

Volatilitätsprognosen am Intraday-Markt

Machine Learning Methoden für die Flexibilitätsvermarktung

AGENDA

- 1 **KoM-Solution Energy Services**
- 2 **Flexibilitätsvermarktung**
- 3 **Daten**
- 4 **Methodik**
- 5 **Ergebnisse**
- 6 **Zusammenfassung**

1. Wer sind wir ?

KoM-SOLUTION
ENERGY SERVICES

- Als kommunales Unternehmen bieten wir praxisnahe und operativ geprägte **Beratungs- und Dienstleistungslösungen** für die Energiewirtschaft.
- Wir unterstützen Sie bei der **Entwicklung neuer Geschäftsfelder und -modelle** sowie bei der Umsetzung energiewirtschaftlicher Prozesse durch unsere hochautomatisierten IT-Systeme.
- Wir spüren Handlungsfelder der **Energiewende** auf, machen **Wertschöpfungspotenziale** aus veränderten Marktbedingungen sichtbar und halten Sie über Entwicklungen der rechtlichen Rahmenbedingungen und **Trends am Markt** auf dem Laufenden.

1. Unser Produktportfolio



GAS BALANCE DESK

Bilanzkreiskooperation Gas

- Bündelung von Gasbilanzkreisen zur Reduktion von AE*-kosten
- >200 Kooperationspartner
- 290 TWh, 30% des deutschen Gasmarkts

*AE - Ausgleichsenergie



ENERGY TRADING DESK

Handelsplattform Gas und Strom

- Automatisierte 24/7 Bewirtschaftung von Stormportfolien
- Termin, Day-Ahead, Intraday
- EEX, EPEX, OTC

