

Entwicklung eines empirischen KI-basierten Prognosemodells für das Umformergebnis beim Walzrunden von Grobblechen

L. V. Kappis, E. von Cramon-Taubadel, P. Froitzheim, W. Flügge

Fraunhofer-Institut für Großstrukturen in der Produktionstechnik Rostock IGP

Lukas.Kappis@igp.fraunhofer.de

Abstract

Das Walzrunden wird zum Rundbiegen von Blechen verwendet. Bei dem Verfahren stellt sich im Grobblechbereich derzeit das Problem, dass die eingesetzten Rundbiegemaschinen überwiegend über keine objektiven Prozesssteuerungssysteme verfügen. Aus diesem Grund muss das Verfahren subjektiv durch den Maschinenbediener gesteuert werden. Hierdurch hängen die Wirtschaftlichkeit und Maßhaltigkeit vornehmlich von dessen Qualifikation und Erfahrung ab. Diese Abhängigkeit ist für die Blechbearbeitungsbetriebe insbesondere vor dem Hintergrund des Fachkräftemangels problematisch. Gegenstand derzeitiger Forschung ist daher die Entwicklung von technischen Systemen, die eine objektive Prozesssteuerung ermöglichen. Eine Möglichkeit hierzu sind Prognosemodelle, die das Umformergebnis vorhersagen und den Maschinenbediener somit bei der Einstellung der Maschine unterstützen können.

Die große Herausforderung bei der Aufstellung von Umformprognosen stellt die Berücksichtigung von Störeinflüssen dar, wie etwa Schwankungen der Werkstück- und Maschineneigenschaften. Durch diese kann das Umformergebnis nicht deterministisch aus der Maschineneinstellung hergeleitet werden. Jedoch wird die Berücksichtigung der Störeinflüsse dadurch erschwert, dass ihr Ausmaß im Allgemeinen erst während der Umformung ersichtlich wird.

In dieser Arbeit wurde ein KI-basiertes Prognosemodell für das Walzrunden von Grobblechen entwickelt, welches die aus der Umformung zu erwartende Plattenkrümmung anhand von Prozessdaten prognostiziert. Hierdurch wird eine erfahrungsgestützte Kompensation von Störeinflüssen ermöglicht, die im Gegensatz zu einem menschlichen Bediener einem objektiven mathematischen Modell unterliegt. Für die Entwicklung wurden synthetische Versuchsdaten verwendet, die mithilfe von FE-Simulationen generiert wurden. Die Prognosegüte wurde anhand von FE-Simulationen und einem Experiment untersucht. Dabei konnte eine gute Zuverlässigkeit nachgewiesen werden.

1 Einleitung

Beim Walzrunden werden Bleche mithilfe von rotierenden Walzen über ihre Länge rundgebogen. Das Verfahren umfasst im Grobblechbereich ($t > 3 \text{ mm}$) ein sehr breites Anwendungsspektrum. Hier wird es beispielsweise für die Herstellung dickwandiger Rohre und Schalen für den maritimen Sektor, den Bereich der Erneuerbaren Energien und die Bauindustrie eingesetzt. Ein typischer Ablauf des Verfahrens ist in der *Abb. 1* dargestellt.

