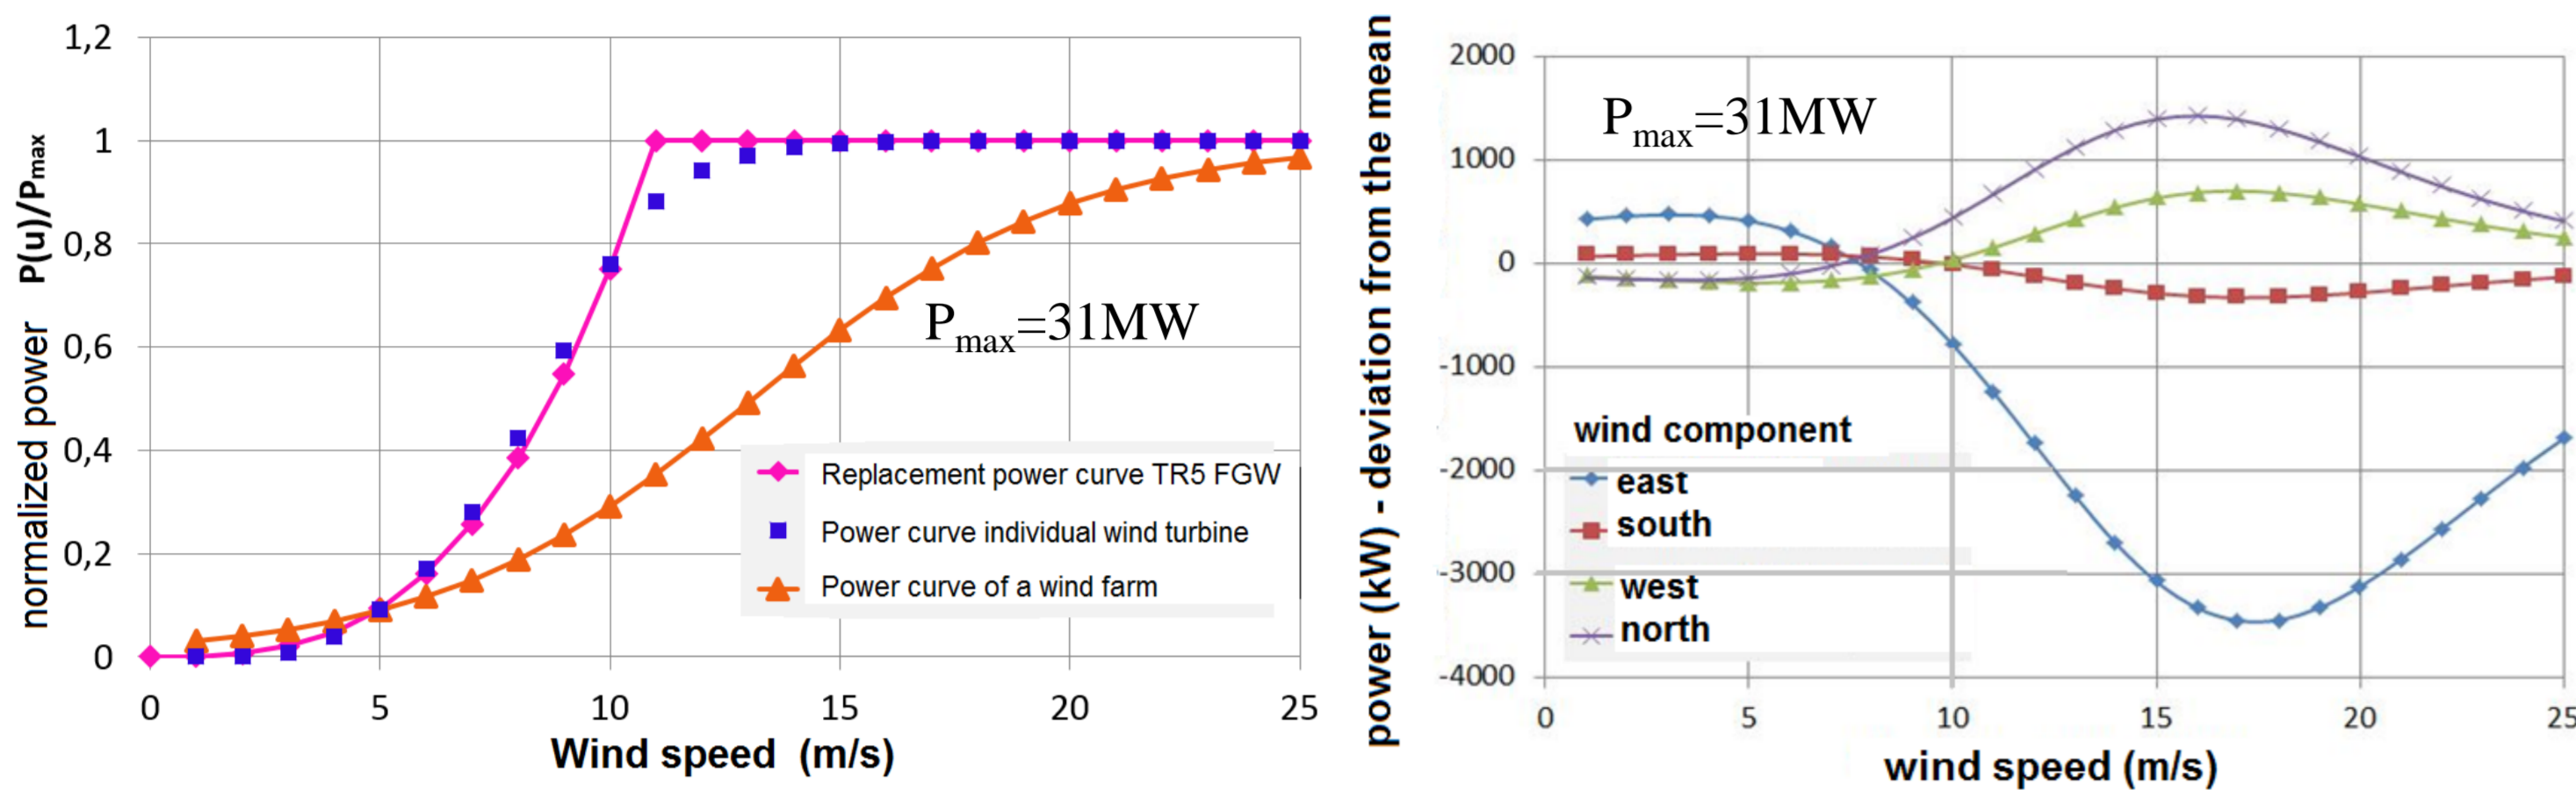


## Motivation

Die durch Windenergieanlagen bzw. Solaranlagen in einer bestimmten Region erzeugte elektrische Energie wird an Netzübertragungspunkten zusammengeführt und von dort im Netz verteilt. Die an diesen Punkten eingespeiste Energie unterliegt – obwohl sie aus einer größeren Region stammt – einer zeitlichen Variabilität, die auf die veränderlichen Wetterbedingungen (Wind- und Globalstrahlungsangebot) zurückgeht. Am Beispiel eines Windparks wird hier gezeigt, dass es für eine Leistungsprognose günstig ist, alle an einem Netzübertragungspunkt zusammengeführten Windparks in einer Leistungskennlinie zu erfassen, bestimmten Regionen zuzuordnen und in Abhängigkeit von der Windrichtung in die Prognose einzubeziehen. Für die Prognose des Energieertrages von PV-Anlagen ist es vorteilhaft eine zeitveränderliche Aussage zur wechselnden Bewölkung aus der regionalen Inhomogenität der Globalstrahlungsvorhersage zu generieren. Beide Einflüsse (regionalisierte Leistungskennlinien zusammengefasster Windparks und der Effekt wechselnder Bewölkung auf Solaranlagen) sind systematischer Natur und können in ein Prognoseverfahren einbezogen werden, das auf einem künstlichen neuronalen Netz (KNN) beruht.

## LEISTUNGSKENNLINIE EINE WINDPARKS



### Typische Leistungskennlinien

- Ersatzleistungskennlinie nach TR5 FGW e.V., 2013
