

# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang

Salah satu faktor penurunan kualitas hidup pada lanjut usia adalah ketidaknormalan aktivitas yang disebabkan oleh penurunan kognitif yang terjadi di usia 50 tahun (Xiantao dkk., 2019). Penurunan kognitif pada lanjut usia merupakan kondisi sel saraf otak tidak berfungsi secara normal yang akan menyebabkan masalah pada mobilitas, kemampuan fisik, dan kemampuan dalam cara berpikir di kesehariannya (Feifei dkk, 2020). Kondisi tersebut sangat rentan terhadap penyakit demensia apabila tidak ditindaklanjuti dengan segera, sehingga perlu dilakukan deteksi gejala demensia secara dini.

Deteksi gejala demensia yang dilakukan secara non medis dapat dilakukan dengan cara mengidentifikasi kebiasaan aktivitas lanjut usia dalam kehidupan sehari-harinya. Hal tersebut dikarenakan ciri-ciri gejala demensia yang umum terjadi pada lanjut usia adalah tidak mengulangi kebiasaan aktivitas yang biasanya dilakukan dalam kesehariannya (Arifoglu & Bouchachia, 2018). Untuk mengidentifikasi kebiasaan tersebut diperlukan sebuah sistem yang dapat mendeteksi kebiasaan aktivitas lanjut usia dalam kehidupan sehari-hari. Evaluasi sebelumnya juga telah dilakukan dengan memodelkan aktivitas manusia dalam rutinitas sehari-hari berdasarkan data historis menggunakan model *Long Short Term Memory* (LSTM)(Arifoglu & Bouchachia, 2018; Almeida dan Azkune, 2018; Zhan dan Haddadi, 2019).

Kelebihan model LSTM dalam kasus ini adalah model LSTM memiliki blok memori yang memungkinkan dapat menyimpan pola aktivitas pada periode waktu tertentu (Evermann dkk., 2017), misalnya seseorang selalu melakukan aktivitas menonton TV setelah melakukan aktivitas makan malam, jika seseorang terdeteksi sedang melakukan aktivitas makan malam, maka aktivitas selanjutnya kemungkinan besar adalah menonton TV (Du dkk., 2019). Selain itu, kelebihan model LSTM dalam kasus pengenalan aktivitas manusia memiliki kinerja yang lebih baik dibandingkan

dengan model lainnya, seperti CNN pada kasus klasifikasi aktivitas (Singh dkk., 2017), Naïve Bayes, HMM dan SVM pada kasus deteksi anomali aktivitas (Arifoglu dan Bouchia, 2018), GRU dan Naïve Bayes pada kasus prediksi aktivitas selanjutnya (Du dkk., 2019).

Salah satu permasalahan dalam menggunakan model LSTM adalah model membutuhkan waktu yang lama untuk mencapai konvergensi selama melakukan pelatihan (Almeida dan Azkune, 2018; Yu dkk., 2019). Hal tersebut dikarenakan distribusi *input* setiap lapisan berubah selama pelatihan karena adanya perubahan parameter di lapisan sebelumnya yang akan memperlambat proses pelatihan (Ioffe dan Szegedy, 2015). Terdapat beberapa cara untuk mengatasi permasalahan tersebut, salah satunya adalah dengan menerapkan metode optimasi berbasis gradien (Brownlee, 2018). Metode optimasi berbasis gradien merupakan algoritma optimasi yang memperkirakan kesalahan (*error*) untuk keadaan model saat ini dengan menggunakan sampel data pelatihan, kemudian memperbarui bobot model pada proses propagasi mundur sehingga fungsi kesalahan dapat mencapai nilai minimum.

Metode optimasi yang banyak digunakan saat ini adalah optimasi Adam yang memiliki kelebihan sangat cepat dalam mencapai konvergensi dan sebagai salah satu metode optimasi yang mengatasi lambatnya konvergensi pada metode optimasi *Stochastic Gradient Descent* (SGD) (Kingma dan Ba, 2014). Penelitian sebelumnya juga telah menerapkan model LSTM yang dioptimasi dengan metode Adam pada kasus deteksi aktivitas manusia (Almeida dan Azkune, 2018), namun permasalahan dengan menggunakan optimasi Adam adalah pada kasus tertentu metode optimasi Adam tidak menghasilkan generalisasi yang optimal. Penelitian (Wilson dkk., 2017) menemukan bahwa dalam penelitiannya hasil pengujian model yang dioptimasi dengan metode optimasi adaptif, seperti Adam dan RMSProp menghasilkan generalisasi yang kurang optimal dibandingkan metode optimasi SGD.

Seiring dengan perkembangannya, terdapat peneliti yang menggabungkan metode optimasi Adam dan SGD untuk mempercepat proses pelatihan pada model *neural network* (Keskar dan Socher, 2017). Dalam penelitian tersebut mengusulkan strategi yang dinamakan SWATS (*Switching from Adam to SGD*) yang bertujuan untuk

melakukan transisi optimasi Adam ke optimasi SGD selama pelatihan model. Hasil penelitian tersebut menunjukkan bahwa dengan melakukan transisi optimasi Adam ke optimasi SGD selama pelatihan dapat menghasilkan generalisasi yang lebih optimal. Meskipun pengaruh metode optimasi sangat mempengaruhi terhadap cepat atau lambatnya model dalam mencapai konvergensi, hal tersebut tak terlepas dari konfigurasi parameter yang digunakan seperti penentuan nilai *learning rate* dan pemilihan fungsi aktivasi. Penentuan nilai *learning rate* dan pemilihan fungsi aktivasi merupakan faktor lain yang dapat mempengaruhi model dalam mencapai konvergensi (Brownlee, 2018).

Oleh karena itu berdasarkan pada permasalahan model LSTM yang lambat dalam mencapai konvergensi dan membutuhkan waktu yang lama selama melakukan pelatihan, penelitian ini mengusulkan pengoptimalan model LSTM untuk mempercepat waktu proses pelatihan pada kasus deteksi aktivitas lanjut usia dengan menerapkan tiga metode optimasi, yaitu optimasi SGD, Adam, dan penggabungan kedua optimasi tersebut. Proses optimasi dilakukan dengan berdasarkan konfigurasi penentuan nilai *learning rate* dan pemilihan fungsi aktivasi ReLU, Sigmoid, dan Tanh. Kemudian hasil pengujian model akan dievaluasi dengan mekanisme pengujian akurasi *Top-N* untuk mendapatkan nilai akurasi.

## **1.2 Tujuan Penelitian**

Tujuan dari penelitian ini adalah mengoptimalkan model LSTM pada kasus deteksi aktivitas lanjut usia menggunakan metode optimasi SGD, Adam, dan penggabungan metode optimasi Adam dan SGD dengan berdasarkan penentuan nilai *learning rate* dan pemilihan fungsi aktivasi.

## **1.3 Manfaat Penelitian**

Manfaat penelitian ini adalah mendapatkan model LSTM dengan kinerja terbaik pada kasus deteksi aktivitas lanjut usia.