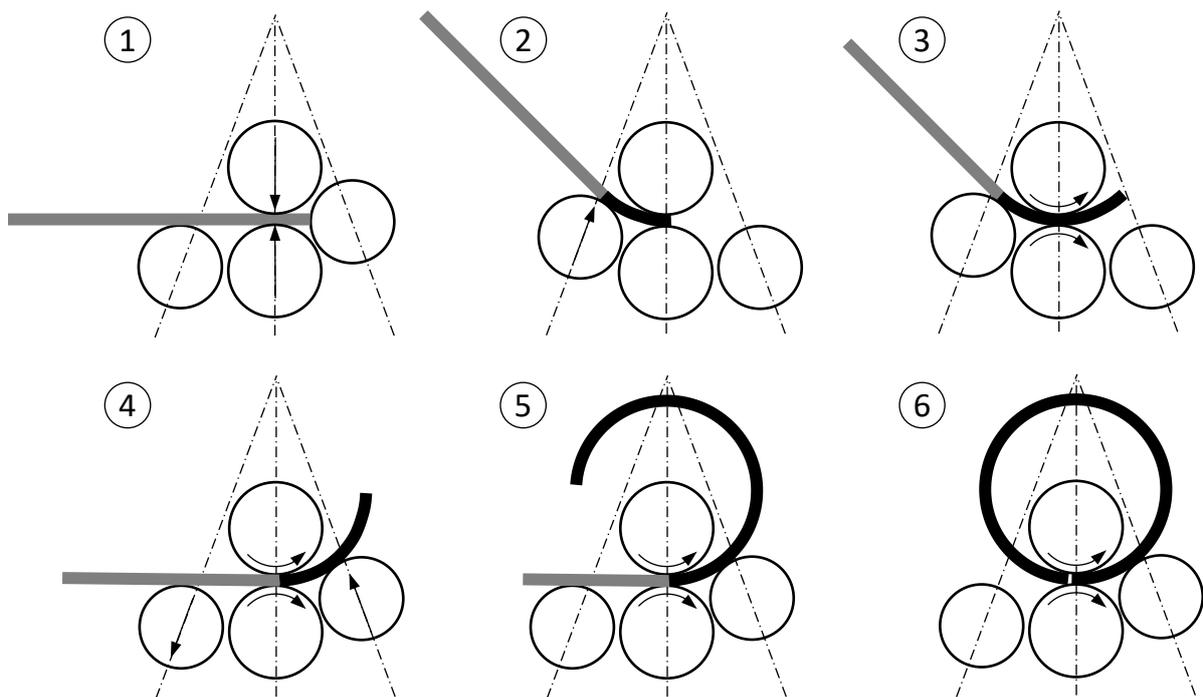


Abb. 1: Prinzipieller Verfahrensablauf beim Walzrunden mit einer 4-Walzen-Rundbiegemaschine.

Im ersten Schritt wird die umzuformende Platte zwischen den zentrischen Walzen eingespannt und ausgerichtet. Daraufhin wird zunächst das vordere Plattenende rundgebogen. Hierzu wird die Seitenwalze auf der Einlassseite zugestellt, womit die Platte lokal gebogen wird (Schritt 2). Anschließend werden die zentrischen Walzen rotatorisch angetrieben (Schritt 3), sodass die Platte vorgeschoben und dabei kontinuierlich rundgeformt wird. Nachdem das vordere Ende umgeformt ist, wird die Seitenwalze auf der Auslassseite zugestellt (Schritt 4), um den restlichen Plattenabschnitt rundzubiegen (Schritte 5 und 6).

2 Stand der Technik

In der Vergangenheit wurde bereits ausgiebig an der Entwicklung von Prognosemodellen für das Walzrunden geforscht. Dabei wurden verschiedene Ansätze erprobt. In einigen Arbeiten wurden analytische Modelle entwickelt, die sich aus geometrischen Verhältnissen zwischen der Rundbiegemaschine und einer kreisförmig umgeformten Platte herleiten [1, 2]. Diese besitzen jedoch die Einschränkung, dass sie nur für das Biegen mit der auslassseitigen Seitenwalze ausgelegt sind, sodass das einlassseitige Biegen hiermit nicht prognostiziert werden kann. In [3] und [4] wurden numerische Modelle für das Walzrunden von Feinblechen entwickelt, in denen das Blech in ideal biegesteife Elemente diskretisiert wird. Zwischen diesen wird ein Drehwinkel anhand einer Momenten-Winkel-Beziehung berechnet, die sich aus der elementaren Biegetheorie nach Ludwik [5] ableitet. Von der Firma HAEUSLER wurde ein Prognosesystem entwickelt, das auf einer iterativen Finite-Elemente-Simulation basiert [6]. Hierbei wird die Plattenkrümmung zwischen den einzelnen Iterationsschritten vom Maschinenbediener vermessen und in das Modell eingegeben, sodass die Prognosegenauigkeit adaptiv verbessert werden kann. Die genannten Modelle haben die Gemeinsamkeit, dass sie den bedeutenden Einfluss von Schwankungen der Umformparameter auf das Umformergebnis nicht ohne Weiteres berücksichtigen können. Sie müssen daher mit Korrektursystemen gekoppelt werden, die eine Kompensation der Schwankungen ermöglichen. Als solche wurden beispielsweise künstliche neuronale Netze (KNN) [4] oder lineare Regressionsmodelle [6] erprobt.

Das in dieser Arbeit entwickelte Prognosemodell grenzt sich von den bisherigen Arbeiten dadurch ab, dass die Prognosen ausschließlich durch ein KNN berechnet werden. Durch diese datengetriebene Form der Modellierung ist dem Modell ein Korrektursystem immanent. Durch das Anlernen auf Prozessdaten können die Prognosen erfahrungsgestützt verbessert werden. Aufgrund des empirischen Ansatzes kann das Modell flexibel an die Verfahrensweise angepasst werden und ist sowohl für die Prognose des einlass- als auch des auslassseitigen Biegens geeignet. Ein weiterer Vorteil ist die Rechengeschwindigkeit des KNN. Es kann Prognosen in Echtzeit bereitstellen und ist damit erheblich schneller als beispielsweise eine FE-Simulation.

