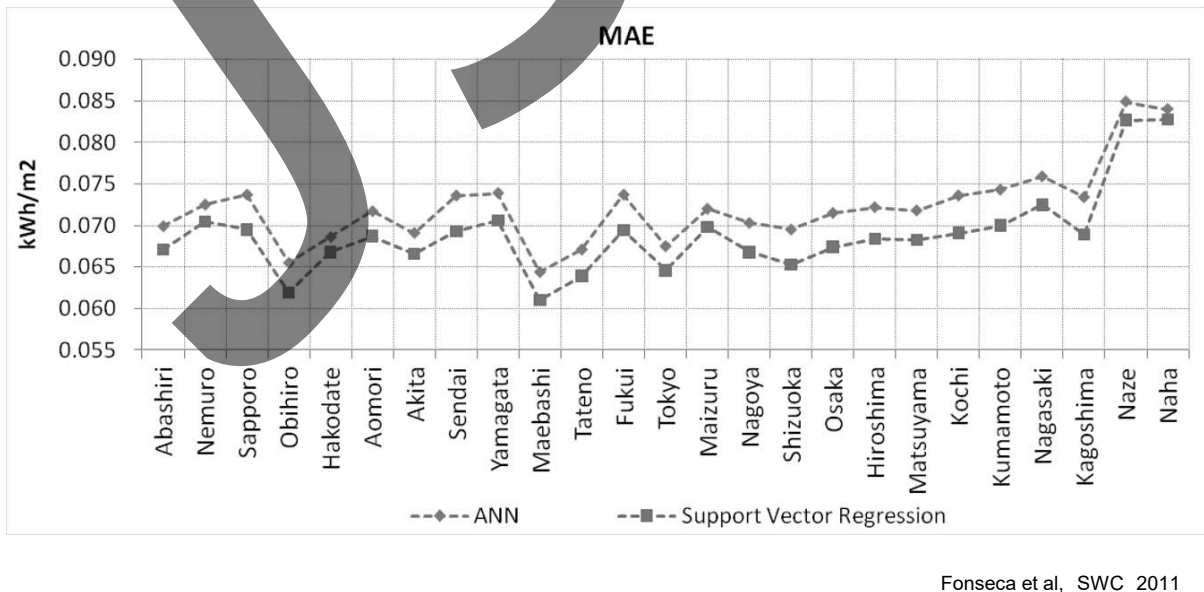
➔ 25箇所の一年間のRMSE



1

# Results

➔ 25箇所の一年間の絶対誤差



# PV Power Forecast (Hibikinada PV Power Plant)

2

## 発電所について

データ	値
緯度	33° 55' N
経度	130° 44' E
最大出力	1 MW(nominal)
太陽光モジュール	5600*
傾斜	20°

\*多結晶シリコン



## 予測条件について

データ	値
予測期間	1年(2009年)
予測種類	一時間毎(6時から19時迄)
訓練事例量	60日
予測時間	前日の18時

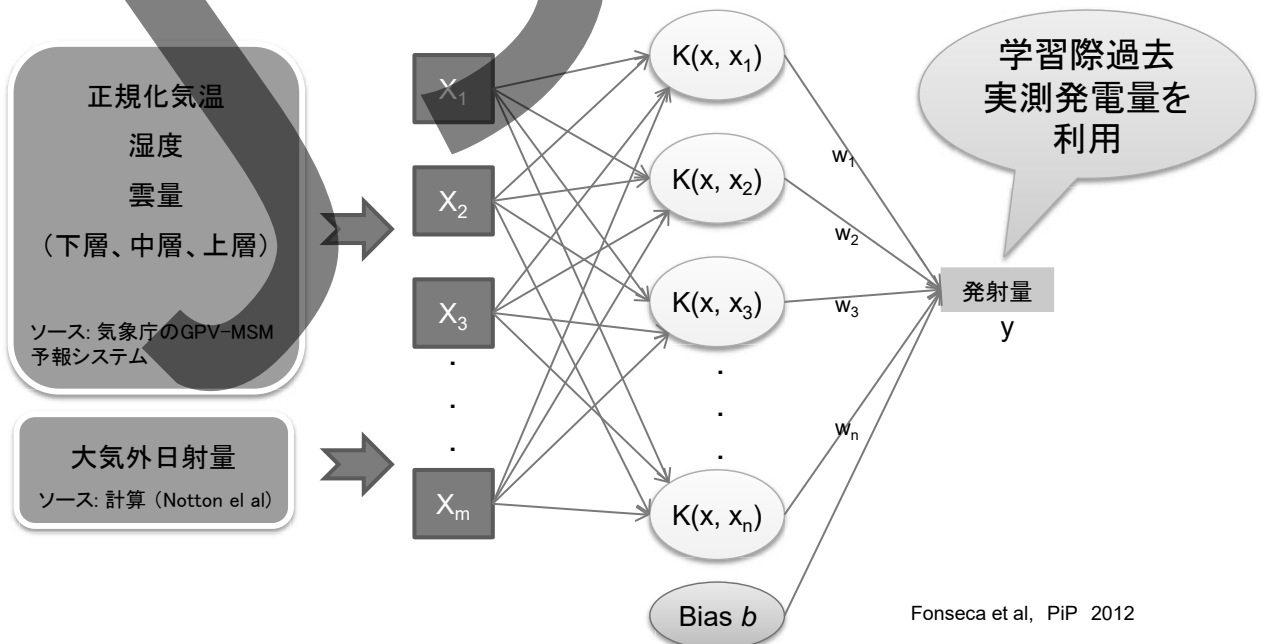
ソース JPOWER平成19年度 共同研究業務成果報告書

独立行政法人 産業技術総合研究所

# PV Power Forecast

2

## サポートベクターマシンの設定



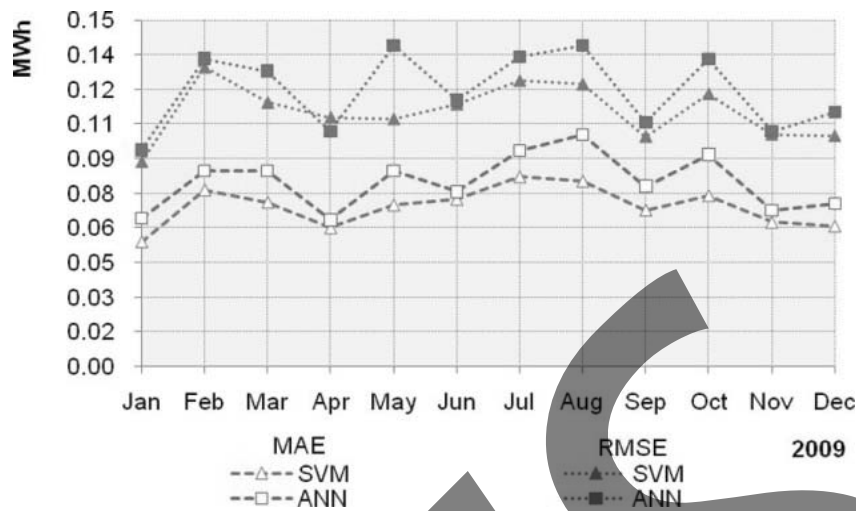
Input Layer

Feature Layer

Output Layer

独立行政法人 産業技術総合研究所

# Results



Fonseca et al., IEEE PVSC 2011

	MAE (MWh)	RMSE (MWh)
ANNの予測	0.080	0.1206
SVMの予測	0.069	0.1109
変動(ANNから)	-13%	-8%

独立行政法人 産業技術総合研究所

Table 1. ANN input parameters.

## Main Points

- 研究の結果によるSVMの予測精度がANNの予測精度より良いことが分かった。
- 両手法が同程度の予測RMSEを生じさせた。RMSEが大きい外れを示す計量なので予測をしがたい時にSVMがANNより良い効果があることを言えない。
- 然しながらSVMを用いた予測の絶対誤差がANNを用いた予測誤差より低かったので予測しがたい以外状況ではSVM用が予測に効果があった。

# Forecast Accuracy

日射量予測の例  
(日本国内の25箇所)

	最低値	最大値	日射計の精度
RMSE (kWh/m <sup>2</sup> )	0.105	0.135	±0.03 kWh/m <sup>2</sup>
MAE (kWh/m <sup>2</sup> )	0.060	0.085	