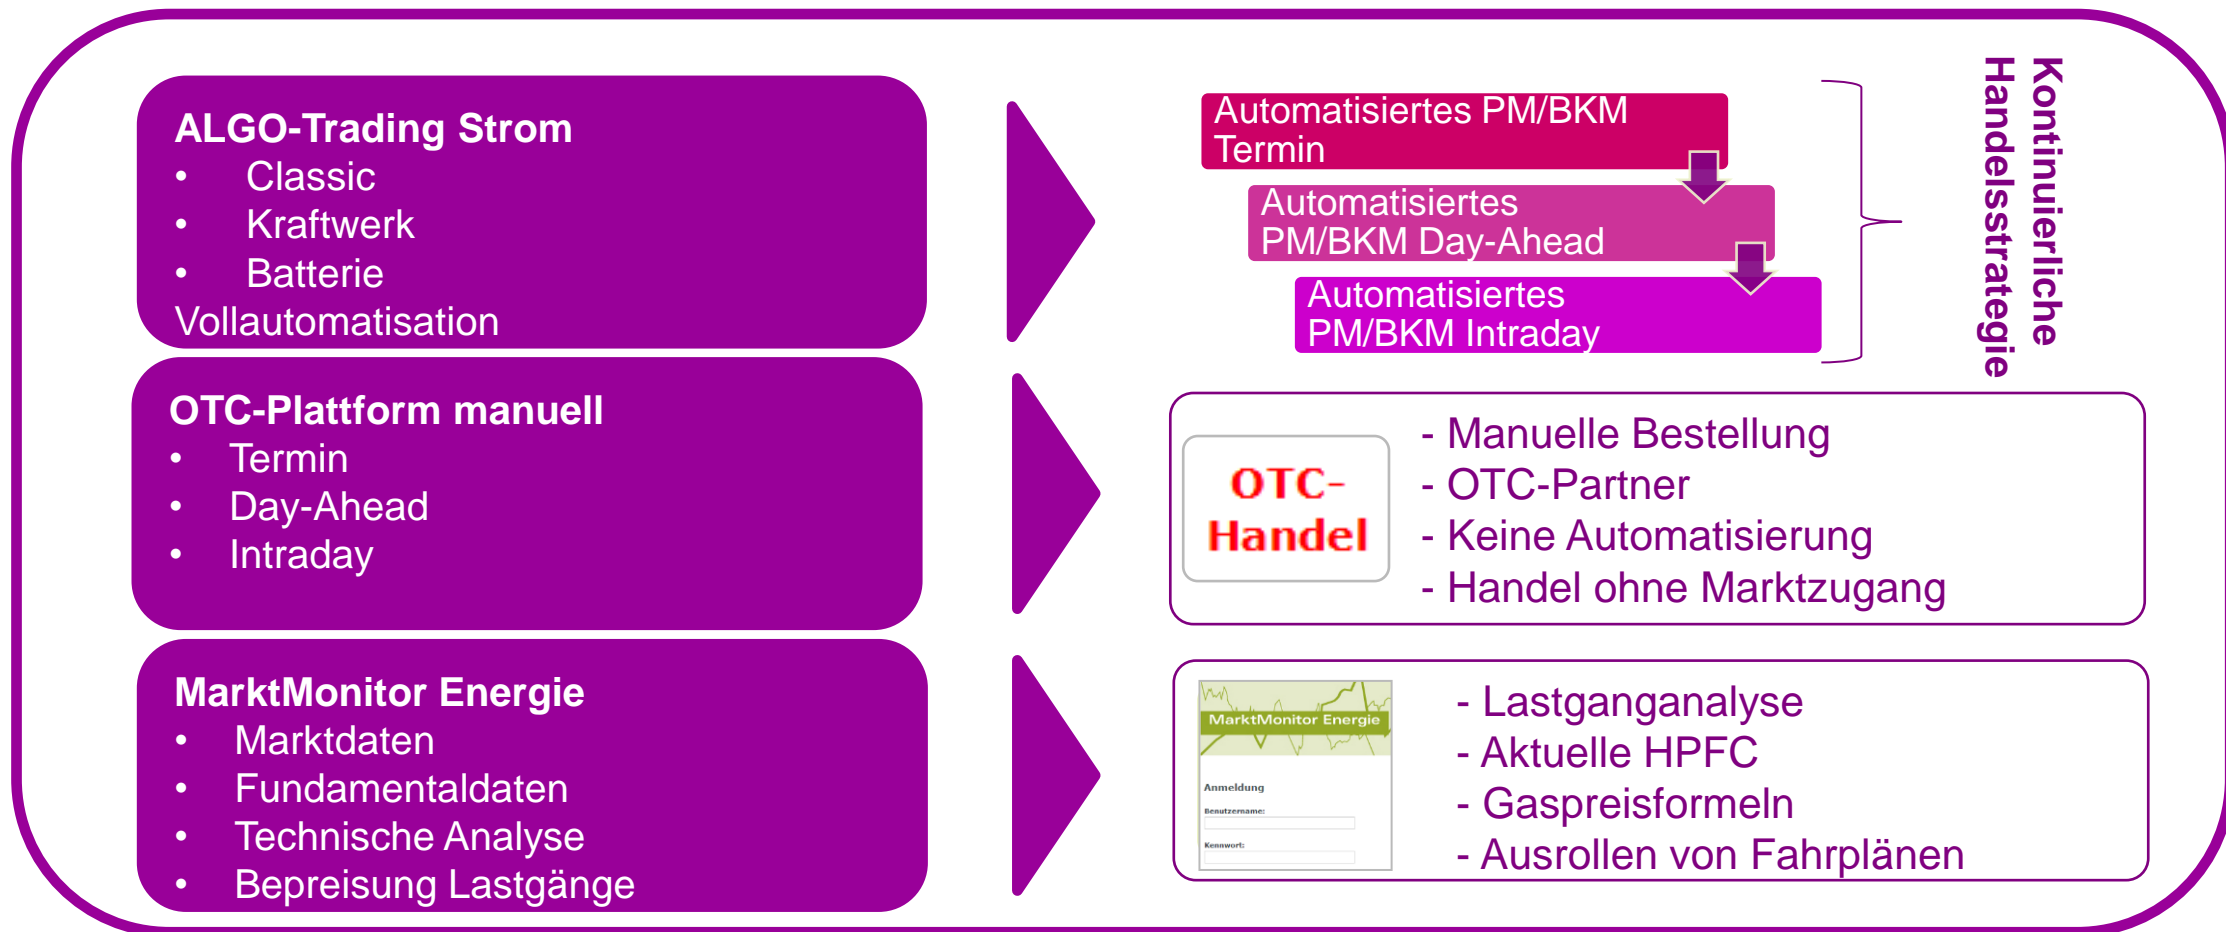


GREEN ENERGY DESK

Kommunale Plattform

- Direktvermarktung von EEG-Anlagen
- Grünstromlieferungen
- Regionalstromkonzepte
- Stromkennzeichnung

ETD-STROM



2. Flexibilitätsvermarktung: Ausgangslage

- Sinkende Strompreise greifen herkömmliche Geschäftsmodelle der EVU's an.
- Fehlende Investitionsanreize in flexible Erzeugungskapazitäten
- Rückbau steuerbarer Erzeuger: Atomausstieg, Kohleausstieg
- Bedarf an flexiblen Erzeugern zum Ausgleich fluktuierender Einspeisung aus EE

