

**interpretable machine Learning for earnings forecasts:
Leveraging high-dimensional financial statement data**

CFR working paper 25-06

Im Mittelpunkt steht die Frage, ob sich künftige Unternehmensgewinne über mehrere Jahre hinweg präziser und zugleich nachvollziehbar prognostizieren lassen, wenn statt einiger weniger Kennzahlen der vollständige Informationsgehalt der Jahresabschlüsse (Compustat) mit modernen Machine-Learning-Verfahren ausgewertet wird. Die praktische Tragweite zeigt sich darin, dass Gewinnschätzungen beispielsweise in Unternehmensbewertungen oder in die Abschätzung impliziter Eigenkapitalkosten (Implied Cost of Capital, ICC) einfließen – und damit für Investoren zentral sind.

Im Leistungsvergleich schlagen die getesteten Machine-Learning-Verfahren (ML) durchweg die besten traditionellen Schätzansätze. So verbessert sich die Genauigkeit von Einjahres-Prognosen, gemessen am preisskalierten absoluten Prognosefehler, um rund 11 %. Selbst bei einem Fünfjahres-Horizont bleibt ein Vorteil von etwa 6 % bestehen. Beide Modellwelten liefern bis etwa drei Jahre im Voraus weitgehend unverzerrte Schätzungen. Bei längeren Horizonten neigen sie zur Überschätzung, wobei die ML-Modelle weniger Bias zeigen. Über die reine Genauigkeit hinaus erklären ML-Modelle deutlich mehr Querschnittsvarianz zukünftiger Gewinne. Zeitreihenanalysen zeigen zudem, dass sich die Performance beider Ansätze nach der Finanzkrise kurzfristig angleicht, danach jedoch wieder zugunsten der ML-Modelle auseinanderläuft.

Differenziert man die Firmen nach ihrem aktuellen Stand im Lebenszyklus, erweisen sich die ML-Verfahren in allen Gruppen als überlegen; die Zugewinne konzentrieren sich jedoch dort, wo Prognosen traditionell schwierig sind. Besonders für Unternehmen im Frühstadium oder im Abschwung lassen sich die größten Verbesserungen erzielen. Analog profitieren die Prognosen für kleinere Unternehmen überproportional. Im Durchschnitt spielen Interaktionen und Nichtlinearitäten zwar eine untergeordnete Rolle, werden aber in frühen bzw. späten Lebenszyklusphasen wichtiger – ein Hinweis darauf, dass ML komplexe Muster in Fundamentaldaten erkennt, die einfache Modelle nicht erfassen können.