発電量予測の例  
(響灘発電所)

	最低値	最大出力
RMSE (MWh)	0.116	1 MWh
MAE (MWh)	0.069	

独立行政法人 産業技術総合研究所

## Improving the Forecast Method

予測手法の改善と実用化を向け次の話題を研究した。

- ◆ 学習データ量 (例 15日間から365日間迄)
- ◆ 学習データの種類(例 直前のデータ 対 類似があるデータ)
- ◆ SVMのカーネル関数の種類 (例 3つ種類)
- ◆ 手法の初期設定 (例 交差検定対単純なグリッド検索等)
- ◆ 予測時間の影響 (例 2時間前迄 対 25時間前迄)
- ◆ 入力変数の効果 (例 雲量等使うかどうか)
- ◆ 1日に1SVM 対 1時間に1SVM
- ◆ ...

独立行政法人 産業技術総合研究所

- 全国の太陽光発電予測 (FT-Data) 予測手法の検証
- 予測値の信頼空間の検討

## 太陽光発電電力量の予測 (FT データ)

地域による

	北海道	東北	関東	中部	関西	四国	中国	九州	沖縄
システムの数	8	18	151	132	111	27	46	89	4
比率	1.35%	3.1%	25.75%	22.5%	19%	4.6%	7.85%	15.18%	0.67%

北海道から沖縄まで586箇所 全国2010年の予測結果


地域による

北海道から沖縄まで756箇所 全国2009年の予測結果

	北海道	東北	関東	中部	関西	四国	中国	九州	沖縄
システムの数	14	19	194	172	123	33	77	120	4
比率	1.85%	2.5%	25.66%	22.76%	16.27%	4.35%	10.20%	15.88%	0.53%