3 Entwicklung eines KI-basierten Prognosemodells

Das entwickelte Prognosemodell basiert auf einem künstlichen neuronalen Netz. Mit diesem wird das zu erwartende Umformergebnis als Funktion der lokalen Plattenkrümmung über der Plattenlänge prognostiziert. Weiterhin wurde ein geometrisches Modell entwickelt, mit dem diese Prognosen auch geometrisch visualisiert werden können.

3.1 Charakterisierung des Umformprozesses

Für zuverlässige Umformvorhersagen muss das Prognosemodell alle Parameter, die das Ergebnis signifikant beeinflussen, berücksichtigen. Für 4-Walzen-Rundbiegemaschinen wurde in [7] mithilfe einer numerischen Sensitivitätsanalyse gezeigt, dass das Umformergebnis maßgeblich durch den Zustellweg der seitlichen Biegewalze, die Plattenabmessungen und die mechanischen Eigenschaften des Plattenmaterials beeinflusst wird. Darüber hinaus ist von Bedeutung, ob relativ zur Walzrichtung die seitliche Biegewalze auf der Einlass- oder auf der Auslassseite verwendet wird (vgl. *Abb. 1*).

Um den Einfluss der Biegeseite zu demonstrieren, wurden mithilfe des FE-Modells aus [8] zwei FE-Simulationen durchgeführt. In diesen wurde das Walzrunden einer 30 mm dicken Platte aus S350 simuliert, wobei zum Biegen jeweils eine andere Seitenwalze verwendet wurde. Hervorzuheben ist, dass der Zustellweg in beiden Simulationen gleich groß war. Die Ergebnisse der Simulationen sind in der *Abb. 2* gegenübergestellt. Diese zeigt den Plattenquerschnitt in der Nähe des Walzspalts. Farblich eingefärbt ist der Druck, der in den einzelnen FE-Elementen vorherrscht. Er berechnet sich aus dem negativen arithmetischen Mittel der drei Normalspannungen.

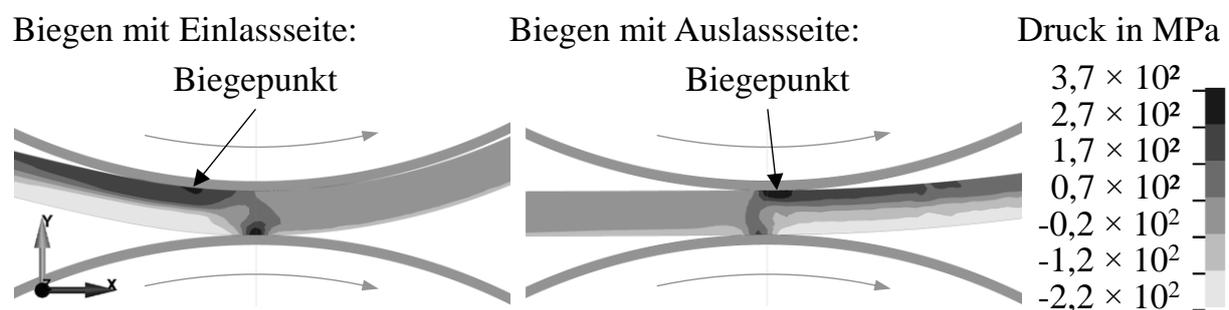


Abb. 2: Druckverteilung im Plattenquerschnitt bei unterschiedlichen Biegevarianten.

Die in der *Abb. 2* dargestellten Zonen mit maximaler Druckbelastung zeigen die Orte an, an denen die Walzen die größten Kräfte einprägen. Auffällig ist, dass sich der Punkt der maximalen Krafteinleitung durch die Oberwalze (Biegepunkt) beim einlassseitigen Biegen nach vorne verschiebt. Beim auslassseitigen Biegen liegt er dagegen nahe der Walzenmitte. Weiterhin fällt auf, dass beim einlassseitigen Biegen deutlich höhere Spannungen in der Platte erzeugt werden – dies gilt insbesondere für die mittleren Plattenfasern. In der Folge wird hierbei eine erheblich stärkere Umformung erreicht.