- Leistungskennlinie einer individuellen Windturbine
- Leistungskennlinie eines Windparks ermittelt am Netzübergangspunkt (Bsp. Windpark 31MW)

### Funktion zur analytischen Darstellung der Leistungskennlinien für einen Windpark:

$$\frac{P(u)}{P_{max}} = \left( \exp\left(-\frac{u-u_0}{L_u}\right) + 1 \right)^{-1}$$

$P_{max}$  : installierte Leistung (Maximum)

$P(u)$  : Leistungsabgabe

$u$  : Windgeschwindigkeit in Nabenhöhe

→  $u_0$  und  $L_u$  müssen bestimmt werden


Mit diesen Parametern kann überprüft werden, ob das für die Ertragsprognose verwendete neuronale Netz diese Parameter nach einer ‚Trainingsphase‘ reproduzieren kann.

### Abweichung von der mittleren Leistungsabgabe für verschiedene Windrichtungssektoren ( $P_{max}=31MW$ )

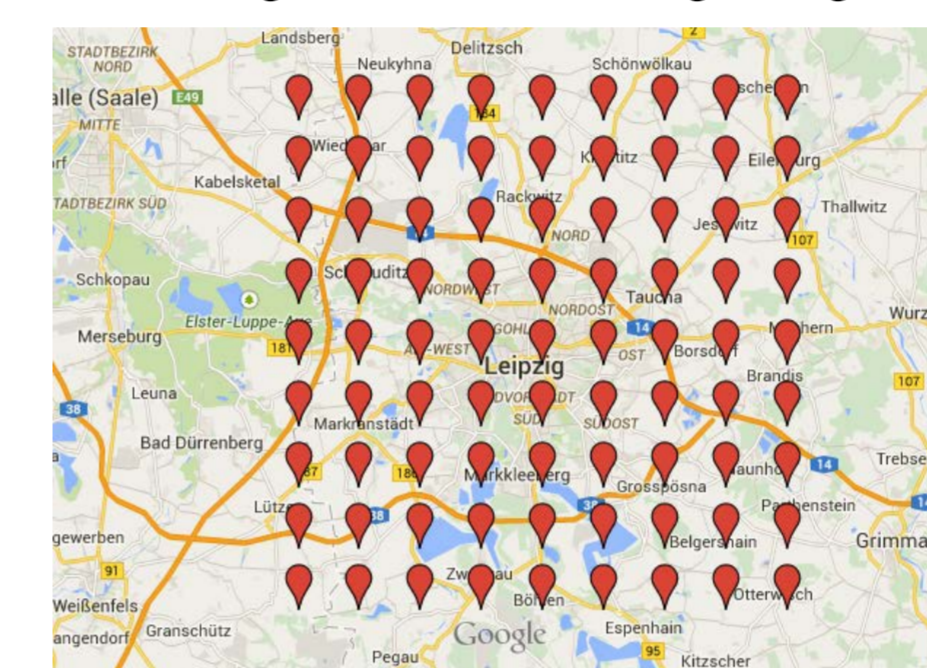
Tab.: Anpassung der Parameter  $u_0$  und  $L_u$  an die verschiedenen Windrichtungssektoren

Wind farm (31 MW)	$u_0$ (m/s)	$L_u$ (m/s)
Farm 1 total	13.3	3.6
North	12.8	3.3
East	14.7	4.5
South	13.4	3.7
West	13.1	3.4

## DURCHBROCHENE BEWÖLKUNG UND PHOTOVOLTAIK-ERTRAG



Beispiel für die Leistungsabgabe einer PV Anlage an einem sonnigen und an einem Tag mit durchbrochener Bewölkung. Die Leistungsabgabe ist am wolkenigen Tag als Folge des ‚Broken Cloud Effekts‘ und der dabei niedrigeren Modultemperatur zeitweilig höher als an sonnigen Tagen.



