

# **Eine *Machine Learning* Demo**

10-Tage Solarstrahlungsprognose  
beruhend auf einer Wettervorhersage

Otmar Mak    Technischer Mathematiker    A-9074 Keutschach am See

# Solarstrahlungsprognose

## verwendete Daten für die Demonstration:

Stündliche Wetterdaten für ausgewählte Standorte (historische and Prognosen)  
Europa: Klagenfurt, Wien, Frankfurt a.M., *Trainingszeitraum: 2004-2005*  
USA: Boston, MA (2004-2010); Elizabeth City, N.C. (2005-2007)  
Historische Solarstrahlungsdaten (stündlich, für *dieselben Trainingszeiträume*)

## Datenquellen:

Wetterdaten: [www.wunderground.com](http://www.wunderground.com)

Solarstrahlungsdaten:

Europa: SODA/Helioclim (Satelliten-basierte Daten)

USA: NSRDB/METSTAT für Boston (Satelliten-basierte Daten),  
University of Elizabeth City (Bodenstationsmessdaten)

# Solarstrahlungsprognosen

Computermodell geringer Komplexität mit minimalen Datenerfordernissen

## *Input-Daten (stündlich):*

Lufttemperatur	[°C]
Taupunkttemperatur	[°C]
Luftdruck	[hPa]
Luftfeuchtigkeit	[%]
Windgeschwindigkeit	[km/h]
Windrichtung	[Grad]
Wetterbedingungen	[verbal]

## *physikalische Parameter:*

Sonnenstandshöhe  
Geoposition/Zeitzone  
Standort-spezifischer Turbiditäts-Parameter  
Seehöhe

# Solarstrahlungsprognosen

Computervermodell mit minimalen Datenerfordernissen

*Input-Daten (stündlich) - Datenaufbereitung:*

Verbale Klassifikationen von **Wetterbedingungen**

(z.B. wolkenlos, bewölkt, teilweise bewölkt,  
bedeckt, Regen, Gewitter, ... )

werden übersetzt  
in einen numerischen Raum geringer Dimensionalität

# Solarstrahlungsprognosen

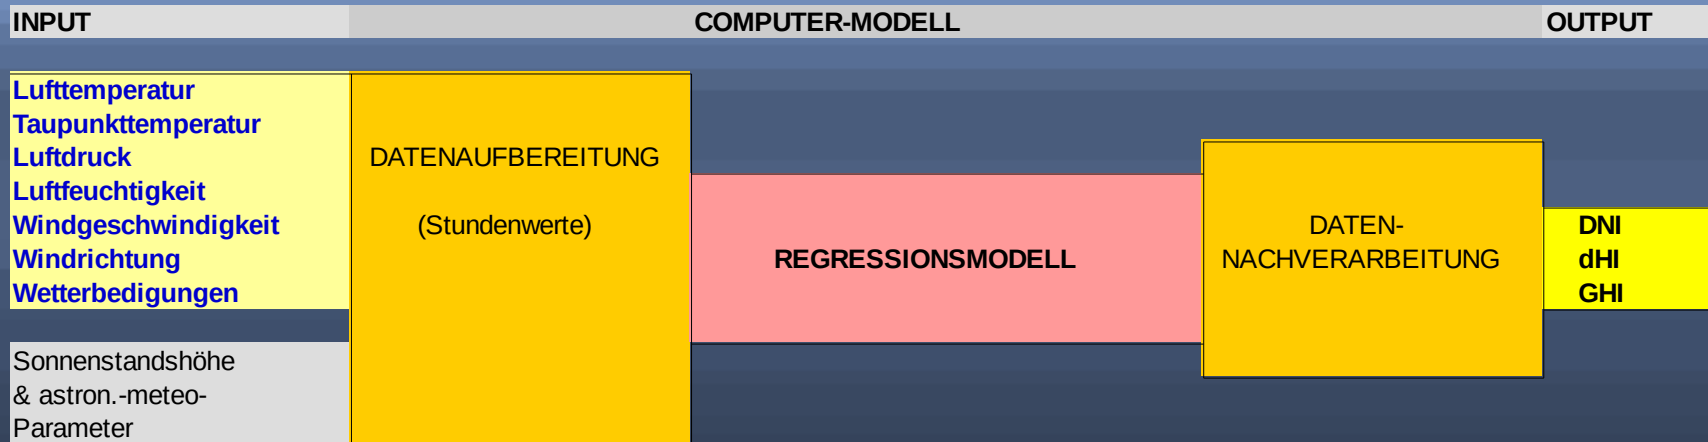
## Output (stündlich):