3.2 Künstliche Intelligenz

Das Ziel des entwickelten KNN ist die Vorhersage des Umformergebnisses in Abhängigkeit von definierten Eingangsgrößen. Nach [4] besteht die Grundidee der Modellierung mit einem KNN darin, einer vordefinierten Modellstruktur einen Datensatz zu Verfügung zu stellen, aus dem die Informationen mit Hilfe eines komplexen Netzwerks von Signalverarbeitungseinheiten (künstliche Neuronen) extrahiert werden. Das KNN kann auf diese Weise "selbständig" lernen, sich einer Lösung für ein bestimmtes Problem anzunähern. Für genaue Umformvorhersagen muss das Modell als Eingangsgrößen die maßgeblich einflussnehmenden Parameter berücksichtigen. Die getroffene Auswahl der Eingangsgrößen wurde in Abschnitt 3.1 begründet.

Den Einfluss von Schwankungen dieser Eingangsgrößen soll das Modell anhand von Prozessdaten empirisch berücksichtigen. Hierzu muss das Ergebnis nach dem Umformen vermessen und in einer Datenbank des KNN archiviert werden. Auf den hinzugekommenen Daten kann das Modell neu trainiert werden, sodass die Prognosen adaptiv verbessert werden. Dies ermöglicht beispielsweise, dass chargenspezifische Schwankungen der Werkstückeigenschaften anhand von Prozessdaten zu chargengleichen Platten erfahrungsgestützt kompensiert werden können. Damit das Modell zwischen verschiedenen Platten und Werkstoffchargen differenzieren kann, soll analog zum KI-basierten Korrektursystem aus [4] für jede Platte und für jede Werkstoffcharge eine Identifikationsnummer angelegt werden. Diese IDs werden in den Datensätzen der Prozessdatenbank gespeichert und kennzeichnen somit die individuelle Beschaffenheit und Chargenzugehörigkeit der Platten.

Für das Training des KNN wurden synthetische Daten aus einer FE-Studie [7] verwendet. Diese Daten wurden durch die Analyse von 100 Umformsimulationen gewonnen, die mit der Software LS DYNA durchgeführt wurden. Hierbei wurde das Walzrunden mit einer 4-Walzen-Rundbiegemaschine und auslassseitigem Biegen mit einem einmaligen Walzdurchlauf simuliert. Eine Übersicht über die verwendeten Trainingsdaten ist in *Tab. 1* dargestellt. Die Ausgabegröße des Modells ist die lokale Plattenkrümmung als Funktion der normierten Plattenlänge. Hierbei ist eine Normierung der Plattenlänge erforderlich, damit das Modell das Umformverhalten von Platten unterschiedlicher Länge vergleichend auswerten kann.

Um die Funktion der lokalen Krümmung über der normierten Plattenlänge für die simulierten umgeformten Platten zu erhalten, wurde eine Methode aus [9] angewandt. Nach dieser wird eine Platte in Abschnitte diskretisiert und die lokale Krümmung jedes Abschnitts mithilfe der folgenden Formel berechnet:

$$r_{innen} = t \cdot \frac{1 + \varepsilon_{innen}}{\varepsilon_{au\beta en} - \varepsilon_{innen}},$$

mit dem inneren Krümmungsradius r_{innen} , der Plattendicke t und den Dehnungen auf der Innen- und Außenseite des Plattenabschnitts ε_{innen} bzw. $\varepsilon_{au\beta en}$. Bei der Analyse der FE-Simulationen wurden als Abschnittslänge drei aufeinander folgende FE-Elemente verwendet.

Anzumerken ist, dass für die Untersuchung nur Prozessdaten zu einzelnen Chargen der Werkstoffe S355 und S690 vorlagen. Bei der Evaluierung der Prognosegüte muss der Einfluss von chargenspezifischen Schwankungen der Werkstoffeigenschaften daher vernachlässigt werden.

Tab. 1: Parametermatrix für das Training des KNN.

Parameter	Parameterbereich
Plattenlänge in mm	2660–5250
Plattenbreite in mm	1400–4000
Plattendicke in mm	30–100
Werkstoff	S355, S690
Zustellweg der Seitenwalze in Grad	16–61,9
Biegevariante	Auslasseitig
Normierte Plattenlänge	0–1
Lokaler Krümmungsradius in mm	

Für das Training wurde der Datensatz randomisiert und in 70% Trainingsdaten und jeweils 15% Validierungs- und Testdaten aufgeteilt. Als Trainingsalgorithmus wurde die Bayessche Regularisierung verwendet. Als Netzwerktopologie wurde ein Feedforward-Netz mit zwei Schichten gewählt, wobei die erste Schicht aus 20 Neuronen mit sigmoidalen Aktivierungsfunktionen und die zweite Schicht aus einem Neuron mit einer linearen Aktivierungsfunktion besteht. Es wurde festgestellt, dass mit dieser Topologie eine sehr genaue Anpassung an die Trainingsdaten ($R = 0,98$) und gleichzeitig eine gute Generalisierungsfähigkeit erreicht werden kann.