# 太陽光発電電力量の予測 (FT データの処理)

## 太陽電池の種類による

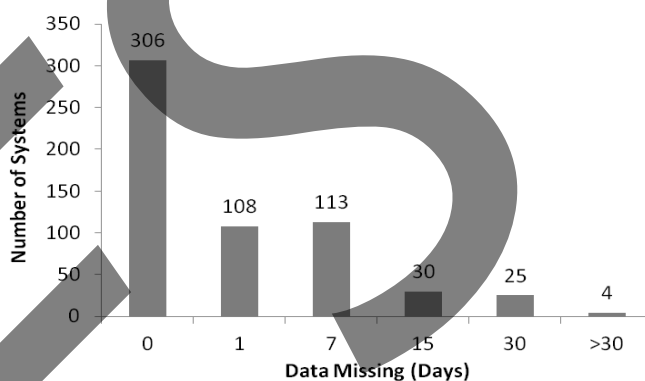


2009年

## 発電電力量欠側データ





2010年



独立行政法人 産業技術総合研究所

# ① 太陽光発電電力量の予測 (FTデータの処理)





■北海道 ■東北 ■関東 ■中部 ■関西 ■中国 ■四国 ■九州 ■沖縄

独立行政法人 産業技術総合研究所



# ① 太陽光発電電力量の予測 (FT データの処理)

平均 = 0.505 kWh/kWh\_avg

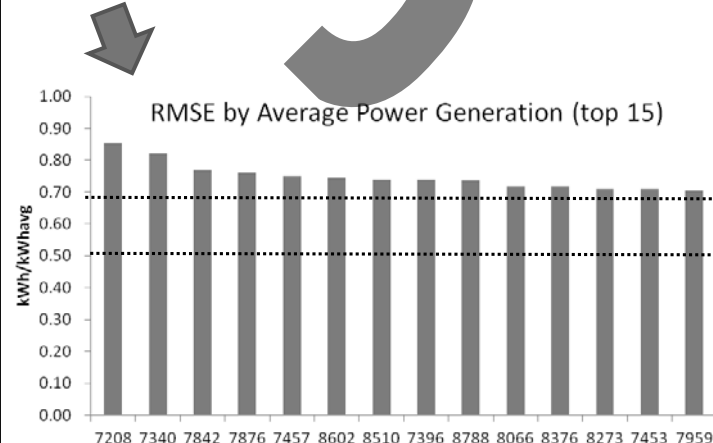



■北海道 ■東北 ■関東 ■中部 ■関西 ■中国 ■四国 ■九州 ■沖縄

平均 = 0.509 kWh/kWh\_avg

# ① いつ大きい外れが発生?


2009年の結果の分析



System ID	Location	Array Cap (kW)	Module Tilt	Module Orient	Capacity Factor (Avg 0.21)	Invalid days	Cell Type
7208	愛知県	10.00	11.3	S	0.18	0	多結晶
7340	北海道	10.02	43	SSE	0.19	0	多結晶
7842	岡山県	21.34	90/90	S	0.13	0	HIT
7876	長崎県	10.45	15	W	0.20	4	多結晶
7457	北海道	10.02	40	SSE	0.18	1	多結晶
8602	愛知県	67.20	90	S	0.13	9	単結晶
8510	埼玉県	10.02	10	SSE	0.17	0	多結晶
7396	北海道	10.00	60	SSW	0.19	0	多結晶
8788	長野県	10.08	50	W	0.20	3	多結晶
8066	兵庫県	33.18	2	E	0.09	3	単結晶
8376	東京都	10.04	90	S	0.16	1	単結晶
8273	神奈川県	10.40	20	S	0.17	0	多結晶
7453	新潟県	10.00	50	SSW	0.20	0	多結晶
7959	愛媛県	20.88	90	S	0.15	0	多結晶
8542	北海道	10.02	50	S	0.22	0	多結晶

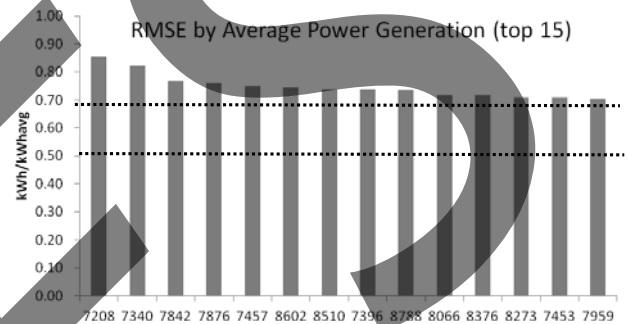
# ① 太陽光発電電力量の予測 (FT データの処理)

## 2009年の結果の分析




System ID	Location	Array Cap (kW)	Module Tilt	Module Orient	Capacity Factor (Avg 0.21)	Invalid days	Cell Type
7340	北海道	10.02	43	SSE	0.19	0	多結晶
7842	岡山県	21.34	90 90	S	0.13	0	HIT
7876	長崎県	10.45	15	W	0.20	4	多結晶
7457	北海道	10.02	40	SSE	0.18	1	多結晶
8602	愛知県	67.20	90	S	0.13	9	単結晶
8510	埼玉県	10.02	10	SSE	0.17	0	多結晶
7396	北海道	10.00	60	SSW	0.19	0	多結晶
8788	長野県	10.08	50	W	0.20	3	多結晶
8066	兵庫県	33.18	2	E	0.09	3	単結晶
8376	東京都	10.04	90	S	0.16	1	単結晶
8273	神奈川県	10.40	20	S	0.17	0	多結晶
7453	新潟県	10.00	50	SSW	0.20	0	多結晶
7959	愛媛県	20.88	90	S	0.15	0	多結晶
8542	北海道	10.02	50	S	0.22	0	多結晶