Direktnormalstrahlung	(DNI)	[W/m <sup>2</sup> ]
Diffuse Horizontalstrahlung	(dHI)	[W/m <sup>2</sup> ]
Global Horizontalstrahlung	(GHI)	[W/m <sup>2</sup> ]

(W/m<sup>2</sup> als stündliche Mittelwerte)

entsprechend dem Zeitraum der Wettervorhersage,  
z.B. für die nächsten 10 Tage

# Solarstrahlungsprognosen



Das Regressionsmodell wird anhand historischer Daten trainiert


# Solarstrahlungsprognosen

## Typische Alternativen für Regressionsmodelle:

- \* Künstliche Neuronale Netzwerke (NN)
- \* Nichtparametrische Regression (NPR)
- \* Random Forests (RF)
- \* Support Vector Regression (SVR)

# Solarstrahlungsprognosen

Die Güte der Einzelstandortprognosen ist vergleichbar mit bester Praxis



# Solarstrahlungsprognosen

Die Güte der Einzelstandortprognosen  
ist vergleichbar mit bester Praxis

Literaturhinweise für Qualitätsvergleiche:


**IFS**     Computermodell des *European Center for Medium-Range  
Weather Forecasts*

**SKA**     High-Resolution-Limited-Area-Modell des *Danish Meteorological  
Institute*

Manajit Sengupta, Aron Habte, Sarah Kurtz,  
Aron Dobos, Stefan Wilbert, et al.:  
*Best Practices Handbook for the Collection and Use of Solar Resource Data  
for Solar Energy Applications*. [Research Report]  
Technical Report NREL/TP-5D00-63112,  
National Renewable Energy Laboratory. 2015, 236 p.

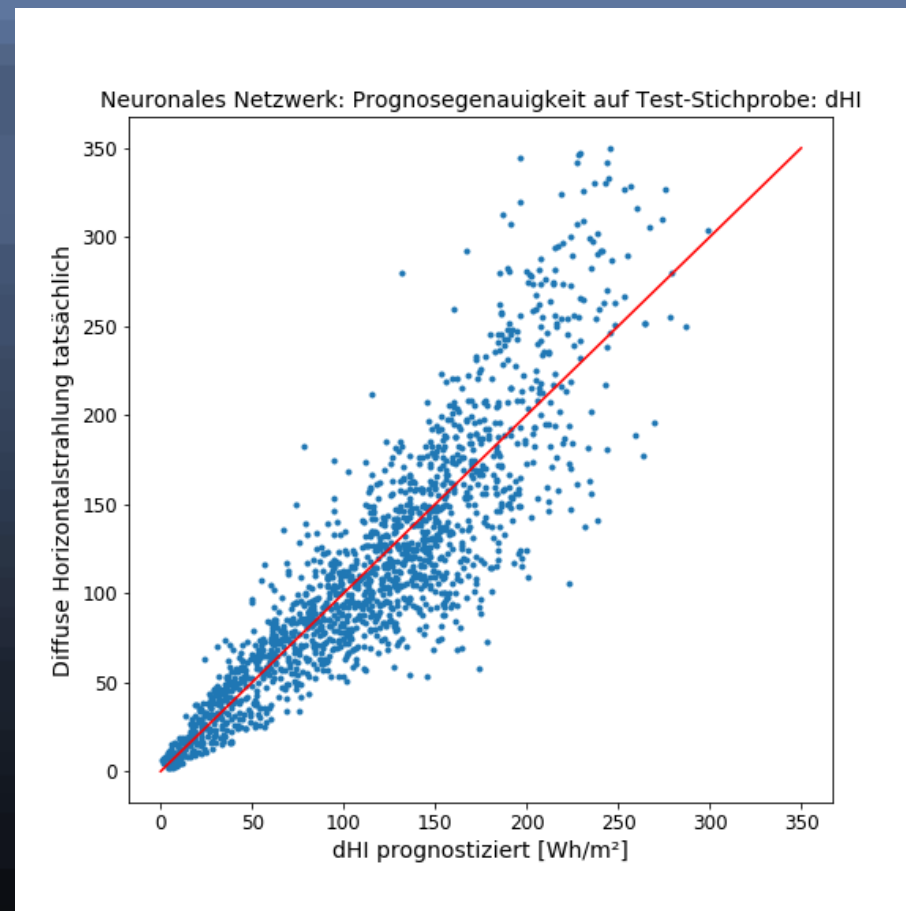
# Solarstrahlungsprognosen

Die Schätzgenauigkeit wird evaluiert anhand (zufälliger) Test-Stichproben aus historischen Daten