- Links: WRF-Modell 9x9 Gitterpunkte in der Umgebung einer PV-Anlage, Gitterweite 4km
- Rechts: Globalstrahlung mit WRF berechnet für die N=81 Gitterpunkte.

Der hier berechnete Inhomogenitätsindex  $\Pi=787W/m^2$  charakterisiert die veränderliche Struktur des Globalstrahlungsfeldes besser als die einfache Streuung  $\sigma=261.9 W/m^2$ .

### Inhomogenitäts-Index ( $\Pi$ ):

$$\Pi = \frac{1}{(\sqrt{N}-2)^2} \sum_{i=1}^{N-2} k_i$$

$$\text{mit: } k_i = |G_i - G_{i-1}| + |G_i - G_{i+1}| + |G_i - G_{i-\sqrt{N}}| + |G_i - G_{i+\sqrt{N}}|$$

Mit diesem Parameter gelingt es dem neuronalen Netz den ‚Broken Cloud Effekt‘ zu quantifizieren:

## WIND ENERGIE

NWP (numerische Wettervorhersage):

Meteorologische Informationen (u.a.):

$I_1$ : hor. Windgeschwindigkeit

$I_2$ : Windrichtung

$I_3$ : Lufttemperatur

Windpark-Charakteristik ( $I_4$ ):