3.3 Geometrisches Modell

Mithilfe des geometrischen Modells können die Umformprognosen des KNN als 2D-Kontur visualisiert werden. Das Funktionsprinzip ist in der Abb. 3 dargestellt.

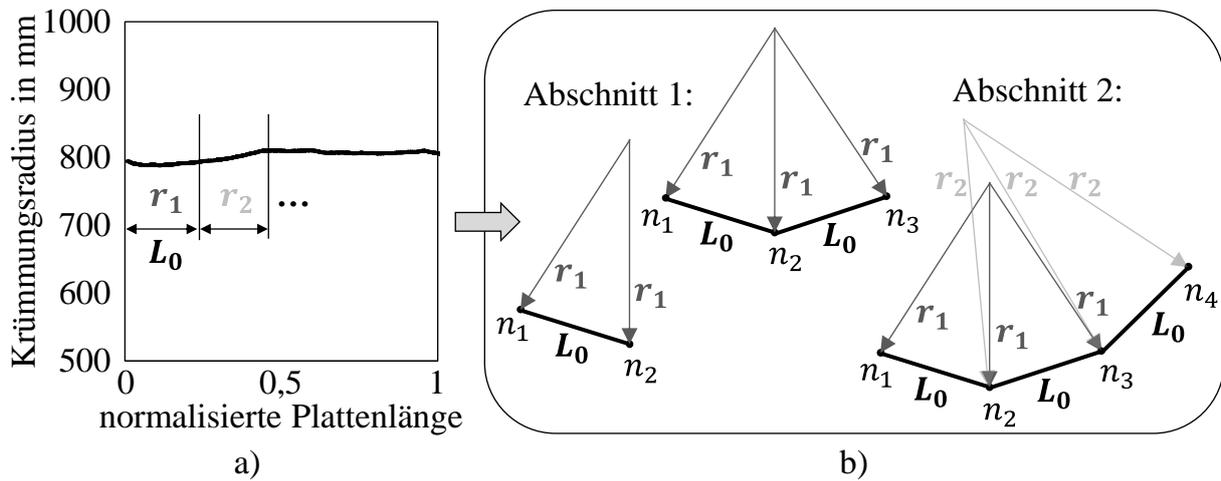


Abb. 3: Methode zur Visualisierung der KNN-Prognose: a) Diskretisierung der Funktion der Plattenkrümmung und b) Ableitung der Plattenkontur.

Die Funktion des lokalen Krümmungsradius über der Plattenlänge wird in einzelne Segmente der Länge L_0 diskretisiert. In jedem Segment i wird der Mittelwert der Krümmung r_i berechnet. Daraufhin wird für jedes Segment i ein Paar aus zwei gleichschenkligen Dreiecken mit der Schenkellänge r_i und der Basislänge L_0 gebildet. Um die Kontur der Platte zu erzeugen, werden diese Dreieckspaare, beginnend mit Segment 1, als Kette ineinander eingepasst. Dabei wird das Dreieckspaar des Segments $i + 1$ so in die bestehende Kette eingepasst, dass sich die Basis seines linken Dreiecks mit der Basis des letzten Dreiecks überlappt. Die kombinierte Kontur der Basen aller Dreiecke (schwarze Linie) entspricht der Kontur der Platte. Dies kann mathematisch einfach gelöst werden, da die Innenwinkel und Seitenlängen aller Dreiecke bekannt sind.

4 Untersuchung der Prognosegenauigkeit

4.1 Erprobung an Simulationsdaten

Die Genauigkeit der KNN-Prognosen wurde anhand von FE-Simulationen untersucht. Zu diesem Zweck wurden neue Parameterkonfigurationen innerhalb des trainierten Parameterbereichs ausgewählt, die jedoch nicht Teil des Trainingsdatensatzes waren. Für diese Parameterkonfigurationen wurden mithilfe des KNN Prognosen aufgestellt und zur Verifizierung zusätzlich FE-Simulationen durchgeführt.