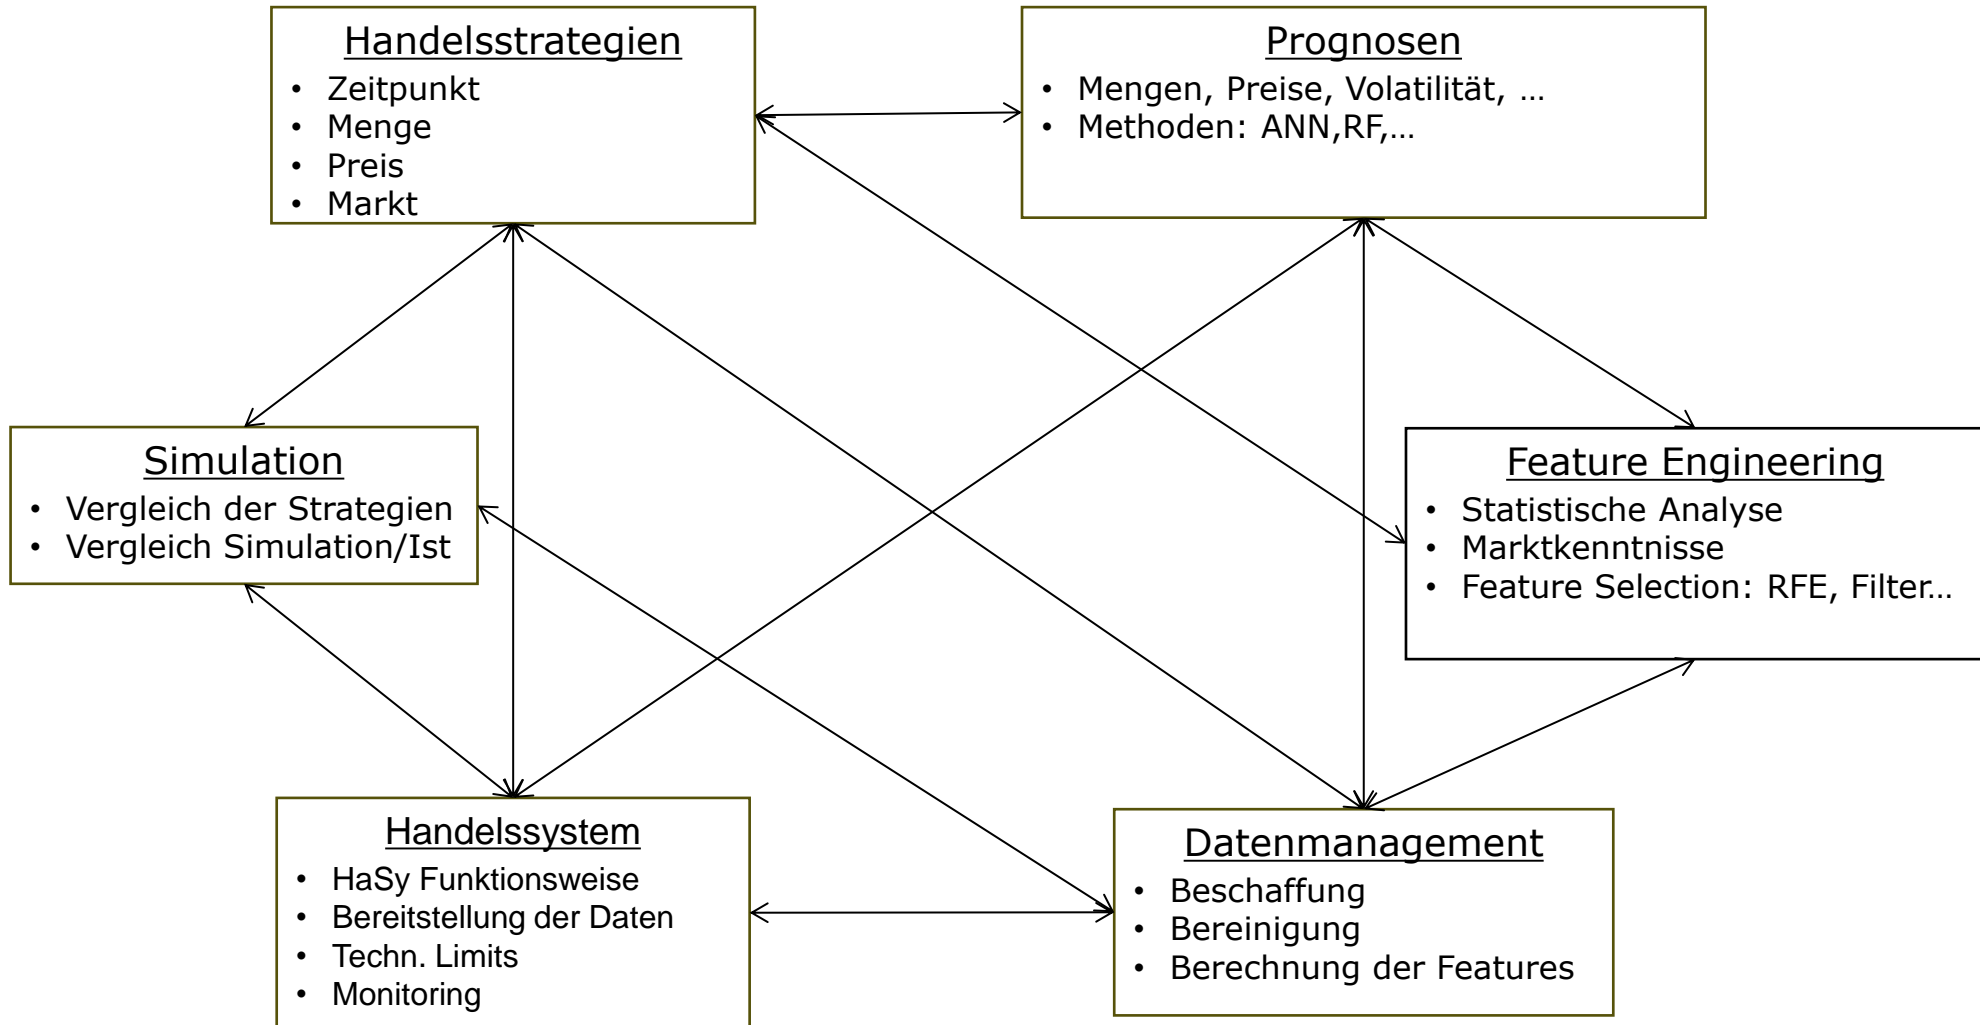
→ Einsatz flexibler Erzeuger als Realloption an kontinuierlichen Intraday-Märkten

2. Flexibilitätsvermarktung: Problemstellung

- Realloptionsbewirtschaftung: Positionsöffnung(long/short) und (möglichst) finanzielles Schließen, ansonsten Einsatz der Realloption.
- Optimierungsproblem Kraftwerkseinsatzentscheidung:
 - Intraday-Markt für $\frac{1}{4}$ h Produkte (IDM15)
 - Intraday-Markt für 1 h Produkte (IDM1)
- Volatilität eines Handelszeitraums ist ein wichtiger Indikator zur Bewertung des Erlöspotenzials
- Wenn Volatilität im voraus bekannt, könnte die verfügbare Flexibilität für Handelszeiträume mit hohem Erlöspotenzial reserviert und der lukrativste Markt bewirtschaftet werden.