• installierte Leistung  $P_{max}$

• Nabenhöhe

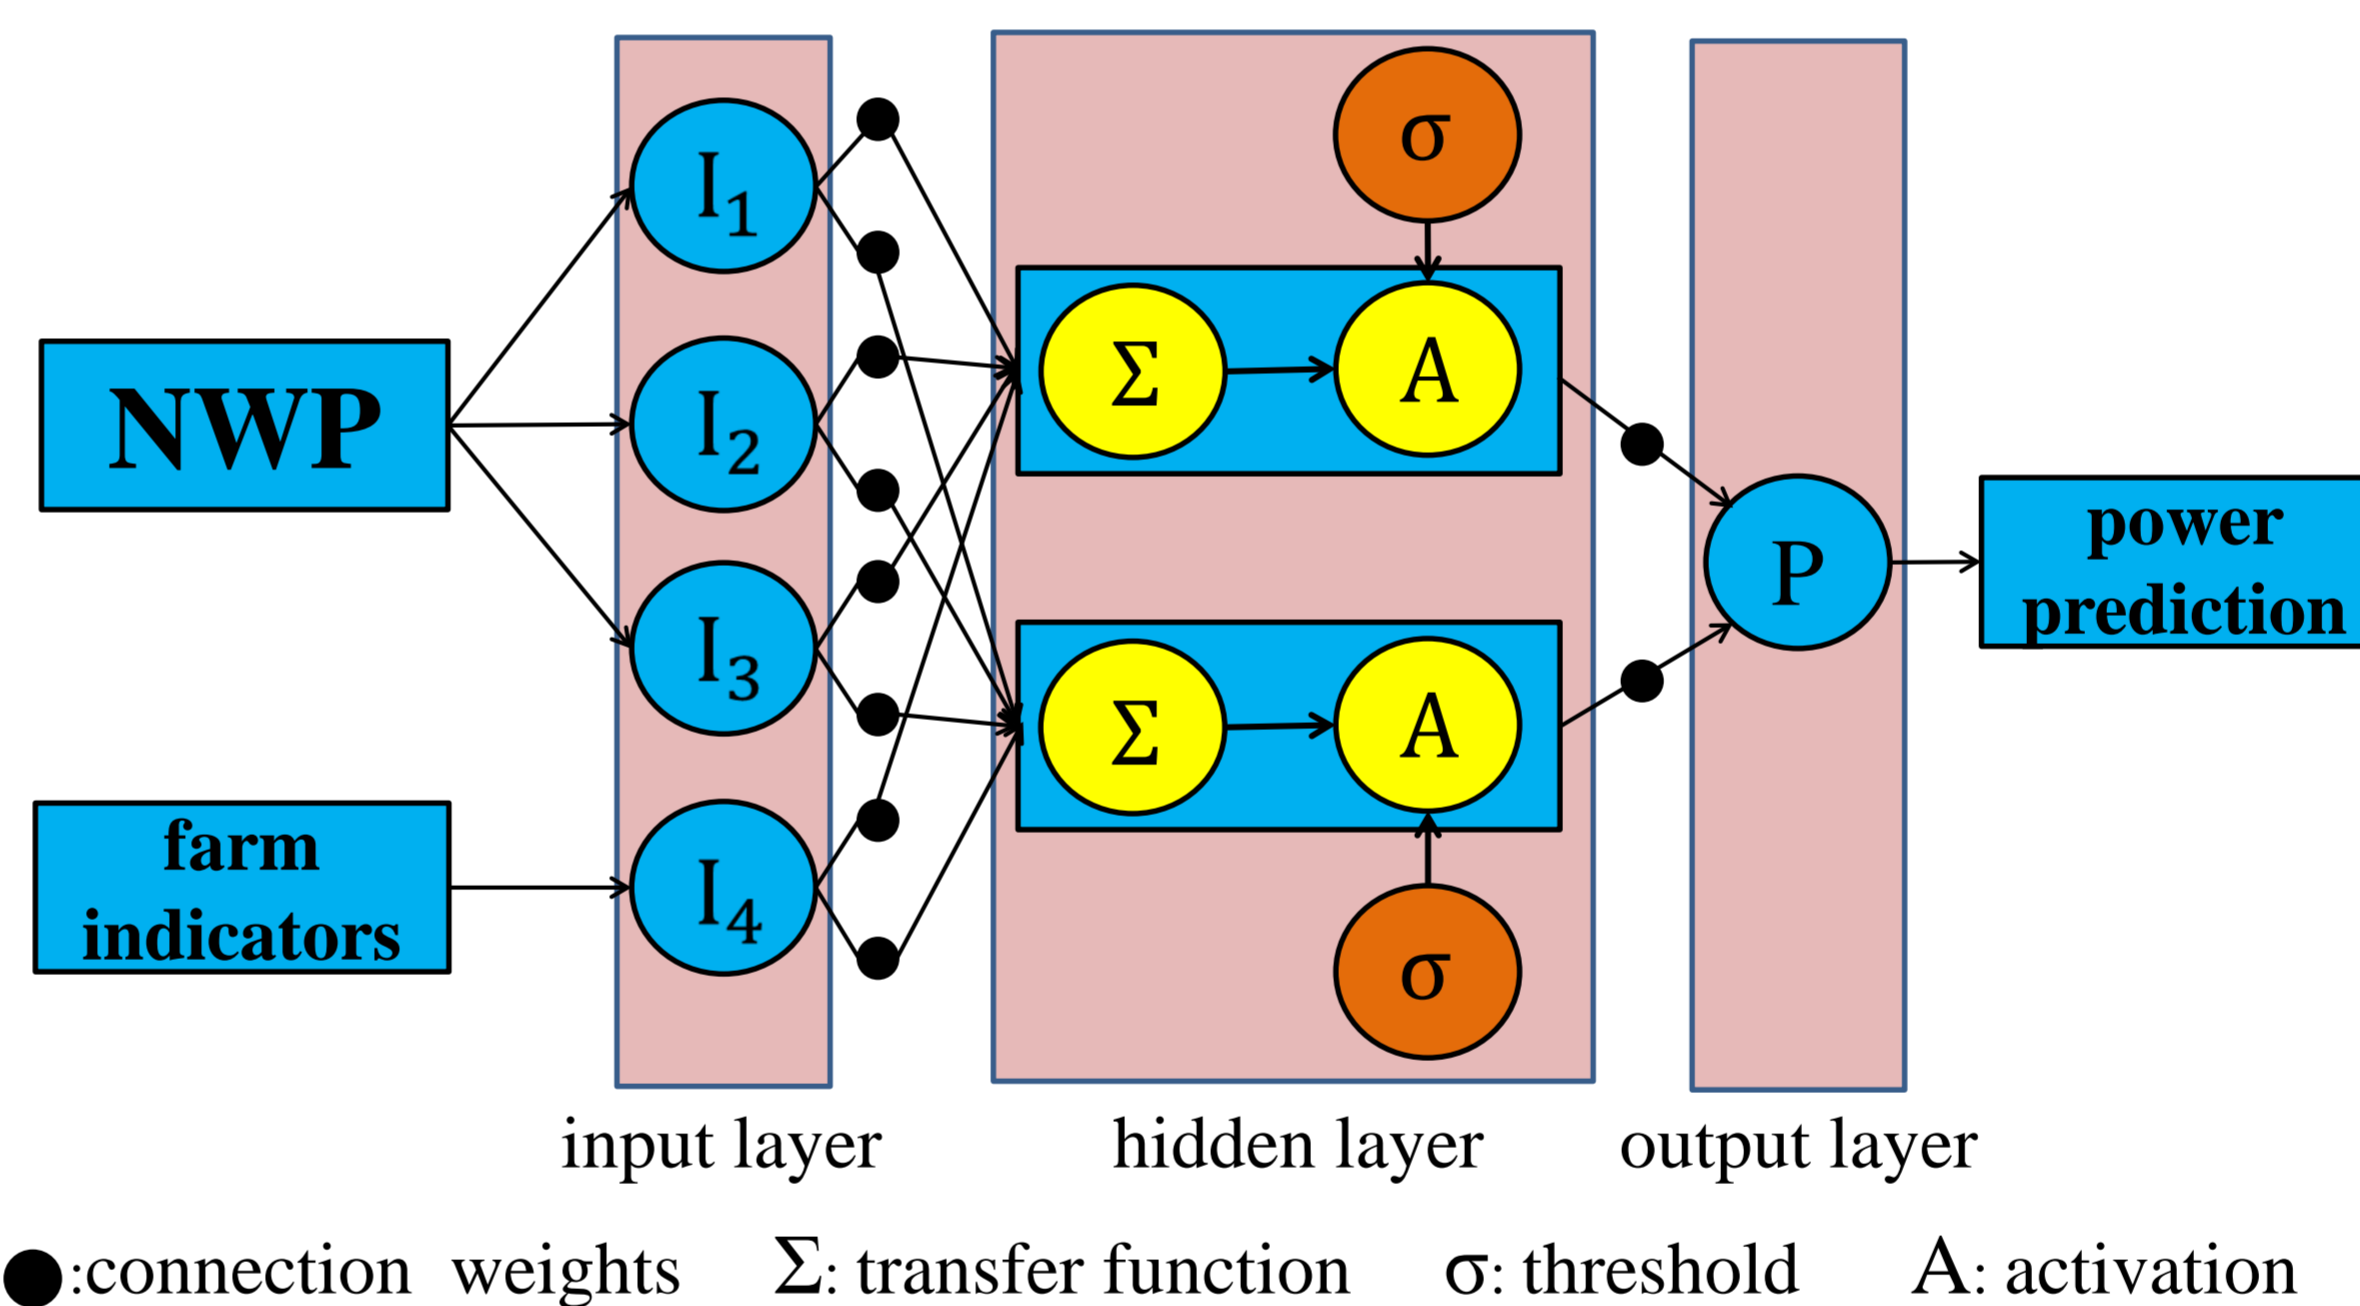
• Zeitverlauf von Produktionsdaten

## Prinzip eines Künstlichen Neuronales Netzes (KNN)

Schematische Darstellung eines ‚feed-forward‘ neuronalen Netzwerkes, das so für die Leistungsprognose verwendet wird.