Abbildung 4 a) zeigt beispielhafte Ergebnisse für zwei Parameterkonfigurationen, die sich nur im Zustellwinkel der Seitenwalze mit 30° bzw. 40° unterscheiden. Die simulierten Platten bestanden aus dem Werkstoff S350 und hatten die Abmessungen $3750 \times 1400 \times 75$ mm. Die Kurven zeigen, dass das KNN in der Lage war, die Berechnungen der FE-Simulation sehr gut vorherzusagen. Der kontinuierlich rundgeformte

Abschnitt in der Mitte der Platte wurde in sehr guter Näherung prognostiziert. In diesem Bereich liegt der relative Fehler der Prognosen bei 3,65% bzw. 0,61%. Die Position und Höhe der Spitzen, die sich aus Änderungen des Kontaktzustands mit den seitlichen Walzen ergeben, werden ebenfalls sehr genau vorhergesagt. An den Plattenenden tendiert der Krümmungsradius gegen unendlich, da diese verfahrensbedingt nicht umgeformt wurden.

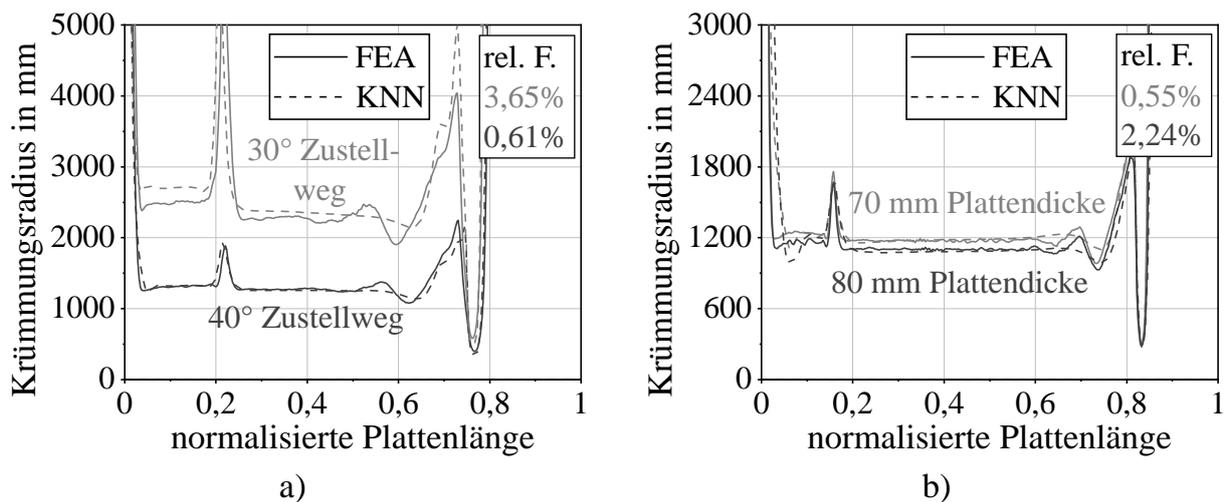


Abb. 4: Vergleich der KNN-Prognosen mit FE-Simulationen bei Variation des Zustellwegs der Seitenwalze (a) und der Plattendicke (b).

Abbildung 4 b) zeigt die Ergebnisse für zwei Parameterkonfigurationen mit unterschiedlichen Plattendicken von 70 mm bzw. 80 mm. Diese Platten bestanden ebenfalls aus dem Werkstoff S350 und hatten eine Länge von 5250 mm und eine Breite von 1400 mm. Der Vorschubwinkel der Seitenwalze betrug jeweils $41,84^\circ$. Auch hier zeigt sich, dass das Prognosemodell die Ergebnisse der FE-Simulation in sehr guter Näherung vorher-sagen konnte. Für den mittleren Plattenabschnitt beträgt der relative Fehler der Prognosen 0,55% bzw. 2,24%. Insgesamt erkennt das KNN den Zusammenhang, dass bei einem konstanten Vorschubwinkel der Seitenwalze der Umformgrad mit der Dicke der Platten zunimmt.

4.2 Experimentelle Erprobung

Für die experimentelle Untersuchung wurde die 4-Walzen-Rundbiegemaschine verwendet, die auch bei der Modellierung betrachtet wurde. Hierbei handelte es sich um eine Maschine vom Typ W12-60*4000 des chinesischen Herstellers Nantong Shengli Heavy Machine Manufacturing. Umgeformt wurde eine Platte aus S350 mit den Abmessungen 2660 x 1400 x 30 mm. Da das KNN mit Daten für das auslassseitige Biegen trainiert

wurde, wurde auch im Experiment mit der Auslassseite umgeformt. Hierbei wurde die Seitenwalze in einem Winkel von $63,4^\circ$ zugestellt. Für die Vermessung des Umformergebnisses wurde ein 3D-Laserscanner der Firma Faro vom Typ Focus 3D X 330 verwendet. Dieser nimmt eine Punktwolke eines einsehbaren Abschnitts der Platte auf. Um den Krümmungsradius dieses Abschnitts zu bestimmen, wurde mit der Software GOM Inspect ein Zylinder durch diese Punktwolke gefittet und dessen Radius bestimmt.