→ Volatilitätsprognose für den IDM15

2. Flexibilitätsvermarktung: Systemkomponenten



3. Daten

Rohdaten:

- EPEX IDM15 : Orders & Trades
- 01.01.2017 – 31.12.2017
- Deutsches Marktgebiet
- Aggregation zu 15-min Handelszeitfenstern (TTF)
- Handelsmenge $Q > 0$

Datensets:

Bezeichnung	Handelszeitraum (von...bis Min. zur Lieferung)	Stichproben- größe	Stichproben- dichte [%]
TP0	45 - 60	69.112	98,6
TP1	75 – 120	124.148	88,6
TP2	135 -180	76.429	54,5
TP3	195 - 840	127.112	8,2
Total:		411891	14,2

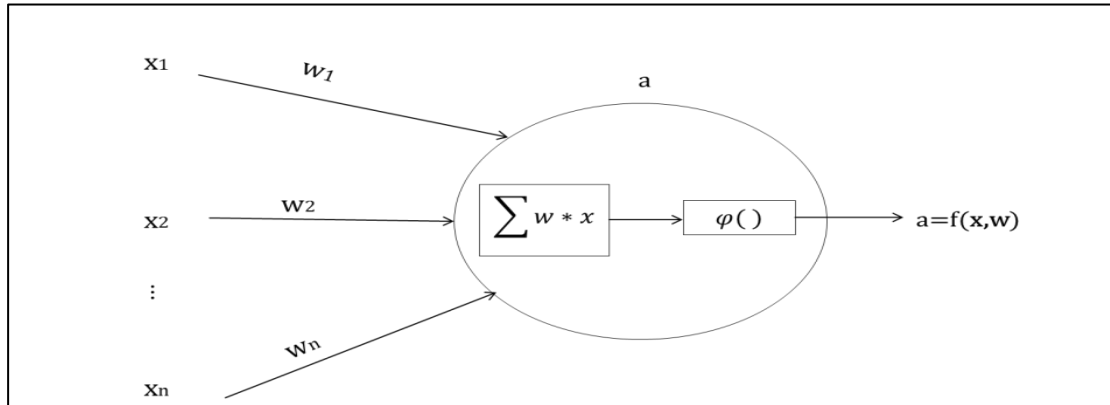
Feature Engineering:

- **Orderbuchbasierte Features:** Orderbuchtiefe(Volumen, Anzahl) , Bid, Ask, Bid-Ask-Spread, Slope, Curvature ...
- **Zeitbezogene Features:** Lieferzeit (Wochentag, Stunde, Min), Handelszeit, Minuten bis zur Lieferung
- **Autoregressive Features:** Handelsmenge, Range, Orderbuch-Features, Trendgrößen ($\Delta t-1$)
- **Total:** 62 Einflussgrößen

Zielgröße: $Range_{class}$: [High, Medium, Low]

$$Range := p_{max} - p_{min}$$




4. Methodik: Künstliche Neuronale Netze



Neuron:


- Analogie zur Biologie
- Nicht lineare Transformation

Activation Functions



Künstliches Neuronales Netzwerk (MLP):

