

BAB V

KESIMPULAN DAN SARAN

Bab ini memuat kesimpulan utama yang diperoleh dari penelitian serta memberikan saran yang dapat digunakan sebagai acuan untuk penelitian selanjutnya.

5.1 Kesimpulan

Berdasarkan hasil penelitian mengenai evaluasi performa model *SGDRegressor* dengan *incremental learning* dalam memprediksi harga saham PT Telkom Indonesia Tbk (TLKM.JK) periode 2015-2024, dapat ditarik kesimpulan sebagai berikut:

1. *Incremental learning* tahunan terbukti lebih adaptif terhadap perubahan data terbaru karena model diperbarui setiap tahun. Hal ini membuat model lebih responsif dalam menangkap tren jangka pendek, meskipun akurasi prediksinya sedikit lebih rendah karena jumlah data pada tiap iterasi relatif kecil sehingga konteks historis yang dipelajari terbatas. Sebaliknya, *incremental learning* dua tahunan menghasilkan prediksi yang lebih stabil dan konsisten. Dengan cakupan data pelatihan yang lebih panjang, model memperoleh konteks temporal yang lebih luas sehingga mampu mengenali pola jangka menengah dan menghasilkan generalisasi yang lebih kuat. Rata-rata nilai koefisien determinasi (R^2) pada skenario dua tahunan sebesar 0,9658, mendekati *batch learning*, dengan tren metrik kesalahan (MSE, RMSE, MAE, MAPE) yang cenderung menurun secara konsisten. Temuan ini membuktikan bahwa cakupan data historis yang lebih luas berkontribusi pada peningkatan kualitas prediksi, sekaligus mengurangi kebutuhan akan iterasi pelatihan dalam jumlah banyak.
2. *Batch learning* menghasilkan tingkat akurasi tertinggi, dengan nilai R^2 sebesar 0,9969 dan *error* yang sangat rendah (MSE = 344,26; RMSE = 18,55; MAE = 15,09; MAPE = 0,49). Hal ini menunjukkan bahwa ketika seluruh data historis digunakan sekaligus, model mampu mempelajari pola dengan optimal. Namun,

pendekatan ini memiliki keterbatasan mendasar, yaitu tidak dapat diperbarui secara bertahap ketika data baru tersedia. Setiap ada data tambahan, seluruh proses pelatihan harus diulang dari awal, sehingga membutuhkan sumber daya komputasi yang besar dan kurang efisien. Kondisi ini membuat *batch learning* lebih cocok digunakan untuk analisis berbasis data historis, tetapi kurang praktis untuk aplikasi nyata yang menuntut adaptasi berkelanjutan dan pembaruan secara *real-time*.

3. Secara keseluruhan, *incremental SGDRegressor* menawarkan kompromi terbaik antara akurasi, fleksibilitas, dan efisiensi. Meskipun performanya masih sedikit di bawah *batch learning* dari sisi akurasi metrik, *incremental learning* memiliki keunggulan strategis karena dapat diperbarui secara berkelanjutan tanpa harus melatih ulang seluruh dataset. Hal ini menjadikannya lebih hemat komputasi dan relevan untuk sistem prediksi jangka panjang yang membutuhkan adaptasi terhadap data baru secara cepat. Penelitian ini juga menegaskan bahwa strategi pembaruan data berperan sama pentingnya dengan pemilihan algoritma itu sendiri. Dengan demikian, penerapan *incremental learning* terbukti mampu mendekati akurasi *batch learning* sekaligus menjaga efisiensi dan keberlanjutan, sehingga sangat potensial untuk dikembangkan dalam sistem pendukung keputusan di pasar modal yang dinamis.

5.2 Saran

Berdasarkan keterbatasan penelitian ini, beberapa saran untuk penelitian selanjutnya adalah sebagai berikut:

1. Penelitian ini hanya menggunakan harga saham historis sebagai dasar prediksi. Kedepannya, penelitian disarankan menambahkan variabel tambahan seperti indikator teknikal (misalnya *moving average*, RSI, MACD), analisis sentimen berita atau media sosial, serta faktor makroekonomi (inflasi, suku bunga, kurs). Variabel-variabel tersebut berpotensi meningkatkan akurasi model sekaligus memberikan konteks yang lebih realistis dalam menggambarkan pergerakan pasar saham.
2. Karena *incremental SGDRegressor* bersifat linier, hasilnya masih terbatas pada pola linier data. Oleh karena itu, penelitian selanjutnya dapat mengembangkan

pendekatan *hybrid*, misalnya dengan menggabungkan *incremental learning* dengan algoritma *non-linear* seperti *Long Short-Term Memory* (LSTM), *Recurrent Neural Network* (RNN), atau *Random Forest*. Tujuannya adalah memperoleh akurasi prediksi yang lebih tinggi tanpa kehilangan fleksibilitas pembaruan data secara bertahap.

3. Studi ini hanya difokuskan pada saham PT Telkom Indonesia Tbk (TLKM.JK) sebagai contoh kasus. Agar generalisasi metode lebih kuat, penelitian mendatang sebaiknya melakukan pengujian pada saham lain, baik saham BUMN, swasta, lintas sektor, maupun indeks pasar (misalnya IDX30 atau LQ45). Hal ini akan memperlihatkan sejauh mana metode *incremental learning* dapat diterapkan pada berbagai karakteristik saham dan sektor industri.
4. Penelitian ini belum secara eksplisit menilai konsumsi sumber daya komputasi. Oleh karena itu, penelitian lanjutan disarankan untuk menambahkan evaluasi terhadap aspek waktu komputasi, kebutuhan memori, serta *trade-off* antara jumlah *epoch*, ukuran *batch*, dan frekuensi update. Dengan begitu, dapat diperoleh pemahaman yang lebih konkret mengenai efisiensi metode dalam implementasi nyata.
5. Sebagai tindak lanjut praktis, penelitian mendatang sebaiknya mengembangkan sistem prediksi harga saham berbasis *incremental learning* yang dapat diperbarui secara *real-time* dan terintegrasi dengan platform investasi atau sistem pendukung keputusan finansial. Dengan demikian, hasil penelitian tidak hanya berhenti pada tataran akademis, tetapi juga dapat memberikan dampak nyata bagi investor, analis, maupun praktisi pasar modal.