• Im Vergleich zu Produktionsdaten werden Beziehungen mit unterschiedlichen Gewichten zwischen den Input-Daten und dem tatsächlichen Ertragsdaten ermittelt. Mit zunehmender Trainingszeit ergeben sich Wichtigkeitsfaktoren, die dann unverändert für die Prognose verwendet werden.

• Je besser man die Eingangsdaten charakterisieren kann (Bsp. analytische Leistungskennlinien, Inhomogenitätsindex), desto kürzere und erfolgreichere Trainingszeiten werden für ein KNN benötigt. ●:connection weights  $\Sigma$ : transfer function  $\sigma$ : threshold A: activation



## SOLAR ENERGIE

NWP (numerische Wettervorhersage):

Meteorologische Informationen (u.a.):

$I_1$ : Globalstrahlung

$I_2$ : Tageszeit

$I_3$ : Lufttemperatur

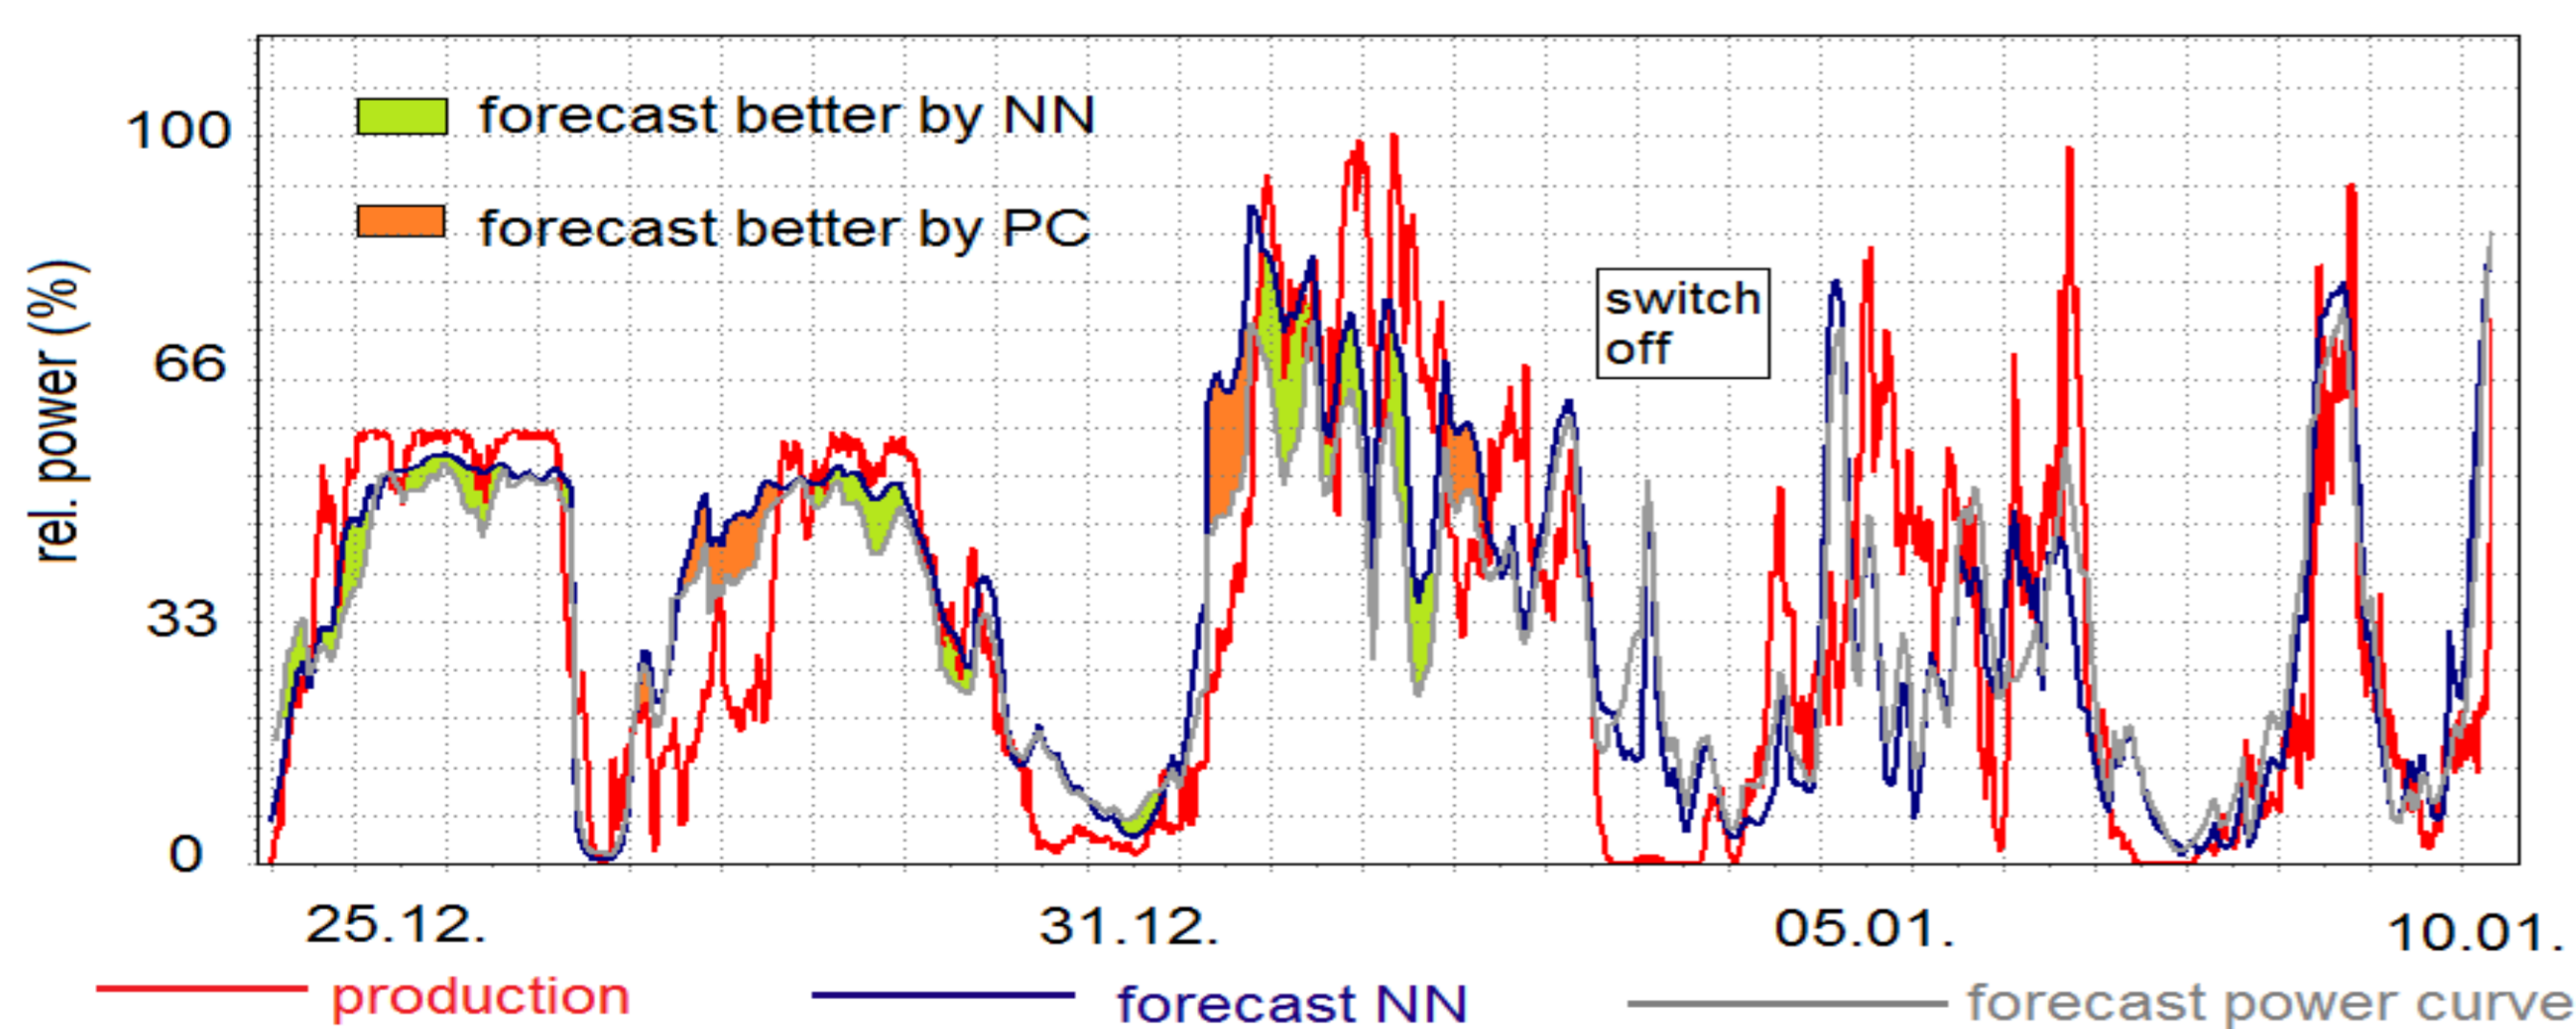
PV-Park-Charakteristik ( $I_4$ ):