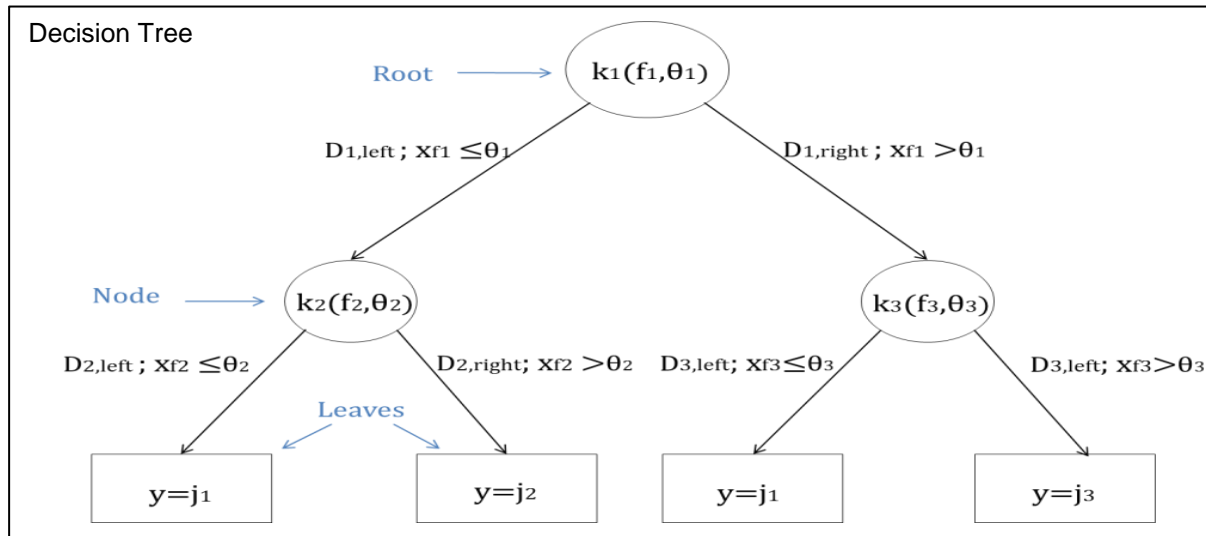

- Schichtweise Verknüpfung einzelner Neuronen zu einem Netzwerk
- Approximiere unbekannte Funktion $f(x)$ durch $f_{\text{app}}(x, w)$
- Optimierungsproblem: Passe Gewichte w an, sodass f_{app} und f möglichst übereinstimmen.
- Lösungsalgorithmen : sgd, adam, lbfgs



4. Methodik: Random Forests

Decision Trees:

- Knoten: Aufteilung des Datensets
- Feature- und Grenzwertwahl zur Minimierung der Label-Heterogenität
- Heterogenitätsmaße (Impurity Functions):
Gini-Impurity; Entropy
- Nachteile: Geringe Performance & Robustheit



Random Forests:

- Ausgleich der Nachteile durch Kombination einzelner, unabhängiger Decision Trees (DT) zu „Forests“.
- Jeder DT bekommt ein zufälliges Featuresubset zugeordnet
- Das Ergebnis ist der Wert mit den meisten Stimmen (bzw. Mittelwert)

4. Methodik: Modelldesign & Berechnungsprozedur