# Solarstrahlungsprognosen

Die Schätzgenauigkeit wird evaluiert anhand (zufälliger) Test-Stichproben



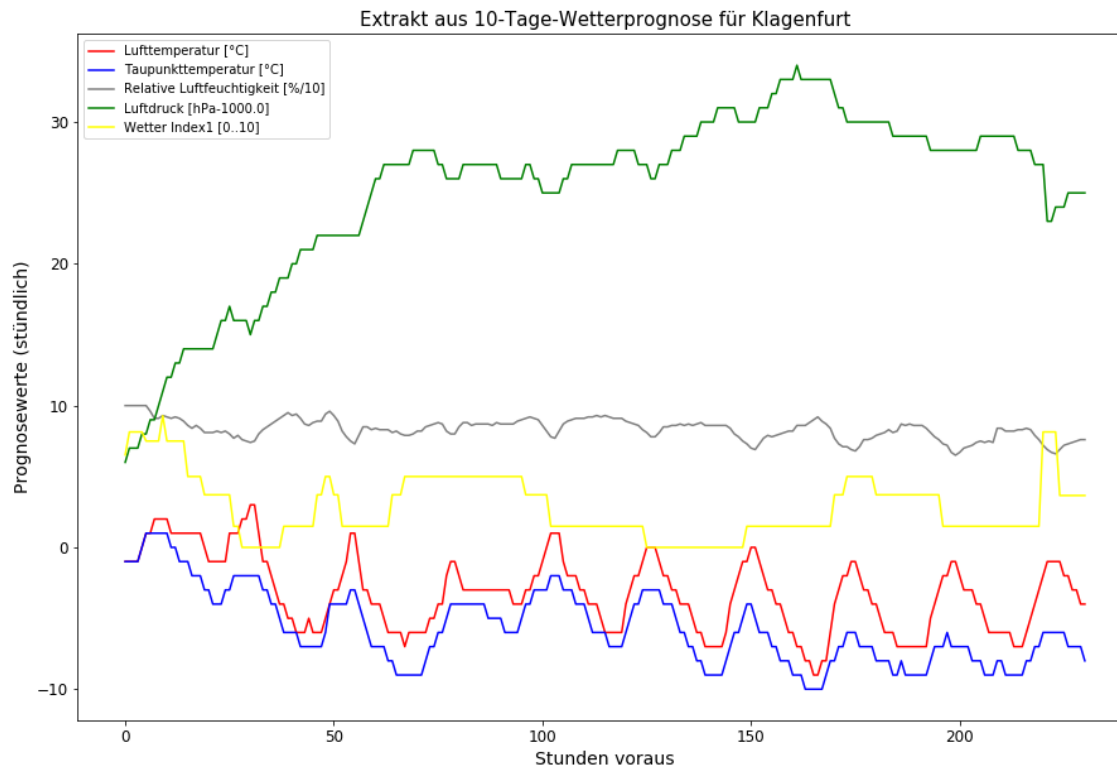
# Solarstrahlungsprognosen

Die Schätzgenauigkeit wird evaluiert anhand (zufälliger) Test-Stichproben



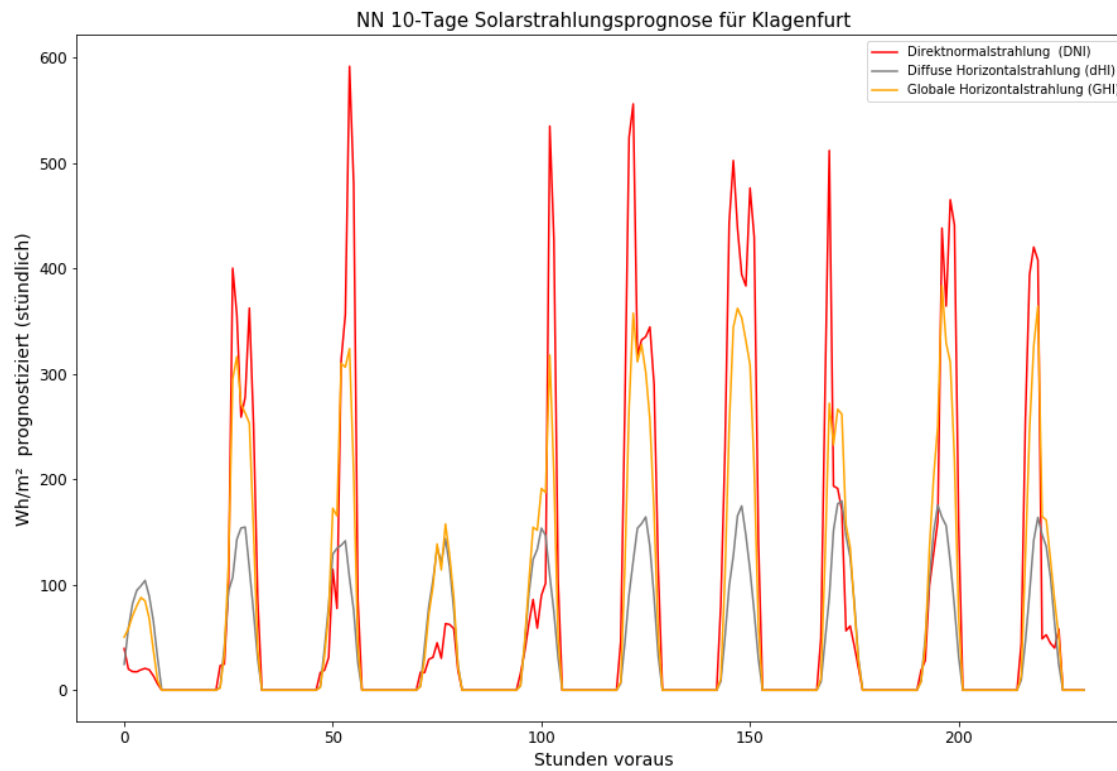
# Solarstrahlungsprognosen

Ein Prognosebeispiel (10-Tage-Demo für Klagenfurt)