最大誤差の事例の中モジュール傾斜角が40度以上システムが多いことが分かった。



# ① 太陽光発電電力量の予測 (FT データの処理)

## 2009年の結果の分析



## これまでの考察 2

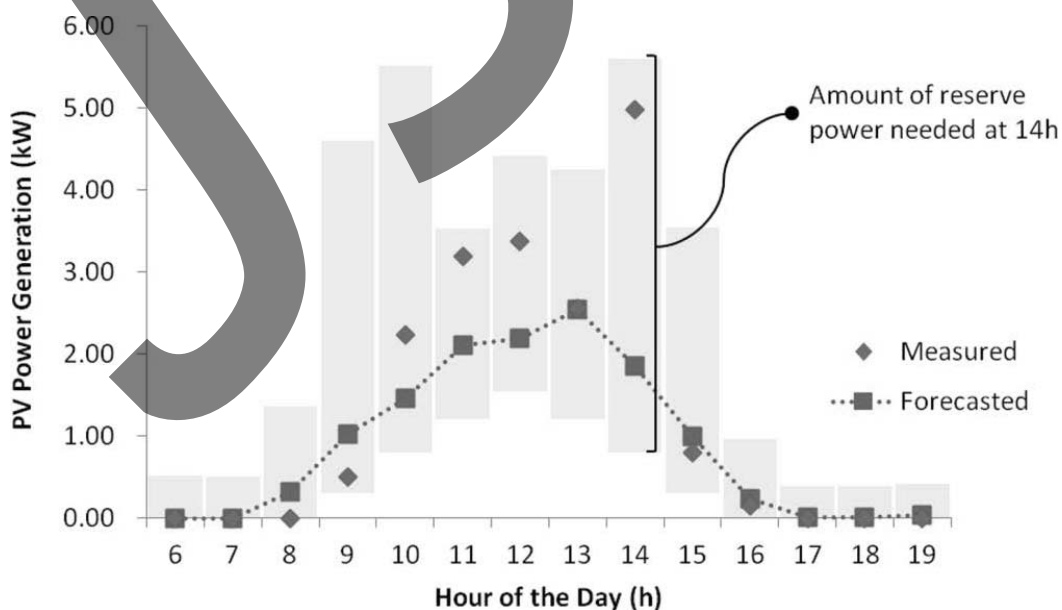
- ✓ サポートベクターマシンを利用した分散太陽光発電予測手法を検証して予測精度を確認した。
- ✓ 様々セルの種類や設置状況などがあっても安定な精度で予測できることが分かった。
- ✓ それでも以外な設置状況の場合個別な対応がひつようです。

予測精度がいくら改善しても発電量が天気状況に依存しているので予測値だけではなくその値の信頼性を評価出来る情報も求められる。

そこで信頼空間の情報が役に立つ。


## 予測値の信頼空間の検討

予測値に対して実測値はどこからどこまで変動することが期待できる？



# 予測値の信頼空間の検討

提案 → 訓練事例データから信頼空間を推定  
 データから予測対象の時間と同じ時間が有る事例のみ利用。



## 研究報告 — 予測値の信頼空間の検討

今回の提案 → 訓練事例データから信頼空間を推定

- ① 予測する時間と同じく過去時間の予測誤差60時間を選択して予測誤差の分布による信頼空間を推定する。
- ② 予測誤差の分布がラプラセ分布として考慮したら偏差  $\sigma$  が次のような計算できる。

$$\sigma = \frac{1}{l} \sum_{i=1}^l |\text{err}_i|$$

- ③ 偏差を計算したらラプラセ分布による信頼空間が次のような計算する。



$$\sigma \ln(2s), -\sigma \ln(2s)$$

$$\text{prob} = 1 - 2s$$

➤ 予測値の信頼空間の検討

研究対象

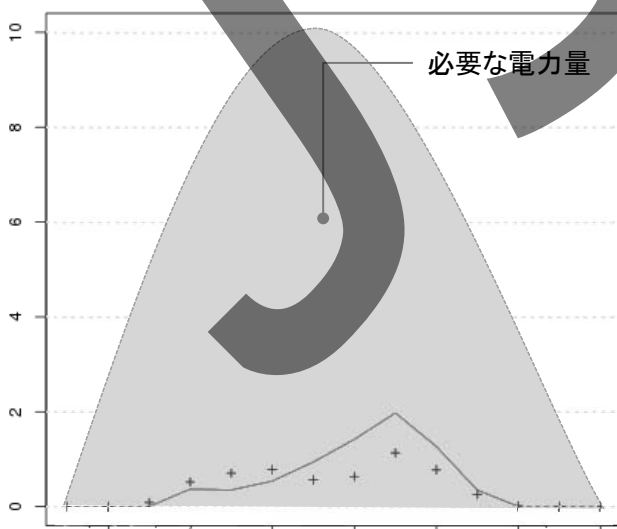
太陽電池の種類	多結晶
アレイ容量 (kW)	10
モジュールの傾斜角	60
モジュールの方向	南東
設置場所	旭川
変換効率	13.98%