Feature Selection: Spearman Filter (Spear) & Recursive Feature Elimination (RFE)

MLP Classifier:

- Activation Function: Sigmoid, Tanh, ReLU
 - Solver: sgd, adam, lbfgs
 - Netzwerktopologie:
 - I: [20] II: [30,10,3]
 - III. [50,30,10,3] IV. :[100,80,50,30,7,5,3]
- 36 Modelle

Random Forest Classifier:

- DTs: [10,50,100,200,500]
 - Min. Stichproben pro Endknoten [2,5,10]
 - Homogenitätsfunktion: Gini, Entropie
- 30 Modelle

Grid Search: 66 Modelltypen, 3 Featuresets , 4 Datensets → Total: 792 Runs


Prognosehorizont: 15 Minuten

Datenaufteilung: 80% Training Data, 20% Test Data, zufällig ausgewählt

Implementierung: Source Code in Python (v.3.5), insb. SciKitLearn (v.0.19.1)

5. Ergebnisse: Prognosegenauigkeit

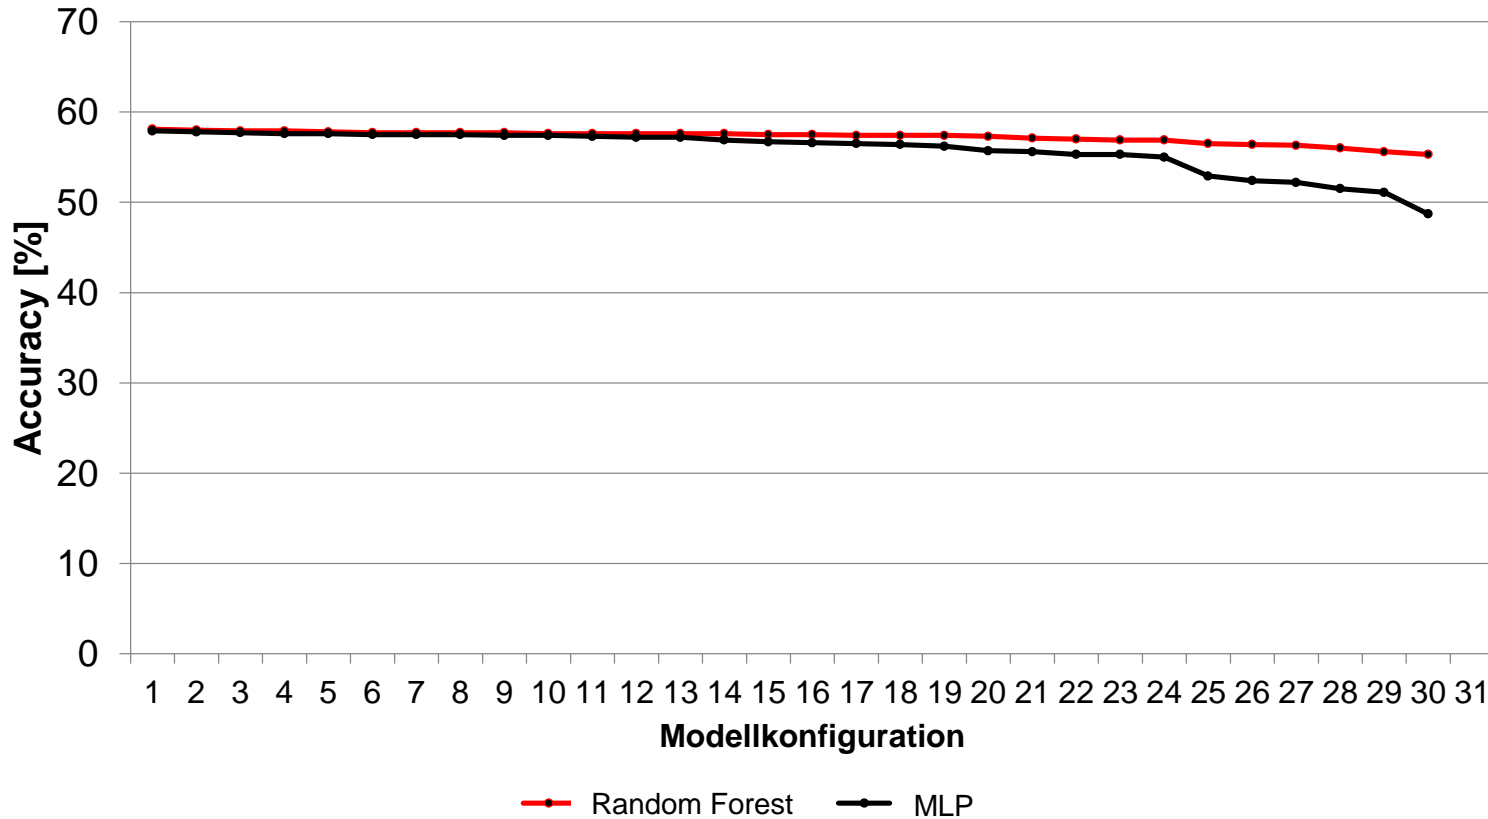
Range_{class} - Prognosegenauigkeit für verschiedene Handelsperioden