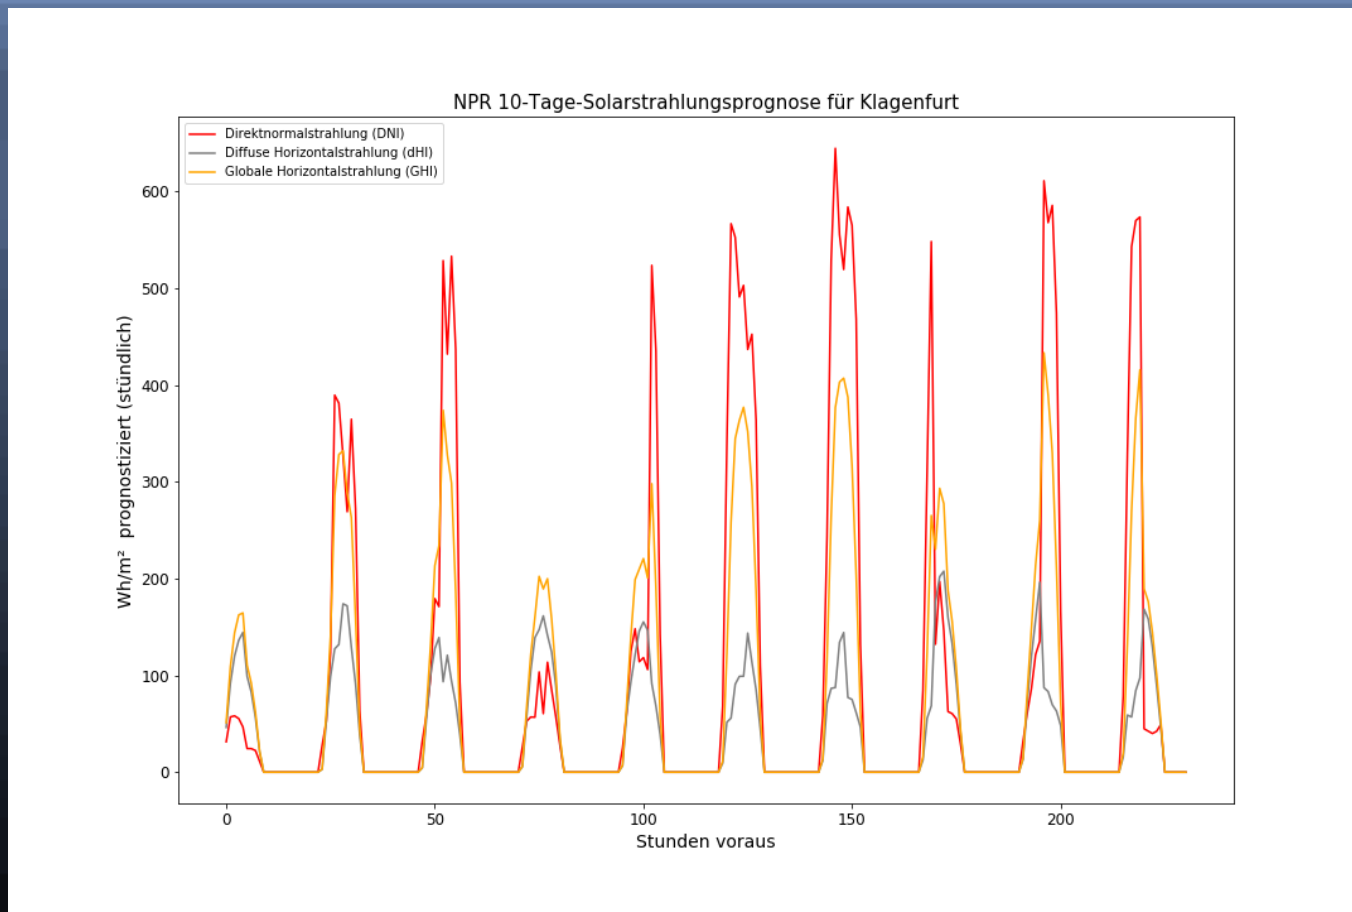
# Solarstrahlungsprognosen

Ein Prognosebeispiel (10-Tage-Demo für Klagenfurt)



# Solarstrahlungsprognosen

Ein Prognosebeispiel (10-Tage-Demo für Klagenfurt)



# Solarstrahlungsprognosen

## Beurteilung von Prognosefehlern:

**Die Genauigkeit der Solarstrahlungsprognose hängt ab von der Genauigkeit der Wettervorhersage:** die genannten RMSE-Schätzwerte für Einzelstandortprognosen mit den demonstrierten NN- und NPR-Modellen gelten nur, wenn die Wetterprognose *korrekt* ist.

Verbesserungspotentiale wie Korrekturen aufgrund von Modell-Outputstatistiken (MOS) wurden nicht benützt.

Noch größere Verbesserungen sind erreichbar durch **regionale Kombination von Prognosen für mehrere Standorte** durch statistischen Fehlerausgleich; weiters durch **Daten höherer Qualität**, z.B. zu Wolkenbildung und -bewegung, höhere zeitliche und räumliche Auflösung der Daten, Bodenmessdaten etc.

# Solarstrahlungsprognosen

## Beurteilung von Prognosefehlern:

**beträchtliche Verbesserungen sind noch erzielbar**

- \* auch mittels **mathematischer Modellen von höherer Komplexität**, vgl. z.B. Mohana Alanazi, Mohsen Mahoor, Amin Khodaei: *Two-Stage Hybrid Day-Ahead Solar Forecasting (2017)*, University of Denver, USA  
mit berichteten RMSE-Werten für GHI bei 10% und darunter für den Standort Denver, (aber mit anderen Annahmen als hier vorausgesetzt zur Verfügbarkeit von Solarstrahlungsdaten für Prognosen)
- \* bei **Kurzfristprognosen** (5min -30min voraus) mittels *sky imaging* (Univ. of California San Diego, Center for Energy Research, vgl. NREL Best Practices Handbook, p.173 )

# **Eine *Machine Learning* Demo: Solarstrahlungsprognosen**

Copyright (C) 2018 Otmar Mak, Keutschach am See,  
Österreich

Kontakt:  
Ingenieurbüro Dr. Otmar Mak

[Nutzungsbedingungen](#)