独立行政法人 産業技術総合研究所

➤ 予測値の信頼空間の検討

手法1 (基準) 全て外れを対応する為毎時間傾斜面大気外日射量の基に計算した発電量を準備。



毎時間の発電電力量を計算する為に Mellit&Pavan, 2010のモデルを用いた。

$$P = A \cdot \eta_{pv} \cdot \eta_{bos} \cdot G$$

P-発電電力量 (kWh)  
 $\eta_{pv}$ -変換効率  $\eta_{bos}$ -システムバランスの効率  
 A-アレイの面積 (m<sup>2</sup>) G-日射量

事例において  
 アレイ面積 71.5176m<sup>2</sup> 変換効率 13.98%  
 $\eta_{bos}$ - 0.7

検証データに於いて誤差の100%を対応する為PIに1.67kWhを足してそして最大値が10.5kWhにした。

➤ 予測値の信頼空間の検討 (Fonseca et al, ISAP2013)

		Method 1	Method 2	Reference
A	Expected forecast intervals coverage	95%	95%	-
B	Effective coverage	89%	94.4%	100%
C	Hours not covered in 1 year of forecasts	559	287	0
D	Power not covered in 1 year (kWh)	582.3	110.6	0
E	Reserve power to achieved the effective coverage (kWh)	16959	19540	31256
F	Total hours forecasted	5096	5096	-
G	Total Power Generated (kWh)	9056	9056	-
H	Forecasts' RMSE (kWh)	1.369	1.369	-

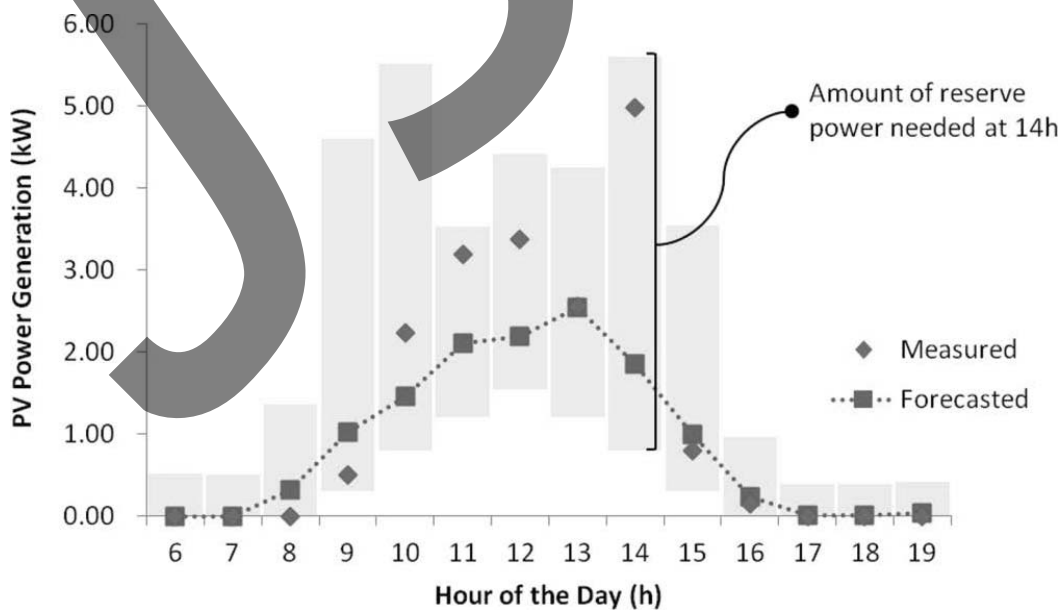
- With Method 1 the expected confidence level was not achieved.
- To cover all errors with the reference method more than 3 times the total PV power generated is required.