- Signifikanter Erkenntnisvorsprung ggü. naiver Benchmark für Handelszeiten bis 120 min vor Lieferung (TP0 & TP1)
- Prognosegüte der Modelltypen unterscheidet sich nur marginal
- Kein Informationsvorteil für Handelszeiten > 120 min vor der Lieferung (TP2 & TP3)

5. Ergebnisse: Einfluss der Modellkonfiguration

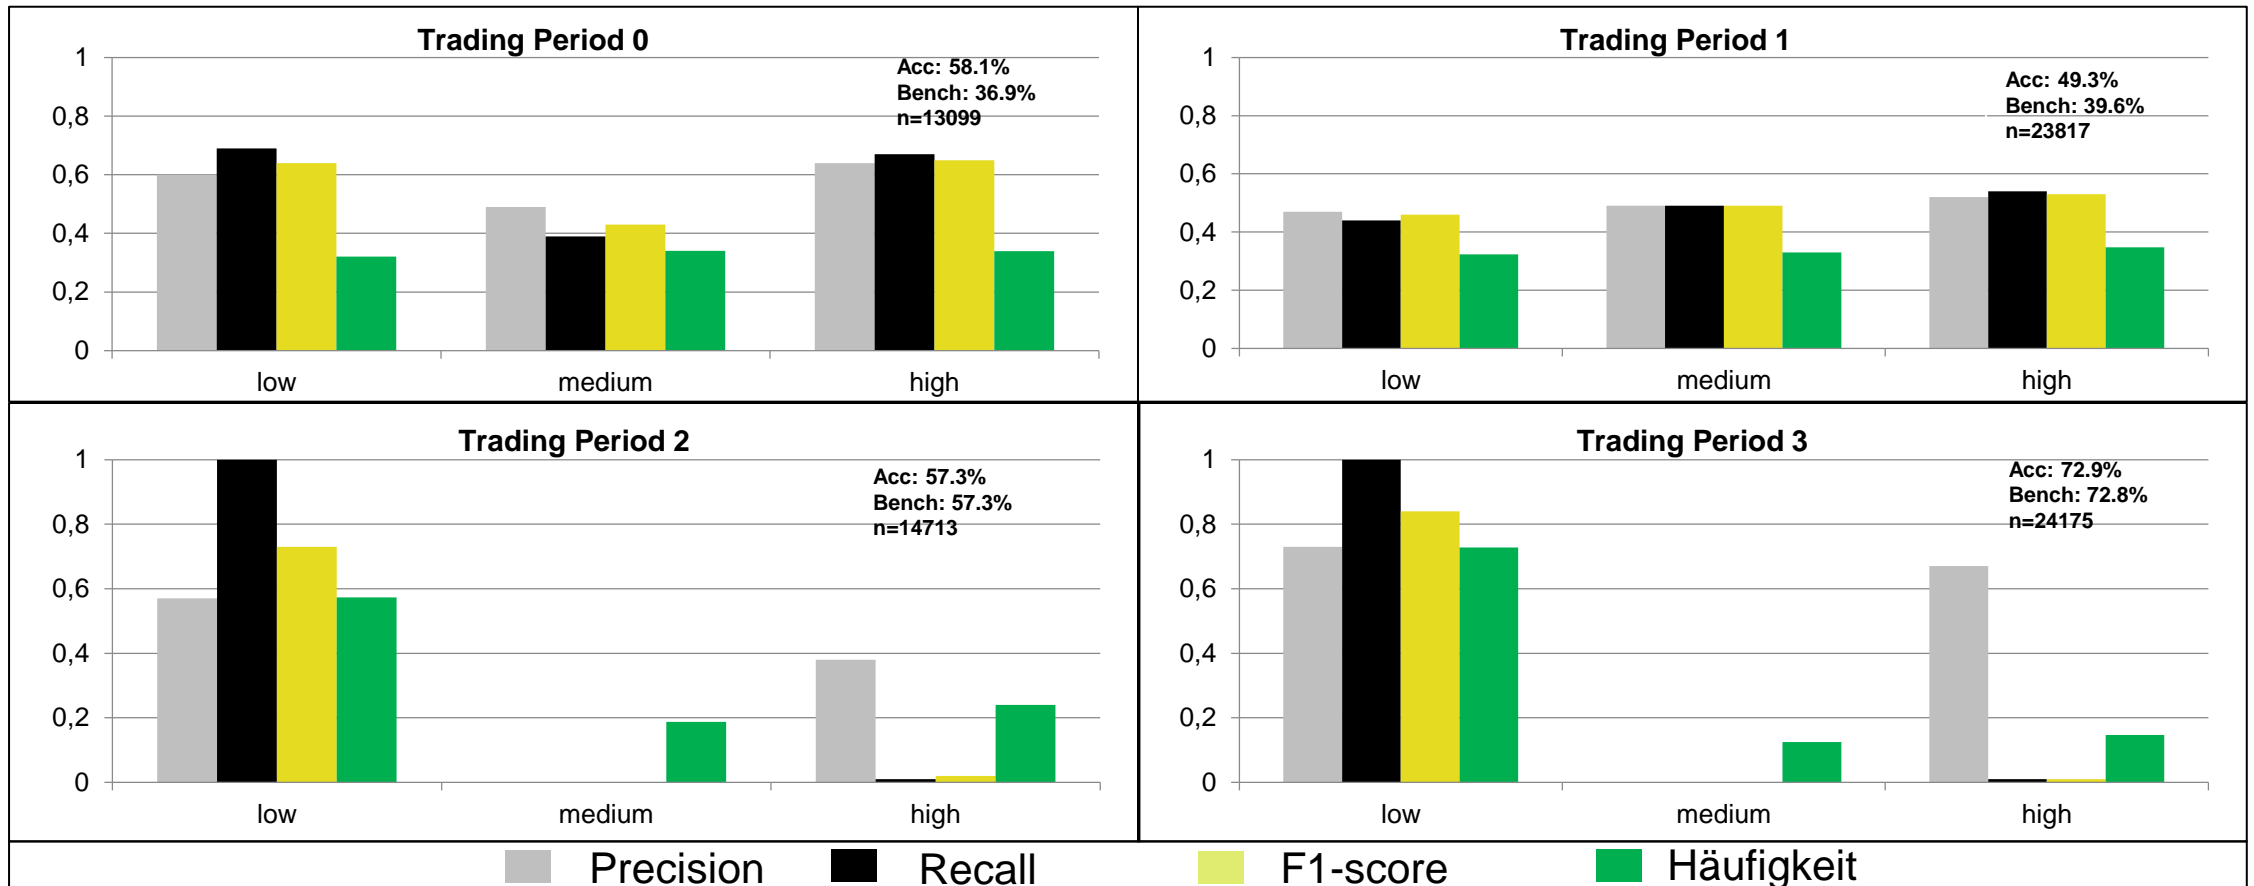
Prognosegenauigkeit verschiedener Modellkonfigurationen für Handelszeiten ≤ 60 min bis zur Lieferung



- Geringer Einfluss der Hyperparameter
- Informationsgehalt der Features wird vermutlich erschöpfend genutzt.