Abbildung 5 a) zeigt den Vergleich der KNN-Prognose mit dem Messergebnis. Dabei ist zu beachten, dass die KNN-Vorhersage die lokale Krümmung der Platte über ihre gesamte Länge angibt. Im Gegensatz dazu konnte mit dem 3D-Scanner nur ein Abschnitt der Platte vermessen werden. Im Diagramm ist der Messwert des 3D-Scans in der Mitte dieses Abschnitts aufgetragen. In der Abb. 5 b) wurde die Vorhersage des KNN mit Hilfe des entwickelten Geometriemodells geometrisch visualisiert und der Punktwolke des 3D-Scans gegenübergestellt.

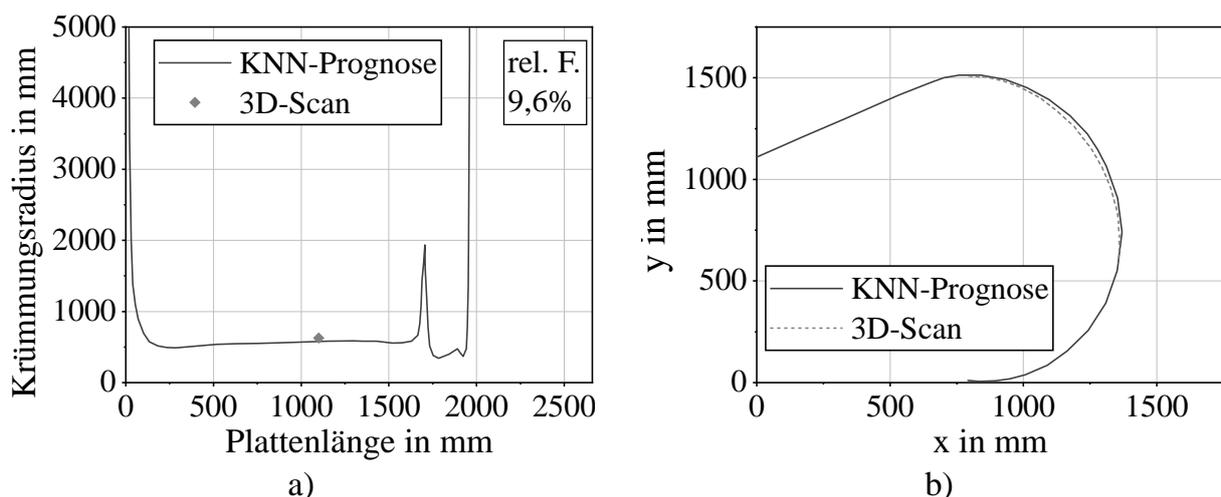


Abb. 5: a) Vergleich der KNN-Prognose mit der Messung des 3D-Scanners. b) Geometrische Gegenüberstellung der Punktwolke des 3D-Scans mit der KNN-Prognose.

Die Ergebnisse zeigen, dass das Prognosemodell eine zu kleine Krümmung und damit eine zu starke Umformung prognostiziert hat. Der relative Fehler zwischen Prognose und Messung liegt bei 9,6%. Dies kann im Sinne einer konservativen Prozesssteuerung jedoch von Vorteil sein, sodass die Prognose für eine erste Annäherung an den Zieldurchmesser verwendet werden kann. Die Abweichung der Vorhersage kann vor allem damit erklärt werden, dass das KNN auf synthetischen Daten aus einer FE-Studie trainiert wurde. Diese sind jedoch bereits mit gewissen Ungenauigkeiten behaftet, da das Modell nur eine Vereinfachung der Realität darstellen kann. In dieser Hinsicht ist ein

großer Einfluss durch die unbekanntenen Schwankungen der Platten- und Maschineneigenschaften anzunehmen, die zu Abweichungen von den Modellannahmen führen.