簡単に信頼空間を確報手法を提案しその手法の有効性を確認できた。

それで現在太陽光発電予測値だけではなくその予測の信頼性の情報も提供できる。

予測値の信頼空間の検討

理想的にある信頼係数に対して最低信頼空間が望ましい。



然し信頼空間は予測誤差の変動を現しているので変動激しかったら空間が大きくなる。

## これまでの考察 3

- ① 研究を始めてからこれまで予測精度が徐々に改善することが出来た。
- ② 現在, SVMを利用する手法を開発してきて日本に有る予測手法の中最先端水準予測精度を達すことも出来た。
- ③ 太陽光発電予測値以外に信頼空間情報を計算する機能予測手法に追加し高い信頼係数でその情報も提供も既にできる。
- ④ 然し予測精度の改善がまだ必要なので研究を進めなければならない。
- ⑤ 信頼空間も改善余地があるので別計算手法することも必要です。
- ⑥ 開発してきた予測手法と確保できた成果も公開されるので日本での太陽発電予測精度の参照ベースになりより予測手法の開発も推進できることが期待される。

初公開 一層発電量予測精度の改善

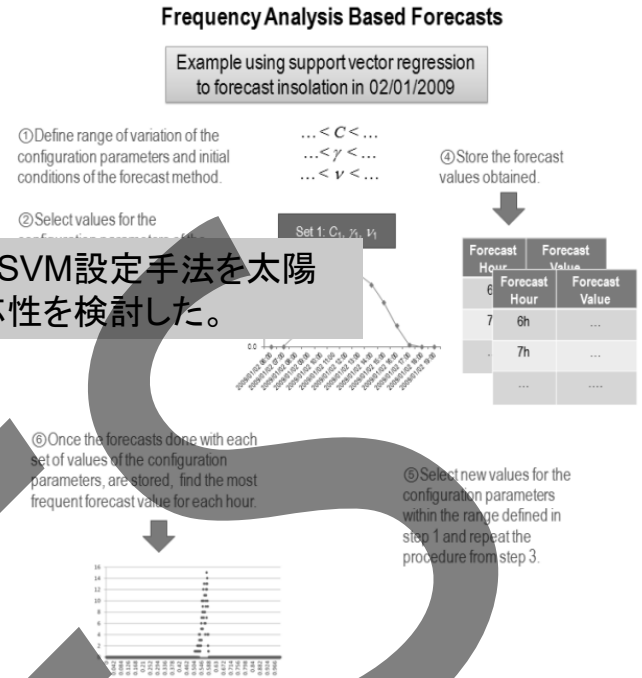
(時間があれば...)

初公開 一層発電量予測精度改善

① 最初にSVMの設定を行う為次の手順を利用した。



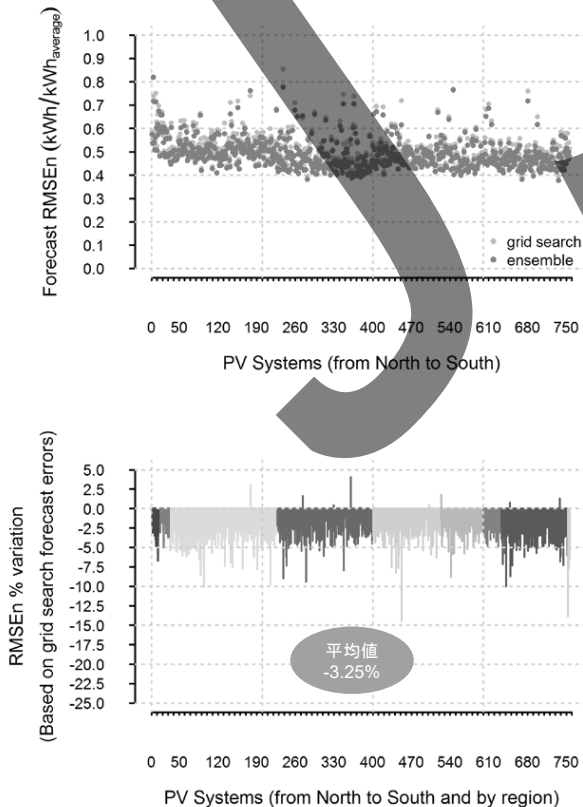
② 処理時間と必要なデータ量を縮小為次の提案をした。



日射量予測問題に提案したSVM設定手法を太陽光発電の問題に採用して適応性を検討した。

今回提案した手法が発電量の問題に採用し検証を行った。

2009年





### これまでの考察 3