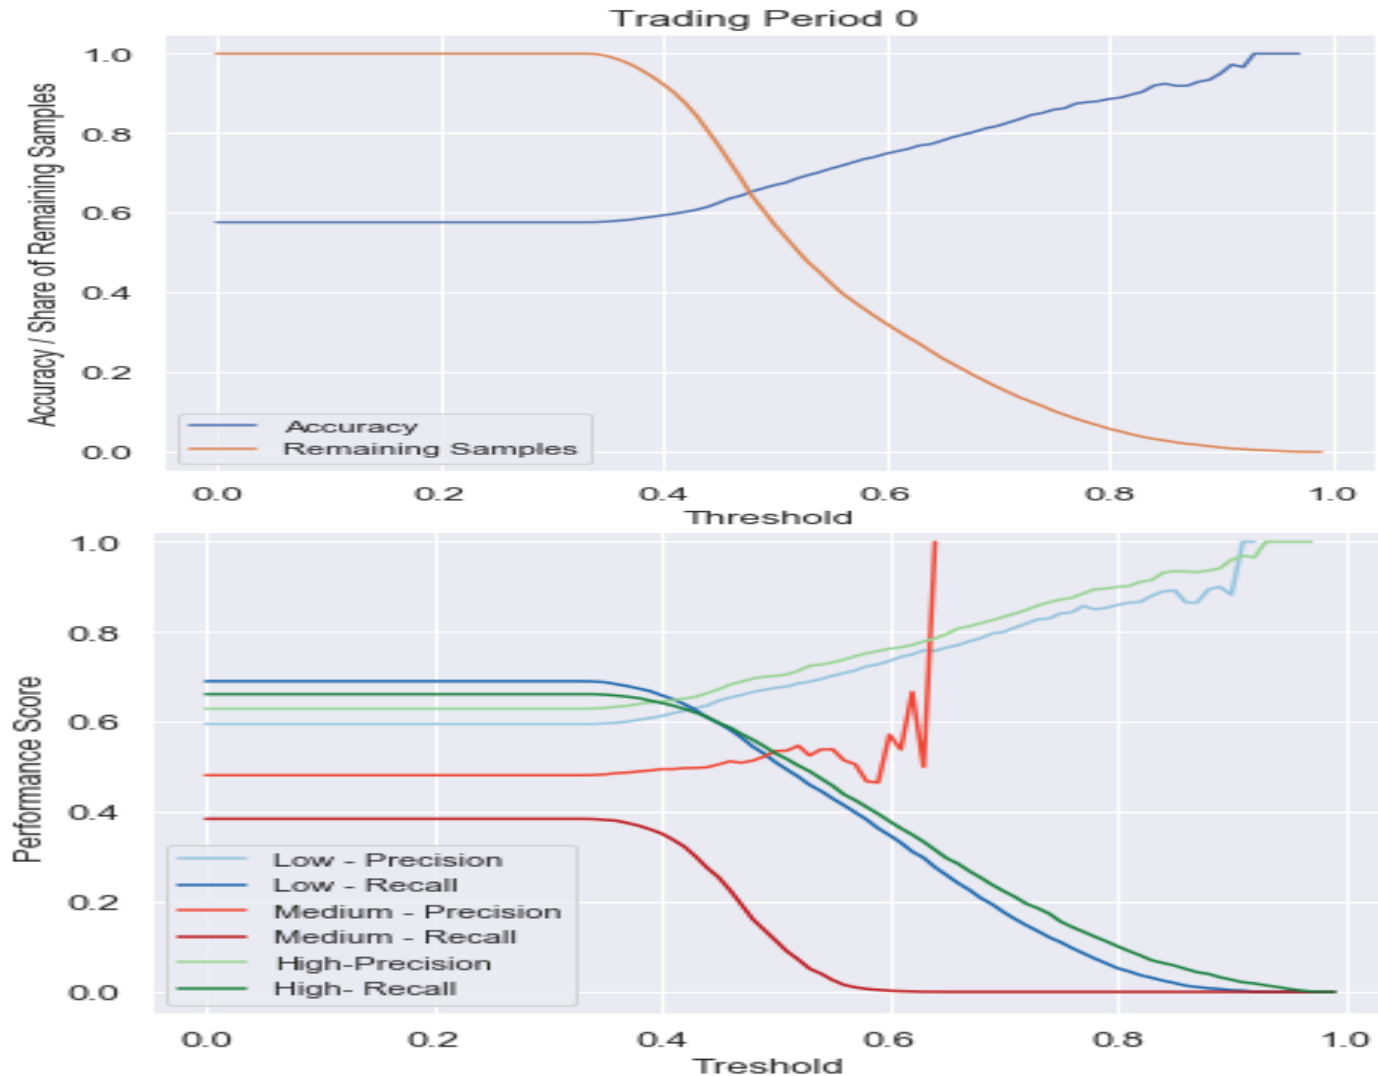
Modelltyp	Hyperparameter	Featureset	Prognosegenauigkeit [%]
MLP_best	lbfgs,logistic,[20]	F_all	57,9
RF_best	200,gini,10	F_all	58,1

5. Ergebnisse: Precision-Recall-Metrics



- In TP0 & TP1 Prognosegüte für alle Klassen etwa gleich, leichter Abschlag für Klasse *Medium* in TP0
- Für Handelszeiten weit vor der Lieferung (TP2 & TP3) keine Differenzierung - (fast) ausschließlich Klasse *Low*
- Geringe Sensitivität vermutlich auf ungleiche Verteilung der Daten zurückzuführen

5. Ergebnisse: Probabilistische Vorhersage - Schwellwertvariation



- Probabilistische Vorhersage

$$\vec{y}_p = \begin{bmatrix} p_l \\ p_m \\ p_h \end{bmatrix}, p_i \in [0,1] \quad y = \max(\vec{y}_p)$$

- Mindestprognosesicherheit θ :

$$y < \theta \Rightarrow \text{k.A.}$$

- Trade-Off :
Prognosegüte vs. -häufigkeit
- Anwendung zur Risikominimierung

5. Fazit

TAKE AWAY:

- Realoptionsbewirtschaftung generiert zusätzliche Erlöspotenziale und schafft Investitionsanreize in systemdienliche Flexibilität
- Volatilitätsprognose für die kommenden 15-Handelsminuten auf dem IDM15
- Verwendung von Neuronalen Netzen und Random Forest Modellen
- Signifikante Erkenntnisvorsprünge ggü. Benchmark zu Handelszeiten nahe der Lieferung
- Feature Engineering wichtiger als Modelltyp und Hyperparameter
- Schwellwertvariationen probabilistischer Vorhersagen zur Anpassung der Prognosegüte an individuelle Risikoprofile

Vielen Dank!

Sofian Makhloufi

M.Sc. Wirtschaftsingenieurwesen
Geschäftsfeldentwicklung

KoM-SOLUTION GmbH
Leipziger Platz 3
D-10117 Berlin

T +49 30 32 59 50 - 0
F +49 30 32 59 50 - 298

E-Mail s.makhloufi@kom-solution.de
Web www.kom-solution.de