• installierte Leistung  $P_{max}$

• Ausrichtung

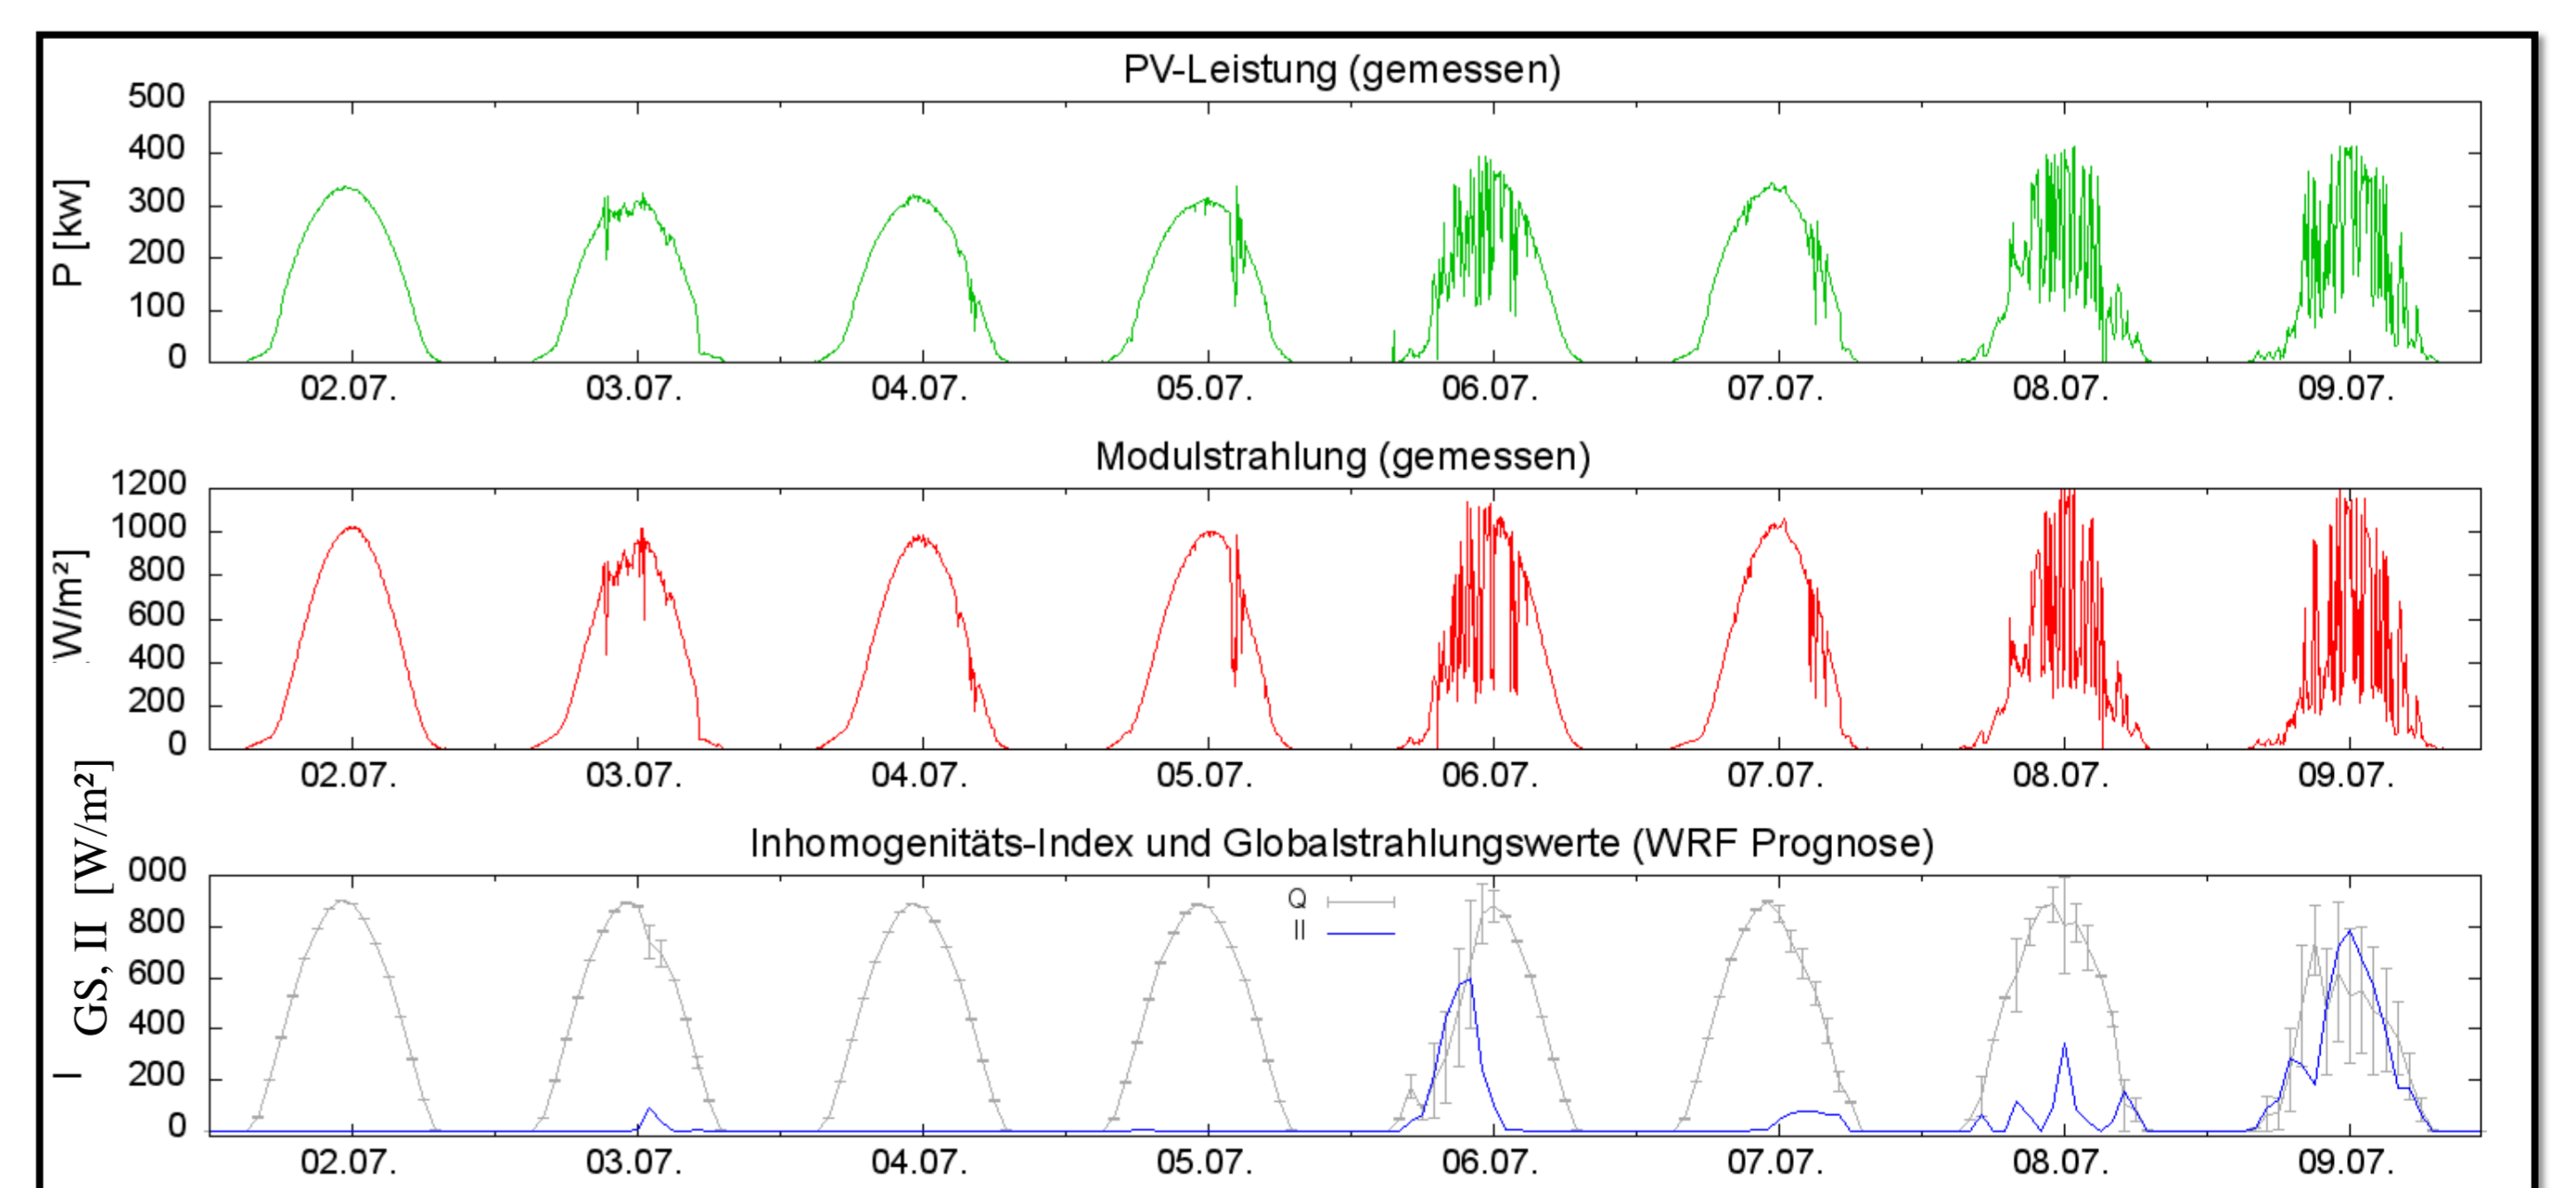
• Zeitverlauf von Produktionsdaten

## Der Einfluss der Verwendung einer analytischen Leistungskennlinie auf die Vorhersage von Windenergieertrag während der Lernphase des neuronalen Netzes



Leistungsabgabe eines Windparks im Vergleich zur Prognose (Day-Ahead) während der Trainingsphase des neuronalen Netzes, einmal mit (PC) und einmal ohne (NN) Vorgabe einer regionalisierten, analytischen Leistungskennlinie (Die Unterschiede verschwinden mit zunehmender Trainingszeit).

## Die Vorhersage des Inhomogenitätsindex mit dem numerischen Wettermodell im Vergleich zur beobachteten Leistungsabgabe einer PV-Anlage



Gemessene Leistung (grün) und Modulstrahlung (rot) der Photovoltaik-Anlage nahe Leipzig, prognostizierter (Day-Ahead) Inhomogenitätsindex ( $\Pi$ , blau) und die gemittelten Globalstrahlungsvorhersagewerte (GS, grau) mit der Standardabweichungen vom 02.07.2015 bis 09.07.2015.

## Schlussfolgerung

- Die an Netzübertragungspunkten durch Windparks einer Region bei verschiedenen Windgeschwindigkeiten anliegende Leistung ähnelt zwar der individuellen Leistungskennlinie einer einzelnen Anlage, zeigt aber typische Einflüsse der Umgebung und der Anordnung der Windenergieanlagen. Wird für die Prognose der Windenergieertrages ein KNN genutzt, erweist es sich als hilfreich die Qualität der erreichten Prognoseergebnisse während der Trainingsphase des KNN gegen eine aus Messungen vorher ermittelte analytische Windparkleistungskurve zu messen. Die Trainingsphase kann so zum Teil erheblich verkürzt werden.