Aus diesen Gründen ist es wahrscheinlich, dass die Genauigkeit der Vorhersagen verbessert werden kann, wenn das KNN auf experimentellen Daten trainiert wird. Auf der Grundlage von Trainingsdaten von Platten der gleichen Charge können Schwankungen der Chargeneigenschaften abgeschätzt werden. Um das Modell in die Lage zu versetzen, zwischen verschiedenen Platten und Werkstoffchargen zu unterscheiden, können entsprechende Identifikationsnummern zugewiesen und dem Modell als zusätzliche Eingabevariablen zugeführt werden (vgl. Abschnitt 3.2). Inwieweit dies die Modellvorhersagen verbessern kann, muss noch untersucht werden.

5 Zusammenfassung und Ausblick

In dieser Arbeit wurde ein Prognosemodell für das Walzrunden von Grobblechen entwickelt, das auf einem künstlichen neuronalen Netz basiert. Es ermöglicht eine erfahrungsgestützte Vorhersage des Umformergebnisses und kann den Maschinenbediener somit bei der Einstellung der Rundbiegemaschine unterstützen. Anhand von numerischen und experimentellen Untersuchungen konnte grundsätzlich eine gute Genauigkeit der Modellprognosen nachgewiesen werden.

Im Rahmen der Arbeit wurde das Modell auf synthetischen Daten aus FE-Simulationen trainiert. Dabei wurden Schwankungen in den Werkstoffeigenschaften vernachlässigt. Da diese in der Praxis jedoch unvermeidbar sind, steht die Untersuchung der Genauigkeit der Modellprognosen bei Platten aus unterschiedlichen Werkstoffchargen noch aus. Damit das Modell zwischen unterschiedlichen Platten und Werkstoffchargen differenzieren kann, können die Trainingsdatensätze mit entsprechenden Identifikationsnummern versehen werden.

Bevor das Modell in der Praxis angewendet werden kann, muss ein Messsystem entwickelt werden, mit dem kontinuierlich Prozessdaten zum Training des KNN aufgezeichnet werden können. Hierzu haben die Autoren bereits einen ersten Demonstrator entwickelt, der in zukünftigen Arbeiten weiterentwickelt werden soll.

Förderhinweis

Gefördert von der Arbeitsgemeinschaft industrieller Forschungsvereinigungen (AiF) in Zusammenarbeit mit der Forschungsvereinigung Schiffbau und Meerestechnik e.V. (FSM) im Rahmen des Projekts 20444BR.

Literatur

- [1] Wu, K.; Sun, Y.; Cao, C.; Zhou, C.; Liu, Q. und Chang, X.: On Simulation Analysis of Plate Forming and Deformation Compensation Technology of the side roll for Four-roll Plate Bending Machine. *Procedia Engineering*, 2017, 207, S. 1617-1622.
- [2] Wang, Y.; Zhu, X.; Wang, Q. und Cui, X.: Research on multi-roll roll forming process of thick plate. *The International Journal of Advanced Manufacturing Technology*, 2019, 102(1-4), S. 17-26.
- [3] Liewald, M.: Prozessführung numerisch gesteuerter Umformprozesse mittels algorithmischer und wissensbasierter Regler. Dissertation, TU Dortmund, 1990.
- [4] Strassmann, T.: Prozessführung für das Walzrunden auf der Basis neuronaler Netze. Dissertation, TU Dortmund, 1990.
- [5] Ludwik, P.: Elemente der Technologischen Mechanik - Ein Beitrag zur Mechanik der Formänderungen. *technische Blätter*, 1903, S. 133-159.
- [6] Haeusler Holding AG [CH]. Biegemaschine und Verfahren zur Steuerung der Biegemaschine. Erfinder: Zwahlen, A. Datum der Anmeldung: 23.10.2018. DE DE102018126336 (A1).
- [7] Kappis, L. V.; von Cramon-Taubadel, E.; Froitzheim, P. and Flügge, W.: Charakterisierung des Einflusses von Eigenspannungen auf das Umformverhalten von Grobblechen beim Walzrunden. Tagungsband 4. Niedersächsisches Symposium Materialtechnik, Clausthal-Zellerfeld, Deutschland, 25. und 26.02.2021. TU Clausthal.
- [8] Kappis, L. V.; von Cramon-Taubadel, E.; Froitzheim, P. and Flügge, W.: A three-dimensional finite element model for the roll bending of heavy plates using a 4-roll plate bending machine. 13th European LS-DYNA Conference 2021, Ulm, Deutschland. 5. bis 7.10.2021.
- [9] Zhao, W.; Liao, T. W. und Kompotiatis, L.: Stress and Springback Analysis of API X70 Pipeline Steel Under 3-Roller Bending via Finite Element Method. *Acta Metallurgica Sinica*; 2017, 30(5), S. 470-482.