- Die Leistungsabgabe von PV-Parks ist im Fall variabler Bewölkung schwer vorherzusagen. Kurzzeitige, auf durchbrochene Bewölkung durch Spiegelwirkung zurückzuführende Überhöhungen des Strahlungsangebotes (Broken Cloud Effekt) werden durch die Modelle nicht ausgewiesen. Aus den mit einem Wettermodell berechneten regionalen Variabilität eine Globalstrahlungsfeldes lässt sich ein Inhomogenitätsindex generieren, mit dessen Hilfe es gelingt für die Prognose der zeitvariablen Leistung eines PV-Parks systematische Informationen bereitzustellen. Bezieht man diesen Index in die KNN- Leistungsprognose ein, dann wird die Vorhersage einer dann auch beobachteten starken zeitlichen Schwankung der Leistungsabgabe bis hin zum Anzeigen eines ‚Broken Cloud Effekts‘ verbessert.

### Referenzen:

Göhler, R., 2015: „Darstellung und Einfluss von durchbrochener Bewölkung auf den Ertrag von Photovoltaik-Anlagen und dessen Prognose. Masterarbeit, Leipziger Institut für Meteorologie, Univ. Leipzig, 88S.

Raabe, A., Wagner, R., Zimmer, J., 2015: Power curves of whole wind farms under real operating conditions. Wiss. Mitteil. Instit. f. Meteorol. Universität Leipzig Bd. 52, S. 87-98.

Wagner, R., 2012: Prognosegüte der Wind- und Solarparks in Norddeutschland. Bachelorarbeit, Leipziger Institut für Meteorologie, Universität Leipzig, 66S.

Wagner, R., Raabe, A., Zimmer, J., 2013: Leistungskurven ganzer Windparks unter realen Betriebsbedingungen. Tagungsbeitrag DACH Meteorologentagung\_2013, Innsbruck, 2.-6.9.2013

Zimmer, J.; Raabe, A.; Heinrich, I.: Increasing grid stability through accurate infeed forecasts of renewable energies, CIRED (22<sup>th</sup> International Conference on Electricity Distribution), Paper Nr. 0381, Lissabon, 29.-30. Mai, 2012